



UNIVERSIDADE FEDERAL DO PARÁ
NÚCLEO DE DESENVOLVIMENTO AMAZÔNICO EM ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA

BRUNO GONÇALVES DE OLIVEIRA

**Previsão Intervalar de Geração Fotovoltaica por Regressão Quantílica em
Regimes de Irradiância**

Tucuruí
2026



UNIVERSIDADE FEDERAL DO PARÁ
NÚCLEO DE DESENVOLVIMENTO AMAZÔNICO EM ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA

BRUNO GONÇALVES DE OLIVEIRA

**Previsão Intervalar de Geração Fotovoltaica por Regressão Quantílica em
Regimes de Irradiância**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Computação Aplicada do Núcleo de Desenvolvimento Amazônico em Engenharia da Universidade Federal do Pará, como requisito parcial para obtenção do título de Mestre em Computação Aplicada.

Orientador: Prof. Dr. Daniel da Conceição Pinheiro

Tucuruí
2026

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)

G635p GonÇalves de Oliveira, BRUNO.
Previsão Intervalar de Geração Fotovoltaica por Regressão
Quantílica em Regimes de Irradiância / BRUNO GonÇalves de
Oliveira. — 2026.
82 f. : il. color.

Orientador(a): Prof. Dr. Daniel da Conceição Pinheiro
Dissertação (Mestrado) - Universidade Federal do Pará, Núcleo
de Desenvolvimento Amazônico em Engenharia, Programa de Pós-
Graduação em Computação Aplicada, Tucuruí, 2026.

1. Previsão Fotovoltaica. 2. Aprendizado de Máquina. 3.
Previsão Probabilística. 4. Regressão Quantílica. 5. Clima
Tropical. I. Título.

CDD 006.31



Banca Examinadora:

Documento assinado digitalmente
 DANIEL DA CONCEIÇÃO PINHEIRO
Data: 15/02/2026 14:12:26-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Daniel da Conceição Pinheiro

Orientador – PPCA/NDAE/UFPA

Documento assinado digitalmente
 VICTOR PELLANDA DARDENGO
Data: 19/02/2026 12:49:32-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Victor Pellanda Dardengo

Examinador Externo – PPGEEL/UFV

Documento assinado digitalmente
 IAGO LINS DE MEDEIROS
Data: 20/02/2026 12:47:03-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Iago Lins de Medeiros

Examinador Interno – PPCA/NDAE/UFPA

Discente:

Documento assinado digitalmente
 BRUNO GONÇALVES DE OLIVEIRA
Data: 15/02/2026 14:21:21-0300
Verifique em <https://validar.iti.gov.br>

Bruno Gonçalves de Oliveira

Tucuruí (PA), 13 de fevereiro de 2026.

RESUMO

A crescente participação da energia solar fotovoltaica na matriz elétrica brasileira intensifica a necessidade de previsões confiáveis que quantifiquem a incerteza inerente a essa fonte intermitente. Este trabalho investiga a previsão intervalar da geração fotovoltaica horária em clima tropical úmido, com foco na região de Tucuruí, no estado do Pará. Propõe-se um arcabouço metodológico que combina um modelo determinístico híbrido, baseado em *Multilayer Perceptron* (MLP) e XGBoost com seleção automática por limiar de irradiância, e uma extensão probabilística fundamentada em regressão quantílica estratificada por regimes de irradiância, implementada via LightGBM. Os dados meteorológicos horários, obtidos da API Open-Meteo para o período de 2018 a 2023, passaram por pré-processamento que incluiu remoção de multicolinearidade via Fator de Inflação da Variância (VIF), resultando em seis variáveis preditoras. Os intervalos de predição são avaliados por métricas de cobertura (PICP) e largura normalizada (PINAW), sendo posteriormente calibrados por um fator de escala λ para aproximar a cobertura empírica do nível nominal de 80%. Os resultados demonstram que a abordagem por regimes melhora a calibração dos intervalos, especialmente em condições de irradiância intermediária, onde a variabilidade é mais pronunciada. Este estudo contribui para o avanço da previsão probabilística fotovoltaica em regiões tropicais, onde a literatura permanece escassa.

Palavras-chave: previsão fotovoltaica; aprendizado de máquina; previsão probabilística; regressão quantílica; clima tropical.

ABSTRACT

The growing share of solar photovoltaic energy in the Brazilian electricity mix intensifies the need for reliable forecasts that quantify the uncertainty inherent to this intermittent source. This work investigates hourly photovoltaic power prediction intervals in a humid tropical climate, focusing on the Tucuruí region in the state of Pará. We propose a methodological framework that combines a deterministic hybrid model, based on Multilayer Perceptron (MLP) and XGBoost with automatic selection by irradiance threshold, and a probabilistic extension grounded in quantile regression stratified by irradiance regimes, implemented via LightGBM. Hourly meteorological data, obtained from the Open-Meteo API for the period 2018–2023, underwent preprocessing that included multicollinearity removal via the Variance Inflation Factor (VIF), resulting in six predictor variables. Prediction intervals are evaluated using coverage (PICP) and normalized width (PINAW) metrics, and subsequently calibrated by a scaling factor λ to approximate the empirical coverage to the nominal 80% level. Results demonstrate that the regime-based approach improves interval calibration, especially under intermediate irradiance conditions, where variability is more pronounced. This study contributes to advancing probabilistic photovoltaic forecasting in tropical regions, where the literature remains scarce.

Keywords: photovoltaic forecasting; machine learning; probabilistic forecasting; quantile regression; tropical climate.

LISTA DE ILUSTRAÇÕES

Figura 1 – Perfis de GHI em Tucuruí-PA para três condições representativas: (a) dia de alta irradiância, (b) dia de alta variabilidade e (c) dia nublado.	18
Figura 2 – Taxonomia dos principais métodos de previsão fotovoltaica.	19
Figura 3 – Esquema do processo de <i>gradient boosting</i>	21
Figura 4 – Comparação entre previsão determinística e probabilística: (a) a previsão determinística fornece apenas um valor pontual, sem informação sobre a incerteza; (b) a previsão probabilística inclui um intervalo que quantifica a incerteza esperada.	22
Figura 5 – Ilustração conceitual das métricas PICP (cobertura) e PINAW (largura normalizada).	25
Figura 6 – Função de perda <i>pinball</i> para diferentes quantis.	26
Figura 7 – Distribuição do erro de previsão por regime de irradiância nos dados de Tucuruí.	27
Figura 8 – Sistema fotovoltaico em estudo: (a) vista aérea da instalação, (b) localização por imagem de satélite e (c) inversor e quadro de proteção.	36
Figura 9 – Perfil médio diário da produção fotovoltaica (barras) e da irradiância GHI (linha) em Tucuruí-PA	41
Figura 10 – Matriz de correlação entre variáveis meteorológicas e produção fotovoltaica.	43
Figura 11 – Relação entre irradiância solar e produção fotovoltaica, com pontos coloridos pela umidade relativa.	44
Figura 12 – Análise de sazonalidade e distribuição da produção fotovoltaica ao longo do período de estudo.	45
Figura 13 – Contraste entre dias típicos da estação seca e da estação chuvosa.	45
Figura 14 – Distribuição da irradiância média horária equivalente e limiares dos regimes de radiação (Q_{33} e Q_{67}).	48
Figura 15 – Fluxograma sintético da metodologia proposta.	49
Figura 16 – Comparação entre MAE e RMSE por regime de irradiância.	63
Figura 17 – Série temporal: observado vs. mediana prevista (dia representativo).	63
Figura 18 – Erro horário (observado – previsto) em um dia representativo.	64
Figura 19 – Efeito da calibração pós-processamento sobre PICP e PINAW	65
Figura 20 – PICP e PINAW por regime de irradiância.	67
Figura 21 – Intervalos de predição (80%) para um dia representativo do conjunto de teste.	67
Figura 22 – Previsão operacional D+1: híbrido e intervalo quantílico calibrado.	69
Figura 23 – Dispersão entre valores observados e previstos (mediana) no conjunto de teste.	71
Figura 24 – Distribuição de erros (observado – previsto) por regime de irradiância.	72

LISTA DE TABELAS

Tabela 1 – Distribuição dos dias por regime de variabilidade em Tucuruí-PA (2018-2023).	27
Tabela 2 – Síntese comparativa de trabalhos relacionados e posicionamento desta dissertação.	35
Tabela 3 – Especificações técnicas do sistema fotovoltaico em estudo.	37
Tabela 4 – Variáveis disponíveis no conjunto de dados bruto.	38
Tabela 5 – Estatísticas descritivas das variáveis meteorológicas e da produção FV.....	39
Tabela 6 – Resultado da análise de multicolinearidade via VIF.....	39
Tabela 7 – Resumo do pré-processamento e filtragens aplicadas ao conjunto de dados (2018–2023).....	42
Tabela 8 – Divisão do conjunto de dados em treino, validação e teste (amostragem aleatória).	46
Tabela 9 – Distribuição dos registros por regime de radiação (conjunto de treinamento).	47
Tabela 10 – Hiperparâmetros do LightGBM para regressão quantílica.....	54
Tabela 11 – Desempenho determinístico global no conjunto de teste.	61
Tabela 12 – Desempenho determinístico por regime de irradiância no conjunto de teste.	62
Tabela 13 – Avaliação probabilística global no conjunto de teste (PICP e PINAW).....	65
Tabela 14 – Avaliação probabilística por regime de irradiância no conjunto de teste (calibrado).....	66

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ANN	<i>Artificial Neural Network</i>
CRPS	<i>Continuous Ranked Probability Score</i>
FV	Fotovoltaico
GHI	<i>Global Horizontal Irradiance</i>
LGBM	<i>Light Gradient Boosting Machine</i>
MAE	<i>Mean Absolute Error</i>
MLP	<i>Multilayer Perceptron</i>
NWP	<i>Numerical Weather Prediction</i>
PICP	<i>Prediction Interval Coverage Probability</i>
PINAW	<i>Prediction Interval Normalized Average Width</i>
PPCA	Programa de Pós-Graduação em Computação Aplicada
PV	<i>Photovoltaic</i>
RMSE	<i>Root Mean Squared Error</i>
UFPA	Universidade Federal do Pará
VIF	<i>Variance Inflation Factor</i>
XGBoost	<i>Extreme Gradient Boosting</i>

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Contextualização e motivação	11
1.2	O desafio do clima tropical úmido	13
1.3	Problema de pesquisa.....	14
1.4	Hipóteses e premissas.....	14
1.5	Objetivos	15
1.5.1	Objetivo geral.....	15
1.5.2	Objetivos específicos.....	15
1.6	Contribuições.....	15
1.7	Organização do trabalho	16
2	FUNDAMENTAÇÃO TEÓRICA E TRABALHOS RELACIONADOS .	17
2.1	Desafios da previsão de geração fotovoltaica	17
2.2	O contexto amazônico: evidências dos dados de Tucuruí.....	17
2.3	Classificação dos métodos de previsão.....	19
2.3.1	Métodos físicos	19
2.3.2	Métodos estatísticos	20
2.3.3	Métodos baseados em aprendizado de máquina.....	20
2.4	Modelos de <i>Gradient Boosting</i>	20
2.5	Previsão determinística versus probabilística	22
2.5.1	Calibração e nitidez.....	22
2.5.2	Intervalos de predição	23
2.6	Métricas de avaliação probabilística.....	24
2.6.1	Cobertura empírica (PICP).....	24
2.6.2	Largura normalizada (PINAW).....	24
2.6.3	O dilema calibração-nitidez	25
2.6.4	A perda <i>pinball</i>	25
2.6.5	Combinação com LightGBM.....	26
2.7	Heterogeneidade da incerteza e regimes de irradiância.....	26
2.7.1	Evidências nos dados de Tucuruí	27
2.7.2	Estratificação por regimes	28
2.7.3	Calibração por fator de escala	28
2.8	Seleção de variáveis e multicolinearidade	29
2.9	Trabalhos relacionados	29
2.9.1	Previsões probabilísticas solares	30
2.9.2	Aplicações de <i>gradient boosting</i> em previsão fotovoltaica	31
2.9.3	Previsão em climas tropicais e lacuna no contexto amazônico	32
2.9.4	Síntese crítica e posicionamento desta dissertação.....	33

2.10	Síntese e posicionamento.....	34
3	DADOS E PRÉ-PROCESSAMENTO	36
3.1	Sistema fotovoltaico em estudo.....	36
3.2	Fontes de dados	37
3.3	Variáveis meteorológicas.....	38
3.4	Seleção de variáveis e remoção de multicolinearidade	38
3.5	Filtragem temporal	40
3.6	Tratamento de valores ausentes	40
3.7	Deteção e tratamento de anomalias.....	41
3.8	Resumo do pré-processamento.....	42
3.9	Análise de correlação	42
3.10	Análise de sazonalidade	42
3.11	Análise de distribuição	43
3.12	Escalonamento de variáveis.....	46
3.13	Divisão treino/validação/teste	46
3.14	Estratificação por regimes de radiação	47
3.15	Resumo do capítulo	47
4	METODOLOGIA	49
4.1	Visão geral da metodologia proposta	49
4.2	Definição do problema e notação	49
4.3	Estrutura experimental e prevenção de vazamento de informação	50
4.4	Modelos determinísticos de referência	50
4.5	Modelo híbrido MLP/XGBoost com seleção por radiação	51
4.5.1	Motivação.....	51
4.5.2	Estratégia de seleção (<i>gating</i>).....	51
4.5.3	Configuração dos modelos	52
4.6	Previsão probabilística via regressão quantílica	52
4.6.1	Perda <i>pinball</i> e estimação de quantis.....	53
4.6.2	Construção de intervalos de predição	53
4.7	Modelo LightGBM para regressão quantílica	53
4.7.1	Justificativa.....	53
4.7.2	Configuração do treinamento	54
4.7.3	Consistência de quantis e cruzamento de intervalos.....	54
4.7.4	Calibração pós-processamento com fator de escala	54
4.8	Estratificação por regimes de radiação	55
4.8.1	Motivação.....	55
4.8.2	Definição dos regimes	55
4.8.3	Treinamento por regime	56
4.9	Métricas de avaliação.....	56

4.9.1	Métricas determinísticas.....	57
4.9.2	Métricas probabilísticas (intervalos de predição)	57
4.9.3	Avaliação por regime.....	57
4.10	Procedimento final do experimento	57
4.10.1	Considerações sobre particionamento e vazamento	58
4.11	Resumo do capítulo	58
5	RESULTADOS E DISCUSSÕES	60
5.1	Visão geral dos experimentos e organização dos resultados	60
5.2	Configuração final e critérios de comparação	60
5.2.1	Modelos avaliados.....	60
5.2.2	Métricas reportadas	61
5.2.3	Níveis de confiança e regimes	61
5.3	Resultados determinísticos (previsão pontual)	61
5.3.1	Desempenho global no conjunto de teste	61
5.3.2	Análise por regimes: onde o erro realmente se concentra	62
5.3.3	Inspeção visual: exemplos de séries temporais	63
5.3.4	Diagnóstico do erro horário em um dia representativo.....	64
5.4	Resultados probabilísticos: calibração e nitidez	64
5.4.1	Cobertura (PICP) e largura (PINAW) no conjunto de teste.....	64
5.4.2	Análise por regimes: calibração localizada	66
5.4.3	Visualização de intervalos: exemplos interpretáveis.....	67
5.5	Discussão: implicações, limitações e comparação com a literatura.....	68
5.5.1	O que os resultados indicam, de forma objetiva.....	68
5.5.2	Limitações e possíveis fontes de viés	68
5.5.3	Aplicação operacional (D+1): ponto + intervalo calibrado + checagem de domínio	69
5.5.4	Comparação com uma baseline de média histórica.....	70
5.5.5	Síntese do trade-off calibração–nitidez	70
5.6	Resumo do capítulo	71
5.6.1	Análise visual de dispersão	71
5.6.2	Distribuição de erros por regime	71
5.6.2.1	Análise crítica do viés no regime de alta radiação.....	72
6	CONCLUSÕES	73
6.1	Síntese do problema e da abordagem	73
6.2	Principais contribuições.....	73
6.3	Conclusões a partir dos resultados	74
6.3.1	Desempenho determinístico	74
6.3.2	Desempenho probabilístico	74
6.3.3	Síntese do trade-off entre calibração e nitidez.....	75

6.4	Limitações	75
6.5	Trabalhos futuros	76
6.6	Produções acadêmicas e materiais gerados	77
6.7	Considerações finais	77
	REFERÊNCIAS	79

1 INTRODUÇÃO

1.1 Contextualização e motivação

A energia solar fotovoltaica consolidou-se como uma das principais fontes do parque gerador brasileiro. Em março de 2025, a potência instalada operacional da fonte superou 55 GW, e sua participação foi reportada em torno de 22% da capacidade instalada nacional, segundo balanço setorial divulgado pela ABSOLAR (2025), reproduzido por veículos de imprensa e mídia especializada (MÁXIMO, 2025; CASARIN, 2025). No cenário internacional, levantamentos setoriais baseados em dados consolidados indicam o Brasil entre os países com maior capacidade acumulada de energia solar fotovoltaica, figurando no grupo de liderança global. Esse crescimento acelerado reflete, sobretudo, a redução de custos de módulos e a expansão da geração distribuída. No entanto, essa expansão traz consigo um desafio operacional importante: a geração fotovoltaica depende diretamente da irradiância solar, que varia ao longo do dia e sofre influência de nuvens, aerossóis e outros fenômenos atmosféricos.

Na prática, isso significa que a potência entregue por uma usina solar pode oscilar bruscamente em questão de minutos. Para os operadores do sistema elétrico, essa variabilidade exige ferramentas de previsão capazes de antecipar o comportamento da geração com algumas horas de antecedência. Previsões confiáveis permitem programar adequadamente os recursos de reserva, evitar cortes desnecessários e, em última instância, viabilizar a integração de volumes cada vez maiores de energia renovável na rede. Uma revisão recente sobre o tema mostra que métodos baseados em aprendizado de máquina têm alcançado resultados promissores nesse contexto (GABOITAOLELWE et al., 2023).

Embora existam estudos que aplicam ciência de dados e aprendizado de máquina a problemas solares na região amazônica, esses trabalhos frequentemente adotam recortes distintos do escopo desta dissertação, como variáveis-alvo relacionadas à irradiação/irradiância, agregações em escala diária e horizontes de previsão mais longos. Em contraste, são menos frequentes estudos que, em base horária e no contexto operacional de uma planta fotovoltaica, integrem (i) previsão pontual competitiva e (ii) previsão probabilística com intervalos calibrados, de modo a fornecer faixas de previsão simultaneamente informativas e confiáveis sob alta variabilidade atmosférica. Além disso, a literatura reporta com menor frequência abordagens que combinem regressão quantílica, estratificação por regimes de radiação e calibração dos intervalos em clima tropical úmido. Assim, este trabalho propõe e avalia uma abordagem híbrida de previsão, que combina modelagem determinística (previsão pontual) e modelagem probabilística por quantis, incluindo calibração dos intervalos e análise do desempenho por regimes de radiação, em um estudo de caso na Amazônia brasileira (MARQUES et al., 2023; MARQUES et al., 2024; LAURET; DAVID; PEDRO, 2017b; ZHANG et al., 2023).

A qualidade dessas previsões probabilísticas é avaliada por dois critérios complementares:

calibração e nitidez. Um intervalo bem calibrado contém a observação real na frequência esperada. Por exemplo, se um intervalo de 90% é fornecido, espera-se que a geração real esteja nessa faixa em aproximadamente 90% dos casos. Já a nitidez mede o quão estreito é o intervalo; quanto mais concentrado, maior sua utilidade para a tomada de decisão. O objetivo é obter intervalos tão nítidos quanto possível, sem perda de calibração. Esse princípio, consolidado por Gneiting, Balabdaoui e Raftery (2007), orienta boa parte da literatura atual sobre previsão probabilística.

A literatura de previsão de geração fotovoltaica classifica, de forma recorrente, as metodologias em quatro grandes grupos: modelos físicos, modelos estatísticos/séries temporais, modelos orientados por dados (aprendizado de máquina e aprendizado profundo) e modelos híbridos (ANTONANZAS et al., 2016; INMAN; PEDRO; COIMBRA, 2013; SOBRI; KOOHI-KAMALI; RAHIM, 2018; YANG et al., 2023; IHEANETU, 2022). Em geral, a escolha entre essas abordagens depende do horizonte de previsão, da disponibilidade e qualidade dos dados, da escala temporal e espacial de interesse e do contexto de aplicação (operação, despacho, planejamento e gestão energética) (SOBRI; KOOHI-KAMALI; RAHIM, 2018; YANG et al., 2023). Revisões recentes continuam utilizando essa taxonomia e destacam que a comparação entre métodos deve considerar essas diferenças de contexto e de desenho experimental.

Os modelos físicos apresentam como vantagens a interpretabilidade e o vínculo com os mecanismos de conversão fotovoltaica e com variáveis meteorológicas; por outro lado, sua aplicação pode exigir informações detalhadas da planta (orientação, inclinação, sombreamento e parâmetros de módulos e inversores), além de dados meteorológicos confiáveis e maior esforço para representar efeitos não lineares e mudanças rápidas de nebulosidade (SOBRI; KOOHI-KAMALI; RAHIM, 2018; YANG et al., 2023). Já os modelos estatísticos e de séries temporais (por exemplo, persistência, regressões e modelos autorregressivos) são amplamente utilizados como referência devido à simplicidade e ao baixo custo computacional, mas tendem a perder desempenho em cenários com forte não estacionariedade e transições meteorológicas abruptas (SOBRI; KOOHI-KAMALI; RAHIM, 2018; VOYANT et al., 2017).

Por sua vez, os modelos orientados por dados, incluindo técnicas de aprendizado de máquina e aprendizado profundo, têm apresentado ganhos relevantes de acurácia ao capturar relações não lineares e integrar múltiplas fontes de informação (histórico de potência, variáveis meteorológicas e, em alguns casos, dados espaciais e imagens) (GABOITAOLELWE et al., 2023; IHEANETU, 2022; YU et al., 2024; HUSEIN et al., 2024). Entretanto, a literatura também aponta limitações recorrentes, como maior demanda por dados históricos, sensibilidade à escolha de hiperparâmetros, custo computacional elevado, risco de sobreajuste e menor interpretabilidade em arquiteturas mais complexas (MAULADDAWILAH et al., 2024; YU et al., 2024; HUSEIN et al., 2024). Os modelos híbridos, por sua vez, buscam combinar vantagens de abordagens distintas para aumentar robustez e desempenho em diferentes condições operacionais, mas frequentemente elevam a complexidade de modelagem, o esforço de calibração e a dependência de decisões de projeto, como seleção de variáveis, estratégia de fusão e pós-processamento

(SOBRI; KOOHI-KAMALI; RAHIM, 2018; YANG et al., 2023; NGUYEN-DUC et al., 2023).

Além das limitações intrínsecas a cada classe de método, revisões recentes destacam dificuldades transversais na comparação entre estudos, como diferenças de horizonte de previsão, bases de dados, métricas e protocolos de avaliação, além do uso de bases privadas e ausência de *benchmarks* unificados (GANDHI et al., 2024; HUSEIN et al., 2024; YU et al., 2024). No contexto desta dissertação, essas limitações tornam-se ainda mais relevantes, pois a elevada variabilidade atmosférica do clima tropical úmido impõe heterogeneidade entre regimes de irradiância, exigindo modelos capazes de representar explicitamente a incerteza associada às previsões.

1.2 O desafio do clima tropical úmido

Grande parte dos estudos sobre previsão fotovoltaica foi desenvolvida em regiões de clima temperado ou semiárido, onde a variabilidade da irradiância segue padrões relativamente previsíveis. O clima tropical úmido, característico da Amazônia brasileira, apresenta uma dinâmica distinta. A elevada umidade, a formação frequente de nuvens convectivas e as transições rápidas entre céu claro e encoberto tornam a irradiância mais difícil de prever.

Tucuruí, no sudeste do Pará, exemplifica esse cenário. Localizada às margens do rio Tocantins e sede de uma das maiores hidrelétricas do mundo, a cidade apresenta clima equatorial (tipo Am na classificação de Köppen), com temperatura média anual em torno de 26°C, umidade relativa frequentemente acima de 80% e precipitação anual superior a 2.000 mm. Durante a estação chuvosa, de dezembro a maio, a cobertura de nuvens convectivas se intensifica, especialmente no período da tarde. Mesmo em dias aparentemente ensolarados, eventos convectivos localizados podem provocar quedas abruptas na geração, que modelos treinados com dados de outras regiões podem não antecipar adequadamente.

Essa variabilidade irregular produz um fenômeno estatístico conhecido como heterocedasticidade: a dispersão do erro de previsão não é constante ao longo do tempo. Em condições de céu muito nublado, a geração tende a ser baixa e relativamente estável. Em condições de céu parcialmente nublado, a variabilidade aumenta de forma acentuada, e a passagem de uma única nuvem pode reduzir a geração pela metade em poucos minutos. Em dias de céu limpo, a geração tende a ser alta e previsível, exceto em eventos convectivos localizados. Estudos realizados em Singapura, outro ambiente tropical, confirmam a dificuldade adicional de prever irradiância nessas condições (VERBOIS; RUSYDI; THIERY, 2018).

Diante dessa heterogeneidade, surge a seguinte questão metodológica: um modelo global, treinado com a base horária de variáveis meteorológicas e geração fotovoltaica utilizada neste estudo, consegue representar adequadamente a incerteza em cada regime de radiação? Alternativamente, modelos específicos para diferentes condições de irradiância, com ajuste dos intervalos de predição conforme o regime, podem oferecer melhor desempenho. Para responder

a essa questão, esta dissertação desenvolve e avalia uma metodologia de previsão probabilística horária baseada em regressão quantílica com LightGBM, estratificação por regimes de radiação e calibração dos intervalos.

1.3 Problema de pesquisa

Embora existam estudos que aplicam ciência de dados e aprendizado de máquina a problemas solares na região amazônica, esses trabalhos frequentemente adotam recortes distintos do escopo desta dissertação, como variáveis-alvo relacionadas à irradiação/irradiância, agregações em escala diária e horizontes de previsão mais longos. Em contraste, são menos frequentes estudos que, em base horária e no contexto operacional de uma planta fotovoltaica, integrem de forma explícita (i) previsão pontual competitiva e (ii) previsão probabilística com intervalos calibrados, de modo a fornecer faixas de previsão simultaneamente informativas e confiáveis sob alta variabilidade atmosférica. Além disso, a literatura reporta com menor frequência abordagens que combinem regressão quantílica, estratificação por regimes de radiação e calibração dos intervalos em clima tropical úmido. Assim, este trabalho propõe e avalia uma abordagem híbrida de previsão, que combina modelagem determinística (previsão pontual) e modelagem probabilística por quantis, incluindo calibração dos intervalos e análise do desempenho por regimes de radiação, em um estudo de caso na Amazônia brasileira (MARQUES et al., 2023; MARQUES et al., 2024; LAURET; DAVID; PEDRO, 2017b; ZHANG et al., 2023).

A pergunta que orienta esta dissertação é:

Como construir previsões probabilísticas horárias de geração fotovoltaica em clima tropical úmido que sejam simultaneamente bem calibradas e informativas, adaptando a estimativa de incerteza aos diferentes regimes de radiação?

1.4 Hipóteses e premissas

Este trabalho parte das seguintes premissas e formula uma hipótese central:

- **Premissa 1:** A incerteza da geração fotovoltaica em clima tropical úmido varia conforme o regime de radiação. Em condições de céu parcialmente nublado, a variabilidade é maior do que em condições de céu limpo ou totalmente encoberto.
- **Premissa 2:** A regressão quantílica é uma técnica adequada para capturar essa heterogeneidade, pois estima diretamente os quantis condicionais da distribuição, sem impor hipóteses paramétricas sobre sua forma (KOENKER, 2005).

- **Hipótese:** A segmentação do problema em regimes de radiação (baixa, intermediária e alta) permite obter intervalos de predição mais calibrados e mais nítidos do que uma abordagem global, especialmente no regime intermediário, onde a variabilidade é maior.
- **Premissa 3:** As métricas PICP (*Prediction Interval Coverage Probability*) e PINAW (*Prediction Interval Normalized Average Width*) são adequadas para avaliar, respectivamente, a calibração e a nitidez dos intervalos de predição (KHOSRAVI et al., 2011).

1.5 Objetivos

1.5.1 Objetivo geral

Desenvolver e avaliar uma metodologia de previsão probabilística horária da geração fotovoltaica em clima tropical úmido, baseada em regressão quantílica com LightGBM, que adapte a estimativa de incerteza aos diferentes regimes de radiação.

1.5.2 Objetivos específicos

1. Construir uma base de dados integrando variáveis meteorológicas e estimativas de geração fotovoltaica para a região de Tucuruí-PA.
2. Implementar o pré-processamento dos dados, incluindo filtragem do período diurno, tratamento de valores ausentes, análise de multicolinearidade e normalização.
3. Desenvolver modelos determinísticos de referência (persistência e LightGBM pontual) para estabelecer linhas de base.
4. Construir modelos probabilísticos via regressão quantílica com LightGBM, estimando quantis condicionais para diferentes níveis de confiança.
5. Implementar e avaliar a estratificação por regimes de radiação como forma de capturar a heterocedasticidade.
6. Comparar o desempenho dos modelos por meio de métricas determinísticas (MAE, RMSE) e probabilísticas (PICP, PINAW).

1.6 Contribuições

As principais contribuições desta dissertação são:

- Proposição de um sistema híbrido para previsão de geração fotovoltaica em base horária, combinando um modelo determinístico para previsão pontual e um modelo probabilístico por quantis para construção de intervalos de previsão.

- Implementação de uma etapa explícita de calibração dos intervalos, buscando melhorar a confiabilidade (cobertura) sem ampliar excessivamente a largura dos intervalos.
- Avaliação abrangente do desempenho determinístico e probabilístico, incluindo análise estratificada por regimes de radiação para evidenciar variações sistemáticas de erro e incerteza.
- Estudo de caso em clima amazônico, com discussão orientada a implicações operacionais e limitações de generalização.

1.7 Organização do trabalho

Além desta introdução, a dissertação está organizada em mais cinco capítulos. O Capítulo 2 apresenta a fundamentação teórica, revisando conceitos de previsão fotovoltaica, previsão probabilística, regressão quantílica e modelos de gradient boosting. O Capítulo 3 descreve os dados utilizados e as etapas de pré-processamento. O Capítulo 4 detalha a metodologia proposta, incluindo a definição dos regimes e a construção dos intervalos de predição. O Capítulo 5 apresenta os resultados e discussões. Por fim, o Capítulo 6 traz as conclusões e sugestões para trabalhos futuros.

Ao longo dos capítulos, procura-se evidenciar que a combinação entre regressão quantílica com LightGBM, estratificação por regimes de radiação e calibração pós-processamento constitui um arcabouço metodológico adequado para representar a incerteza da geração fotovoltaica em clima tropical úmido, contribuindo para avançar a discussão sobre representação de incerteza em previsão fotovoltaica sob clima tropical úmido e para mitigar uma lacuna identificada na literatura.

2 FUNDAMENTAÇÃO TEÓRICA E TRABALHOS RELACIONADOS

Este capítulo apresenta os conceitos que fundamentam a metodologia proposta. São discutidos os desafios da previsão fotovoltaica, os principais grupos de métodos e as técnicas probabilísticas utilizadas para quantificar a incerteza das previsões.

2.1 Desafios da previsão de geração fotovoltaica

A previsão de geração fotovoltaica em horizontes de curto prazo depende, principalmente, da irradiância solar incidente, mas não apenas dela. A resposta em potência também é influenciada por temperatura dos módulos, características dos equipamentos, perdas elétricas, sombreamento, sujeidade, degradação e condições operacionais do sistema. Além disso, a própria irradiância é afetada por processos atmosféricos de rápida variação, como passagem de nuvens, aerossóis e vapor d'água. Em consequência, reduções expressivas de geração podem ocorrer em poucos minutos.

Essa variabilidade impõe desafios operacionais ao sistema elétrico. A superestimação da geração fotovoltaica pode resultar em insuficiência de energia disponível em tempo real, exigindo compensação por outras fontes. A subestimação, por sua vez, pode levar a despacho conservador e uso ineficiente de recursos. Portanto, a qualidade das previsões afeta diretamente os custos de operação e a confiabilidade do suprimento. A revisão de Gaboitaolelwe et al. (2023) destaca que métodos de aprendizado de máquina têm apresentado bom desempenho nessa tarefa, especialmente quando combinados com engenharia de atributos adequada.

A dificuldade da previsão solar depende fortemente do regime atmosférico local. Em regiões com predominância de céu limpo, a irradiância tende a apresentar comportamento diurno mais regular, o que favorece previsões com menor erro. Em contrapartida, em ambientes tropicais e subtropicais sujeitos à convecção frequente, a rápida formação, evolução e dissipação de nuvens intensifica a variabilidade da irradiância e reduz a previsibilidade. Como evidência, Roy et al. analisaram previsões intradiárias baseadas em vetores de movimento de nuvens (CMV) em regiões influenciadas pelas monções do sul da Ásia e observaram piora da acurácia associada ao aumento da atividade convectiva, com variação sazonal relevante do erro entre diferentes locais e períodos (ROY et al., 2022).

2.2 O contexto amazônico: evidências dos dados de Tucuruí

A Amazônia brasileira recebe níveis de irradiação comparáveis aos de outras regiões tropicais, tipicamente entre 4,5 e 5,5 kWh/m² por dia, em média. O principal desafio, nesse contexto, não é a quantidade total de recurso solar, mas a sua distribuição intradiária. Durante a

estação chuvosa (dezembro a maio), a atividade convectiva se intensifica no período da tarde (aproximadamente entre 12h e 18h, em hora local), intervalo em que a geração solar tende a atingir valores elevados.

Uma análise dos dados de reanálise Open-Meteo para Tucuuruí, cobrindo o período de 2018 a 2023 (2.191 dias com dados completos), evidencia esse comportamento. Para caracterizar a variabilidade intradiária, calculou-se o coeficiente de variação (CV) da irradiância global horizontal (GHI) por dia, com $CV = \sigma/\mu$, considerando apenas registros no período diurno (GHI > 0), de modo a evitar distorções associadas aos valores nulos do período noturno. Adotando-se os limiares $CV < 0,5$ (baixa variabilidade), $0,5 \leq CV < 0,8$ (variabilidade moderada) e $CV \geq 0,8$ (alta variabilidade), observou-se que **apenas 2 dias (0,1%) apresentaram baixa variabilidade**. A maior parte da amostra, **95,8% dos dias**, apresentou variabilidade moderada, enquanto 4,1% dos dias tiveram alta variabilidade. Esse resultado indica que, em Tucuuruí, dias com comportamento próximo ao de céu limpo estável são raros no conjunto analisado.

A Figura 1 ilustra essa realidade com três dias selecionados como exemplos representativos dos padrões observados nos dados (e não necessariamente como casos extremos em todas as métricas). No dia com maior irradiância registrada (28/10/2023), a GHI atingiu 960 W/m² e seguiu aproximadamente o perfil teórico, com CV de 0,53, valor ainda acima do limiar adotado para baixa variabilidade. No dia classificado como de alta variabilidade (18/01/2023), observam-se oscilações bruscas, com a irradiância variando de menos de 100 W/m² para mais de 750 W/m² em poucas horas, resultando em CV de 0,99. No dia nublado (30/11/2018), a irradiância permaneceu baixa ao longo do dia, com máxima de 164 W/m².




Figura 1 – Perfis de GHI em Tucuuruí-PA para três condições representativas: (a) dia de alta irradiância, (b) dia de alta variabilidade e (c) dia nublado.

Esses dados reforçam a necessidade de abordagens que vão além da previsão pontual. Se praticamente todos os dias apresentam variabilidade significativa, um modelo que forneça apenas um valor central estará sistematicamente subestimando a incerteza real. Isso motiva o uso de previsões probabilísticas e a estratificação por regimes de irradiância.

A escassez de estudos de previsão de energia fotovoltaica especificamente voltados para a Amazônia contrasta com a crescente capacidade instalada na região Norte do Brasil (LIMA et

al., 2024; WEYLL et al., 2024). Essa lacuna é uma das motivações centrais desta dissertação.

2.3 Classificação dos métodos de previsão

A literatura costuma organizar os métodos de previsão fotovoltaica em três grandes grupos, conforme a natureza da modelagem: métodos físicos, métodos estatísticos e métodos baseados em aprendizado de máquina. A Figura 2 apresenta essa taxonomia, destacando as principais técnicas em cada categoria. Cada grupo tem seus pontos fortes e limitações (GABOI-TAOLELWE et al., 2023; MAULADDAWILAH et al., 2024).




Figura 2 – Taxonomia dos principais métodos de previsão fotovoltaica.

2.3.1 Métodos físicos

Os métodos físicos modelam a cadeia de conversão entre condições atmosféricas e potência gerada. Tipicamente, partem de previsões meteorológicas numéricas (NWP, *Numerical Weather Prediction*) e aplicam um modelo de conversão de irradiância em potência elétrica, considerando temperatura do módulo, perdas do sistema e eficiência do inversor.

A principal vantagem é a interpretabilidade: quando a previsão falha, é possível investigar se a origem do erro está na previsão meteorológica ou no modelo de conversão. A desvantagem é que erros na entrada meteorológica se propagam diretamente para a saída. Se o modelo numérico errar, por exemplo, a posição de uma frente de nuvens, a previsibilidade do sistema fica limitada pela qualidade dessa entrada. Trabalhos recentes mostram que o pós-processamento estatístico das saídas de NWP pode melhorar significativamente a calibração das previsões (MAYER; YANG, 2023).

2.3.2 Métodos estatísticos

Métodos estatísticos partem de uma premissa diferente: a própria série histórica de geração carrega informação suficiente para projetar o futuro próximo. Modelos como ARIMA exploram autocorrelações e padrões sazonais sem precisar de dados meteorológicos externos.

Em condições estáveis, esses modelos funcionam bem e são simples de implementar. O problema aparece quando o tempo muda rapidamente. Se uma nuvem aparece de repente, o padrão recente deixa de ser representativo e o modelo erra. Por isso, métodos puramente estatísticos costumam servir mais como linha de base do que como solução definitiva.

2.3.3 Métodos baseados em aprendizado de máquina

A classe que mais cresceu nos últimos anos é a de aprendizado de máquina. Algoritmos como *Random Forest*, XGBoost e LightGBM conseguem capturar relações não lineares entre múltiplas variáveis de entrada sem que o analista precise especificar a forma funcional dessas relações.

Uma revisão sistemática recente analisou 36 estudos publicados entre 2022 e 2023 e encontrou que modelos baseados em redes neurais recorrentes (LSTM, GRU) e em *gradient boosting* figuram consistentemente entre os melhores (MAULADDAWILAH et al., 2024). A escolha entre um e outro depende do contexto: redes neurais profundas tendem a brilhar quando há muito dado e interesse em capturar dependências temporais longas; modelos de *boosting* são mais rápidos de treinar e funcionam bem com dados tabulares típicos de estações meteorológicas.

Gaboitaolelwe et al. (2023) compararam diversos algoritmos de aprendizado de máquina para previsão FV e concluíram que modelos de *ensemble* baseados em árvores frequentemente superam redes neurais em termos de relação entre acurácia e custo computacional. Essa característica é particularmente relevante para aplicações operacionais, onde previsões precisam ser atualizadas com frequência.

2.4 Modelos de *Gradient Boosting*

Como esta dissertação utiliza o LightGBM como modelo base, é importante apresentar os princípios de funcionamento do *gradient boosting*, abordagem sobre a qual esse modelo é construído. Essa técnica de *ensemble* constrói um preditor mais robusto por meio da combinação sequencial de preditores fracos, geralmente árvores de decisão rasas.

A ideia é simples: treina-se uma primeira árvore, calcula-se o erro (resíduo), treina-se uma segunda árvore para prever esse erro, e assim por diante. O preditor final é a soma de todas as contribuições, conforme ilustra a Figura 3. Matematicamente, dado um conjunto de treinamento $\{(\mathbf{x}_i, y_i)\}_{i=1}^N$, o modelo na iteração m é:

$$F_m(\mathbf{x}) = F_{m-1}(\mathbf{x}) + \gamma_m h_m(\mathbf{x}), \quad (2.1)$$

onde h_m é a árvore ajustada aos resíduos e γ_m é a taxa de aprendizado (FRIEDMAN, 2001).




Figura 3 – Esquema do processo de *gradient boosting*.

O XGBoost popularizou essa abordagem ao introduzir otimizações computacionais e termos de regularização que controlam o *overfitting* (CHEN; GUESTRIN, 2016). O LightGBM foi um passo além, introduzindo o crescimento de árvores por folha (*leaf-wise*) em vez de por nível, o que acelera o treinamento sem sacrificar qualidade (KE et al., 2017).

Entre os métodos baseados em *gradient boosting*, o XGBoost (*Extreme Gradient Boosting*) tornou-se uma das abordagens mais difundidas em problemas de regressão e classificação devido ao seu bom desempenho preditivo e à robustez em diferentes tipos de dados. O algoritmo combina árvores de decisão em sequência, com regularização explícita e estratégias de otimização que contribuem para reduzir sobreajuste e melhorar a generalização. Em aplicações de previsão solar, o XGBoost tem sido amplamente utilizado como referência de alto desempenho em comparação com modelos estatísticos tradicionais e outros algoritmos de aprendizado de máquina (AKSOY; TOLUN, 2023).

O LightGBM (*Light Gradient Boosting Machine*), por sua vez, foi desenvolvido com foco em eficiência computacional e escalabilidade. Entre seus diferenciais estão o uso de histogramas para discretização contínua das variáveis e estratégias de crescimento de árvores que reduzem o custo computacional, tornando o treinamento mais rápido em bases de dados maiores. Essas características tornam o LightGBM particularmente atrativo em estudos comparativos e em aplicações que demandam múltiplos treinamentos e ajustes de hiperparâmetros, como ocorre em experimentos de previsão probabilística (AKSOY; TOLUN, 2023).

O CatBoost (*Categorical Boosting*) também pertence à família dos métodos de *gradient boosting* e se destaca, sobretudo, pelo tratamento eficiente de variáveis categóricas e por mecanismos que mitigam viés de predição durante o treinamento. Embora esse diferencial seja especialmente relevante em problemas com dados tabulares mistos, o CatBoost também tem apresentado desempenho competitivo em tarefas de regressão contínua, incluindo aplicações em energia, sendo frequentemente incluído em estudos comparativos junto com XGBoost e LightGBM (AKSOY; TOLUN, 2023).

No contexto desta dissertação, o LightGBM é adotado como modelo base por combinar bom desempenho preditivo e eficiência computacional. Um aspecto particularmente relevante

é a possibilidade de treinamento direto para regressão quantílica, por meio da minimização da perda *pinball* para cada quantil de interesse. Essa estratégia permite estimar quantis condicionais de forma direta e, conseqüentemente, construir intervalos de predição sem necessidade de etapas adicionais de pós-processamento.

2.5 Previsão determinística versus probabilística

A maioria dos modelos de previsão fornece um único número: “na próxima hora, a usina vai gerar 4,5 kWh”. Essa é uma previsão determinística (ou pontual). Apesar de sua utilidade, essa representação é insuficiente para caracterizar a incerteza preditiva, pois não indica a amplitude possível de erro em torno da estimativa pontual.

Uma previsão probabilística vai além. Em vez de um único valor, ela fornece uma distribuição de possibilidades ou, de forma mais prática, um intervalo de predição: “na próxima hora, a usina vai gerar entre 3,8 e 5,2 kWh, com 90% de confiança”. A Figura 4 ilustra a diferença entre as duas abordagens.




Figura 4 – Comparação entre previsão determinística e probabilística: (a) a previsão determinística fornece apenas um valor pontual, sem informação sobre a incerteza; (b) a previsão probabilística inclui um intervalo que quantifica a incerteza esperada.

Formalmente, considere variáveis explicativas $\mathbf{x}_t \in \mathbb{R}^d$ e uma variável resposta y_t representando a geração FV. Uma previsão determinística pode ser expressa como $\hat{y}_{t+h} = f(\mathbf{x}_t)$, onde $f(\cdot)$ minimiza uma perda como o erro quadrático médio. Já uma previsão probabilística busca representar a distribuição condicional $p(y | \mathbf{x})$, ou estatísticas derivadas como quantis e intervalos (GNEITING; KATZFUSS, 2014).

2.5.1 Calibração e nitidez

Gneiting, Balabdaoui e Raftery (2007) estabeleceram dois critérios fundamentais para avaliar previsões probabilísticas:

- **Calibração:** o intervalo deve conter a observação real na frequência esperada. Se dizemos “90% de confiança”, então em 90% das vezes a observação deve cair dentro do intervalo.
- **Nitidez (*sharpness*):** o intervalo deve ser o mais estreito possível, sem comprometer a cobertura. Intervalos excessivamente largos são pouco informativos para a tomada de decisão.

O princípio central é: *maximize a nitidez sujeito à calibração*. Um intervalo estreito que sistematicamente falha em cobrir as observações é inútil. Um intervalo largo que sempre acerta também não ajuda muito. O bom modelo encontra o equilíbrio.

Esse modelo é particularmente relevante para previsão solar, em que a incerteza varia substancialmente entre diferentes regimes de irradiância. Trabalhos recentes e clássicos da literatura de previsão probabilística solar reforçam a importância de critérios de avaliação adequados, incluindo regras de pontuação próprias (*proper scoring rules*), análise de calibração e comparação com modelos de referência (*benchmarks*) (GNEITING; LERCH; SCHULZ, 2023; LAURET; DAVID; PINSON, 2019; DOUBLEDAY; SCYOC-HERNANDEZ; HODGE, 2020; SALLE; DAVID; LAURET, 2021).

2.5.2 Intervalos de predição

Seja $\alpha \in (0, 1)$ o nível nominal de não cobertura (*miscoverage*), de modo que $(1 - \alpha)$ represente o nível nominal de cobertura do intervalo de predição. Em termos práticos, α indica a fração de observações que, idealmente, pode ficar fora do intervalo em dados fora da amostra. Por exemplo, $\alpha = 0.10$ corresponde a um intervalo com cobertura nominal de 90%, enquanto $\alpha = 0.20$ corresponde a uma cobertura nominal de 80%.

Para um nível nominal $(1 - \alpha)$, um intervalo de predição pode ser escrito como:

$$\hat{I}_{1-\alpha}(\mathbf{x}) = [y^L(\mathbf{x}), y^U(\mathbf{x})], \quad (2.2)$$

onde $y^L(\mathbf{x})$ e $y^U(\mathbf{x})$ representam, respectivamente, os limites inferior e superior do intervalo para a entrada $\mathbf{x}$.

O objetivo de um intervalo de predição de boa qualidade é atender simultaneamente a dois critérios. O primeiro é a **calibração**, isto é, a proporção de observações efetivamente contidas no intervalo, em novas amostras, deve ser próxima de $(1 - \alpha)$. O segundo é a **nitidez** (*sharpness*), que se refere à largura do intervalo: entre dois modelos com calibração semelhante, prefere-se aquele que produz intervalos mais estreitos, por fornecer informação mais precisa.

No caso de intervalos centrais construídos por regressão quantílica, é comum estimar os quantis $\alpha/2$ e $1 - \alpha/2$ como limites inferior e superior, respectivamente. Assim, para um intervalo nominal de 90% ($\alpha = 0.10$), podem ser utilizados, por exemplo, os quantis 0.05 e 0.95.

Revisões sobre intervalos de predição em sistemas de energia enfatizam que a construção de intervalos de qualidade é um problema não trivial, especialmente quando a distribuição dos erros é assimétrica ou heterocedástica, situação frequente em aplicações reais de previsão (KHOSRAVI et al., 2011; MEER; WIDÉN; MUNKHAMMAR, 2018).

2.6 Métricas de avaliação probabilística

A qualidade de intervalos de predição é usualmente avaliada por critérios complementares de cobertura e largura. Duas métricas amplamente utilizadas na literatura, e adotadas nesta dissertação, são apresentadas a seguir.

2.6.1 Cobertura empírica (PICP)

A *Prediction Interval Coverage Probability* (PICP) mede a proporção de observações que caem dentro do intervalo:

$$\text{PICP} = \frac{1}{N} \sum_{i=1}^N \mathbf{I}_{y_i^L \leq y_i \leq y_i^U}, \quad (2.3)$$

onde $\mathbf{I}(\cdot)$ é a função indicadora (vale 1 se a condição é verdadeira, 0 caso contrário).

Se o intervalo nominal é de 90%, esperamos PICP próximo de 0,90. Valores muito abaixo indicam subcalibração (intervalos estreitos demais); valores muito acima indicam supercalibração (intervalos largos demais).

2.6.2 Largura normalizada (PINAW)

A *Prediction Interval Normalized Average Width* (PINAW) mede a largura média dos intervalos de predição, normalizada pela amplitude da variável resposta no conjunto de avaliação:

$$\text{PINAW} = \frac{1}{N} \sum_{i=1}^N \frac{y_i^U - y_i^L}{y_{\max} - y_{\min}}, \quad (2.4)$$

em que y_i^U e y_i^L são, respectivamente, os limites superior e inferior do intervalo de predição para a i -ésima amostra, N é o número de amostras avaliadas, e $y_{\max}$ e $y_{\min}$ representam, respectivamente, os valores máximo e mínimo observados da variável resposta no conjunto de avaliação.

A normalização pela amplitude ($y_{\max} - y_{\min}$) permite comparar a largura média dos intervalos entre modelos e, em certa medida, entre conjuntos de dados com escalas distintas. Quanto menor o PINAW, maior a nitidez (*sharpness*) dos intervalos, desde que a calibração também seja adequada (KHOSRAVI et al., 2011).

2.6.3 O dilema calibração-nitidez

PICP e PINAW são métricas complementares que revelam um dilema fundamental, ilustrado na Figura 5. Intervalos muito largos garantem alta cobertura (PICP elevado), mas são pouco informativos (PINAW alto). Intervalos muito estreitos são mais úteis quando acertam (PINAW baixo), mas falham com frequência (PICP baixo).




Figura 5 – Ilustração conceitual das métricas PICP (cobertura) e PINAW (largura normalizada).

Em previsão fotovoltaica, esse dilema se agrava porque a variabilidade do erro muda conforme as condições atmosféricas. Um modelo global com intervalos de largura fixa tenderá a errar nos dois sentidos: intervalos estreitos demais em condições de alta variabilidade e intervalos largos demais em condições mais estáveis. No contexto de Tucuruí, a predominância de dias nas faixas de variabilidade moderada e alta apresentada na Seção 2.2 (Figura 1 e Tabela 1) reforça a necessidade de estratificação por regimes.

De forma geral, para um intervalo central com cobertura nominal $(1 - \alpha)$, estimam-se os quantis $\alpha/2$ e $1 - \alpha/2$, de modo que

$$\hat{I}_{1-\alpha}(\mathbf{x}) = \hat{Q}_{\alpha/2}(y | \mathbf{x}), \hat{Q}_{1-\alpha/2}(y | \mathbf{x}) . \quad (2.5)$$

2.6.4 A perda *pinball*

Para treinar um modelo quantílico, utiliza-se a perda *pinball* (também chamada *check function*), em que $\tau \in (0, 1)$ representa o nível do quantil de interesse (por exemplo, $\tau = 0,10$, $\tau = 0,50$ ou $\tau = 0,90$):

$$\rho_{\tau}(u) = \begin{cases} \tau \cdot u, & \text{se } u \geq 0, \\ (\tau - 1) \cdot u, & \text{se } u < 0, \end{cases} \quad \text{com } u = y - \hat{y}. \quad (2.6)$$

Nessa definição, u é o resíduo da previsão quantílica. Quando $u > 0$, o valor observado é maior que a predição ($y > \hat{y}$), caracterizando subestimação; quando $u < 0$, a predição fica acima do observado ($y < \hat{y}$), caracterizando superestimação.

Essa função é assimétrica, conforme ilustra a Figura 6. Para $\tau = 0,90$, erros positivos ($u > 0$), isto é, casos em que a previsão fica abaixo do observado, são penalizados mais fortemente do que erros negativos ($u < 0$). Isso desloca a solução para valores mais altos, de modo que aproximadamente 90% das observações fiquem abaixo do quantil estimado. Quando $\tau = 0,50$, a perda *pinball* coincide com a perda absoluta, e o estimador resultante corresponde à mediana condicional.




Figura 6 – Função de perda *pinball* para diferentes quantis.

A perda *pinball* média, calculada sobre múltiplos quantis, também pode ser utilizada como métrica de avaliação probabilística, sendo relacionada ao *Continuous Ranked Probability Score* (CRPS) quando se considera um conjunto denso de quantis (GNEITING, 2011).

2.6.5 Combinação com LightGBM

A grande vantagem prática da regressão quantílica é que ela pode ser combinada com qualquer algoritmo de aprendizado de máquina que aceite funções de perda customizadas. O LightGBM suporta nativamente a perda *pinball*, bastando configurar `objective='quantile'` e especificar o valor de α (equivalente a τ).

Trabalhos recentes confirmam a eficácia dessa combinação para previsão solar. Gandhi et al. (2024) discutem o valor econômico de previsões solares e os custos associados a diferentes tipos de erro, reforçando a importância de quantificar a incerteza. Modelos híbridos combinando redes neurais com regressão quantílica também têm mostrado resultados promissores (NGUYEN-DUC et al., 2023; MOULOUD et al., 2025).

2.7 Heterogeneidade da incerteza e regimes de irradiância

Um dos pontos centrais desta dissertação é que a incerteza não é constante ao longo do domínio de operação. Em condições de céu limpo, a geração tende a seguir o perfil teórico, com

níveis elevados e maior previsibilidade. Em condições de céu totalmente encoberto, a geração é baixa, mas pode permanecer relativamente estável. A maior dificuldade aparece nas condições intermediárias.

Quando o céu está parcialmente nublado, a passagem de nuvens pode causar oscilações bruscas. Nesse regime, a variabilidade é máxima e os modelos tendem a errar mais. A Figura 7 ilustra esse fenômeno usando os dados de Tucuruí: o desvio padrão do erro de previsão aumenta substancialmente do regime de baixa irradiância ($\sigma = 274$) para o regime de alta irradiância ($\sigma = 576$). Estudos sobre previsibilidade solar confirmam esse padrão (PEDRO; COIMBRA, 2012).




Figura 7 – Distribuição do erro de previsão por regime de irradiância nos dados de Tucuruí.

2.7.1 Evidências nos dados de Tucuruí

A análise dos dados Open-Meteo para Tucuruí (2018-2023) apresentada na Seção 2.2 fornece evidências concretas dessa heterogeneidade. A Tabela 1 resume as estatísticas por nível de variabilidade.

Tabela 1 – Distribuição dos dias por regime de variabilidade em Tucuruí-PA (2018-2023).

Classificação	N	%	CV médio	GHI média (W/m^2)
Baixa variabilidade ($CV < 0,5$)	2	0,1%	0,50	320
Variabilidade moderada ($0,5 \leq CV < 0,8$)	2.099	95,8%	0,68	405
Alta variabilidade ($CV \geq 0,8$)	90	4,1%	0,86	286
Total	2.191	100%	0,68	400

Fonte: Elaborado pelo autor a partir de dados Open-Meteo (2018-2023).

Para a classificação da variabilidade intradiária, o coeficiente de variação (CV) foi calculado diariamente como $CV = \sigma/\mu$, em que σ e μ são, respectivamente, o desvio-padrão e a média da irradiância global horizontal (GHI) no período analisado. Foram considerados apenas registros do período diurno (isto é, com $GHI > 0$), de modo a evitar distorções causadas pelos valores nulos do período noturno. A classificação em baixa, moderada e alta variabilidade foi então realizada com base nos limiares definidos nesta seção. Assim, a frequência observada em

cada classe depende diretamente dessa definição metodológica e do comportamento atmosférico local.

Mesmo considerando que a frequência por classe depende da metodologia de cálculo do CV e dos limiares adotados, o resultado indica predominância clara de variabilidade moderada a alta no conjunto analisado. Esse comportamento é consistente com a dinâmica atmosférica tropical úmida, em que a nebulosidade convectiva aumenta a variabilidade intradiária da irradiância.

2.7.2 Estratificação por regimes

Em séries solares, as condições atmosféricas não são homogêneas ao longo do tempo: há períodos de céu claro, dias com nebulosidade intermitente e situações de baixa disponibilidade de recurso solar. Como o erro e a incerteza tendem a mudar entre esses cenários, é útil avaliar o desempenho do modelo por regimes, em vez de resumir tudo em métricas globais.

A definição desses regimes pode seguir diferentes critérios, por exemplo:

- **Limiar de radiação:** divisão em tercís ou quartis da distribuição.
- **Índice de claridade (k_t):** razão entre o recurso solar observado e o estimado em condição de céu claro.
- **Variabilidade de curto prazo:** medidas como desvio padrão ou coeficiente de variação (CV) em janelas móveis.

Neste trabalho, adotou-se uma estratificação em três regimes (**baixa, intermediária e alta radiação**), definidos pelos **tercís** (Q33 e Q67) da distribuição da variável *Radiação (kJ/m^2)*, conforme descrita no Capítulo 3. Os limiares são calculados **exclusivamente no conjunto de treinamento**, de modo a evitar vazamento temporal.

Essa opção combina simplicidade e robustez: os tercís tendem a produzir subconjuntos com tamanhos semelhantes, o que favorece comparações estáveis entre regimes, e a definição no treino preserva a validade do protocolo experimental. Além disso, os limiares podem ser recalculados facilmente em novos períodos ou em outras localidades. Critérios alternativos, como o índice de claridade (k_t) ou o agrupamento não supervisionado, permanecem viáveis e são considerados como extensões naturais em trabalhos futuros.

2.7.3 Calibração por fator de escala

Mesmo com estratificação, os intervalos de predição podem apresentar desvios em relação à cobertura nominal. Uma técnica simples para corrigir isso é a calibração por fator de escala. A ideia é ajustar a largura dos intervalos proporcionalmente, alargando-os se a cobertura empírica estiver abaixo da cobertura nominal, ou estreitando-os se estiver acima.

Matematicamente, dado um fator λ :

$$y^{L,cal} = y^{0.5} - \lambda \cdot (y^{0.5} - y^L), \quad y^{U,cal} = y^{0.5} + \lambda \cdot (y^U - y^{0.5}), \quad (2.7)$$

onde $y^{0.5}$ é a mediana prevista. O fator λ é otimizado em um conjunto de validação para que a cobertura empírica dos intervalos calibrados se aproxime do nível nominal de cobertura $(1 - \alpha)$ previamente definido (por exemplo, 90% ou 80%, dependendo do intervalo de interesse).

2.8 Seleção de variáveis e multicolinearidade

Em previsão fotovoltaica, é comum dispor de muitas variáveis meteorológicas correlacionadas: irradiância global, direta e difusa; temperatura do ar e do módulo; umidade relativa e ponto de orvalho; velocidade e direção do vento. Incluir todas pode introduzir multicolinearidade e prejudicar a estabilidade do modelo.

O Fator de Inflação da Variância (VIF) é uma medida útil para identificar variáveis redundantes:

$$VIF_j = \frac{1}{1 - R_j^2}, \quad (2.8)$$

onde R_j^2 é o coeficiente de determinação da regressão da variável j sobre todas as demais. Valores de VIF acima de 5 ou 10 indicam multicolinearidade problemática. A remoção iterativa de variáveis com alto VIF é uma estratégia comum para obter um conjunto mais parcimonioso (GABOITAOLELWE et al., 2023).

2.9 Trabalhos relacionados

A literatura de previsão solar evoluiu de forma significativa nas últimas décadas, acompanhando o crescimento da inserção de fontes renováveis variáveis nos sistemas elétricos. Em um primeiro momento, o foco concentrou-se em previsões pontuais de irradiância e potência fotovoltaica, com ênfase em redução de erro médio. Entretanto, à medida que a participação da geração solar aumentou em aplicações operacionais, comerciais e de planejamento, tornou-se evidente que previsões pontuais são insuficientes para representar o risco associado à variabilidade atmosférica. Nesse contexto, a previsão probabilística passou a ocupar papel central, por fornecer informação sobre incerteza, dispersão e confiabilidade das estimativas, elementos fundamentais para tomada de decisão em despacho, operação e gestão de ativos.

No caso da geração fotovoltaica, a necessidade de modelagem da incerteza é ainda mais crítica em ambientes com elevada variabilidade de nebulosidade e mudanças rápidas no regime de irradiância. Nessas condições, erros de previsão não são apenas maiores em média, mas também heterogêneos no tempo, com distribuição potencialmente assimétrica e dependente do regime meteorológico. Por essa razão, a literatura recente enfatiza não apenas o desenvolvimento

de modelos mais precisos, mas também estratégias para construção, verificação e calibração de previsões probabilísticas, incluindo intervalos de predição e estimativas quantílicas.

Este subcapítulo organiza os trabalhos relacionados em três eixos: (i) previsão probabilística solar e critérios de verificação; (ii) aplicações de métodos baseados em *gradient boosting* na previsão fotovoltaica; e (iii) estudos em climas tropicais, com ênfase na lacuna existente para previsão probabilística de geração fotovoltaica no contexto amazônico. Ao final, apresenta-se uma síntese comparativa dos trabalhos revisados e o posicionamento desta dissertação.

2.9.1 Previsões probabilísticas solares

A consolidação da previsão probabilística em sistemas fotovoltaicos está associada à necessidade de representar explicitamente a incerteza preditiva, em contraste com a previsão pontual, que fornece apenas um valor estimado. Em revisão abrangente, Meer, Widén e Munkhammar (2018) compilaram métodos de previsão probabilística aplicados à geração fotovoltaica e ao consumo elétrico, destacando que a avaliação de desempenho deve considerar simultaneamente critérios de calibração e nitidez, e não apenas métricas tradicionais de erro pontual. Os autores mostram que a regressão quantílica, os métodos de *post-processing* e abordagens baseadas em *ensembles* meteorológicos constituem linhas promissoras para a construção de intervalos e distribuições preditivas em aplicações energéticas.

Um aspecto central dessa literatura é a distinção entre qualidade pontual e qualidade probabilística. Um modelo pode apresentar bom desempenho em termos de MAE ou RMSE e, ainda assim, produzir intervalos mal calibrados, excessivamente estreitos ou demasiadamente conservadores. Essa constatação levou ao uso crescente de métricas próprias para avaliação probabilística, como cobertura empírica, largura normalizada dos intervalos e regras de pontuação próprias (*proper scoring rules*), capazes de penalizar previsões inconsistentes tanto em termos de localização quanto de dispersão. Nesse sentido, a literatura ressalta que a utilidade operacional de uma previsão depende não apenas de sua acurácia média, mas também da qualidade da quantificação de incerteza associada.

Mais recentemente, Gneiting, Lerch e Schulz (2023) discutem *benchmarks* probabilísticos e estratégias de pós-processamento para previsão solar, reforçando a necessidade de protocolos de comparação mais rigorosos. Os autores argumentam que, para que resultados sejam comparáveis e cientificamente úteis, é necessário definir referências adequadas de desempenho, separar claramente calibração e nitidez, e evitar conclusões baseadas somente em métricas pontuais. Essa discussão é particularmente relevante para estudos que reportam intervalos de predição obtidos por regressão quantílica, uma vez que a qualidade dos intervalos depende tanto do modelo base quanto do procedimento de calibração adotado.

Além das discussões conceituais, trabalhos de verificação probabilística em irradiância solar reforçam que a avaliação de previsões probabilísticas deve ser tratada como um problema

metodológico próprio, e não apenas como extensão da avaliação pontual. Em particular, estudos de verificação e *benchmarking* mostram que métricas de cobertura e largura precisam ser analisadas conjuntamente, e que modelos de referência bem definidos são essenciais para interpretar ganhos reais de desempenho. Essa linha de trabalho fundamenta a escolha, nesta dissertação, de métricas como PICP e PINAW, bem como o uso de procedimentos explícitos de calibração.

Em síntese, a literatura de previsão probabilística solar converge em três pontos relevantes para esta pesquisa: (i) a regressão quantílica é uma abordagem adequada para estimar intervalos de predição sem impor hipóteses paramétricas rígidas sobre os erros; (ii) a qualidade dos intervalos deve ser avaliada por critérios de calibração e nitidez; e (iii) procedimentos de calibração e *post-processing* podem ser necessários, mesmo quando o modelo base apresenta bom desempenho preditivo.

2.9.2 Aplicações de *gradient boosting* em previsão fotovoltaica

A utilização de algoritmos de aprendizado de máquina em previsão de geração fotovoltaica é amplamente documentada, com destaque para métodos aplicados a dados tabulares que combinam variáveis meteorológicas observadas, previsões numéricas do tempo, atributos temporais e históricos de geração. Nesse contexto, algoritmos baseados em *gradient boosting*, como XGBoost, LightGBM e CatBoost, têm recebido atenção crescente por combinarem bom desempenho preditivo, flexibilidade de modelagem não linear e custo computacional frequentemente inferior ao de arquiteturas profundas em diferentes cenários experimentais.

Aksoy e Tolun (2023) comparam XGBoost, LightGBM e CatBoost em tarefas de previsão de potência em plantas solares e mostram que os três algoritmos apresentam desempenho competitivo. O interesse desse tipo de estudo não está apenas no ranking de acurácia, mas também na demonstração de que métodos da família *boosting* podem oferecer uma combinação favorável entre desempenho e eficiência de treinamento. Para pesquisas experimentais com múltiplas combinações de variáveis, validação temporal e ajustes de hiperparâmetros, essa eficiência computacional é particularmente importante, pois viabiliza ciclos iterativos de teste e comparação mais amplos.

Do ponto de vista metodológico, esses algoritmos compartilham a lógica de construção sequencial de preditores fracos, usualmente árvores de decisão rasas, ajustados de forma a reduzir iterativamente os erros do conjunto anterior. Apesar dessa base comum, há diferenças relevantes de implementação e comportamento. O XGBoost é frequentemente associado à robustez e ao uso explícito de regularização; o LightGBM enfatiza escalabilidade e eficiência por meio de discretização por histogramas e estratégias de crescimento de árvore; e o CatBoost incorpora mecanismos específicos para tratamento de variáveis categóricas e mitigação de viés no treinamento. Ainda que nem todos esses diferenciais sejam igualmente explorados em problemas de previsão solar com variáveis majoritariamente numéricas, a presença recorrente desses três

modelos em estudos comparativos indica sua relevância como linha de base moderna para tarefas de previsão fotovoltaica.

Revisões recentes sobre aprendizado de máquina e aprendizado profundo aplicados à previsão fotovoltaica também reportam, de forma recorrente, que modelos baseados em *boosting* figuram entre os mais competitivos em bases tabulares, especialmente quando acompanhados de engenharia de atributos e protocolos adequados de validação temporal (GABOITAOLELWE et al., 2023; MAULADDAWILAH et al., 2024). Essa observação é importante porque desloca o foco de uma comparação simplista entre “modelos clássicos” e “modelos profundos” para uma discussão mais apropriada sobre adequação ao tipo de dado, horizonte de previsão, custo computacional e interpretabilidade experimental.

Para esta dissertação, o interesse em LightGBM não se limita ao desempenho em previsão pontual. Um aspecto decisivo é a possibilidade de treinamento direto para regressão quantílica por meio da minimização da perda *pinball* para quantis específicos. Essa característica permite estimar quantis condicionais de forma direta e construir intervalos de predição sem depender de hipóteses paramétricas sobre a distribuição dos erros. Em termos práticos, isso torna o LightGBM uma alternativa particularmente adequada para estudos que buscam integrar previsão de geração fotovoltaica e quantificação de incerteza em um mesmo arcabouço experimental.

Ainda assim, a literatura também aponta limitações que merecem atenção. Em muitos estudos comparativos, os resultados dependem sensivelmente do conjunto de dados, da qualidade das variáveis exógenas, da estratégia de divisão temporal e do ajuste de hiperparâmetros. Além disso, comparações entre algoritmos nem sempre são realizadas sob protocolos estritamente equivalentes, o que pode favorecer conclusões excessivamente generalizantes. Por essa razão, a adoção de um pipeline padronizado de pré-processamento, divisão temporal e avaliação, como realizado nesta dissertação, é um elemento metodológico relevante para garantir comparabilidade interna dos resultados.

2.9.3 Previsão em climas tropicais e lacuna no contexto amazônico

Embora a literatura internacional sobre previsão solar seja extensa, estudos focados em climas tropicais permanecem relativamente menos numerosos quando comparados a trabalhos em regiões de clima temperado ou com maior predominância de céu limpo. Essa assimetria é metodologicamente relevante porque a previsibilidade da irradiância e da potência fotovoltaica depende fortemente do regime atmosférico local, especialmente da dinâmica de formação, evolução e dissipação de nuvens.

Verbois, Rusydi e Thiery (2018) analisam previsão de irradiância em ambiente tropical (Singapura) e mostram que a combinação de modelos meteorológicos com métodos estatísticos pode melhorar o desempenho de previsão, embora a incerteza permaneça elevada em episódios convectivos. Esse resultado é importante por evidenciar que ganhos metodológicos não eliminam

a dificuldade intrínseca de previsão em contextos de alta variabilidade de nebulosidade. Em outras palavras, a limitação não decorre apenas da escolha do algoritmo, mas também do regime físico-atmosférico subjacente.

No contexto tropical mais amplo, estudos sobre condições convectivas reforçam essa interpretação ao mostrar que a acurácia de previsões solares pode se degradar em períodos e regiões com maior atividade convectiva. Esse tipo de evidência é particularmente útil para fundamentar a análise de variabilidade em regiões tropicais úmidas, pois demonstra que a dificuldade de previsão está associada a mecanismos atmosféricos recorrentes e não apenas a especificidades de uma base de dados local.

No Brasil, trabalhos recentes têm ampliado a discussão sobre recursos solares, irradiância e impactos climáticos, incluindo análises de incertezas em projeções climáticas e propostas de métodos de aprendizado de máquina para previsão de irradiância global horizontal em escalas de médio prazo (LIMA et al., 2024; WEYLL et al., 2024). Esses estudos são relevantes para o avanço do campo no país, mas não eliminam a lacuna específica desta dissertação: a escassez de trabalhos dedicados à previsão probabilística de geração fotovoltaica, com foco em quantificação de incerteza e avaliação por calibração/nitidez, em condições de clima tropical úmido amazônico.

Essa lacuna torna-se mais significativa diante do crescimento da capacidade instalada de geração solar na região Norte do Brasil e da necessidade de ferramentas de previsão mais aderentes às características locais de variabilidade atmosférica. Além disso, grande parte da literatura nacional ainda privilegia previsão pontual, irradiância em vez de potência fotovoltaica, ou horizontes e objetivos distintos dos adotados nesta dissertação. Assim, embora existam trabalhos relacionados em previsão solar no Brasil, permanece limitada a produção voltada especificamente à construção e avaliação de intervalos de predição para geração fotovoltaica em contexto amazônico, com uso de modelos baseados em regressão quantílica e calibração posterior.

2.9.4 Síntese crítica e posicionamento desta dissertação

A revisão apresentada permite identificar uma convergência entre três linhas de literatura que fundamentam esta pesquisa. A primeira estabelece os princípios e critérios da previsão probabilística solar, com ênfase em calibração, nitidez e *benchmarks* probabilísticos. A segunda demonstra a competitividade de algoritmos de *gradient boosting* em tarefas de previsão fotovoltaica, sobretudo em bases tabulares. A terceira evidencia que ambientes tropicais impõem desafios adicionais à previsão solar devido à maior variabilidade atmosférica, ao mesmo tempo em que revela a escassez de estudos específicos no contexto amazônico.

Entretanto, a interseção entre essas três linhas ainda é pouco explorada. Em particular, são escassos os estudos que combinam, de forma sistemática, os seguintes elementos: (i) previsão probabilística de geração fotovoltaica em clima tropical úmido amazônico; (ii) uso de regressão

quantílica com algoritmo de *gradient boosting* como modelo base; (iii) avaliação explícita por calibração e nitidez; e (iv) calibração posterior dos intervalos de predição para aproximação da cobertura nominal. Essa combinação constitui precisamente o recorte metodológico adotado nesta dissertação.

A Tabela 2 sintetiza os principais trabalhos discutidos, destacando objetivo, abordagem, contexto climático e contribuição em relação ao problema investigado nesta pesquisa.

Como contribuição em relação aos trabalhos revisados, esta dissertação não pretende substituir revisões amplas nem propor um novo algoritmo de previsão. Seu objetivo é oferecer uma investigação aplicada e metodologicamente estruturada sobre previsão probabilística de geração fotovoltaica em um contexto climático ainda pouco explorado, com ênfase na construção, avaliação e calibração de intervalos de predição obtidos por regressão quantílica com LightGBM.

2.10 Síntese e posicionamento

Este capítulo apresentou os fundamentos para o restante da dissertação:

1. A previsão fotovoltaica é difícil porque a irradiância varia rapidamente, especialmente em climas tropicais úmidos. Dados de Tucuruí mostram que **99,9% dos dias apresentam variabilidade significativa** ($CV \geq 0,5$), com apenas 2 dias em 6 anos apresentando condições estáveis.
2. Métodos de aprendizado de máquina, particularmente *gradient boosting* (XGBoost, LightGBM), têm se destacado na literatura recente por combinar boa acurácia com eficiência computacional.
3. Previsões probabilísticas são mais informativas que previsões pontuais porque comunicam a incerteza esperada. Os critérios centrais de avaliação são calibração e nitidez.
4. As métricas PICP (cobertura) e PINAW (largura normalizada) permitem avaliar quantitativamente a qualidade dos intervalos de predição.
5. A regressão quantílica permite construir intervalos sem assumir distribuição específica para os erros, e pode ser combinada diretamente com LightGBM.
6. A incerteza varia conforme o regime de irradiância (heterocedasticidade), o que motiva a estratificação do problema em subconjuntos mais homogêneos.

Com base nesse modelo, a dissertação se posiciona ao empregar regressão quantílica com LightGBM, combinada com estratificação por regimes de irradiância, para produzir intervalos de predição calibrados e informativos em um contexto de alta variabilidade atmosférica característico da Amazônia brasileira. O próximo capítulo descreve os dados utilizados e o pré-processamento aplicado.

Tabela 2 – Síntese comparativa de trabalhos relacionados e posicionamento desta dissertação.

Trabalho	Foco principal	Método/abordagem	Contexto climático / dado	Relação com esta dissertação
Meer, Widén e Munkhammar (2018)	Revisão de previsão probabilística em energia (FV e consumo)	Revisão de métodos probabilísticos (quantis, intervalos, distribuições)	Revisão ampla (sem foco climático específico)	Fundamenta conceitos de previsão probabilística, calibração e nitidez, mas não propõe estudo aplicado ao contexto amazônico.
Gneiting, Lerch e Schulz (2023)	<i>Benchmarks</i> e verificação de previsões probabilísticas solares	Discussão metodológica, <i>post-processing</i> e avaliação probabilística	Previsão solar probabilística (sem foco em clima amazônico)	Fundamenta protocolos de avaliação e comparação probabilística; reforça a necessidade de calibração e referências apropriadas.
Aksoy e Tolun (2023)	Comparação de XGBoost, LightGBM e CatBoost em previsão solar	<i>Gradient boosting</i> para previsão de potência solar	Aplicação em plantas solares (contexto específico do estudo)	Sustenta a escolha de modelos baseados em <i>boosting</i> ; não tem foco central em intervalos de predição calibrados.
Gaboitaolelwe et al. (2023)	Revisão de ML para previsão FV	Revisão comparativa de algoritmos de ML	Revisão ampla	Indica competitividade de métodos de <i>boosting</i> ; não aborda especificamente calibração de intervalos em clima amazônico.
Mauladdawilah et al. (2024)	Revisão de abordagens de previsão solar (incluindo DL)	Revisão de métodos e tendências	Revisão ampla	Contextualiza o estado da arte e reforça a importância da adequação metodológica ao tipo de dado.
Verbois, Rusydi e Thiery (2018)	Previsão de irradiância em ambiente tropical (Singapore)	Combinação de NWP e métodos estatísticos	Tropical úmido / convectivo	Evidencia desafios de previsão em clima tropical; foco em irradiância, não em previsão probabilística de geração FV amazônica.
Lima et al. (2024)	Incertezas climáticas e recursos solares no Brasil	Projeções climáticas / análise de incerteza	Brasil (escala macro)	Relevante para contexto nacional de recurso solar, mas não trata diretamente de previsão probabilística de geração FV operacional.
Weyll et al. (2024)	Previsão de GHI no Brasil em médio prazo	Aprendizado de máquina para irradiância	Brasil	Relevante para previsão solar no país, porém com foco em irradiância e horizonte distinto do desta dissertação.
Esta dissertação	Previsão probabilística de geração FV em clima amazônico	LightGBM quantílico + construção de intervalos + calibração por fator de escala + avaliação por PICP/PINAW	Tucuruí (Amazônia, clima tropical úmido)	Integra previsão probabilística, regressão quantílica e calibração de intervalos em contexto amazônico, enfatizando calibração e nitidez sob alta variabilidade de irradiância.

3 DADOS E PRÉ-PROCESSAMENTO

Este capítulo descreve o sistema fotovoltaico estudado, as fontes de dados utilizadas e as etapas de pré-processamento aplicadas. O tratamento adequado dos dados é tão importante quanto a escolha do algoritmo, pois um modelo sofisticado alimentado com dados inconsistentes produzirá resultados inconsistentes (INMAN; PEDRO; COIMBRA, 2013).

3.1 Sistema fotovoltaico em estudo

O sistema fotovoltaico objeto deste estudo está localizado em Tucuruí, no sudeste do estado do Pará, nas coordenadas $3^{\circ}46'59.7''\text{S}$, $49^{\circ}39'57.9''\text{W}$. A Figura 8 apresenta o sistema, incluindo vista aérea, localização via satélite e o inversor utilizado.



Figura 8 – Sistema fotovoltaico em estudo: (a) vista aérea da instalação, (b) localização por imagem de satélite e (c) inversor e quadro de proteção.

A inspeção visual da instalação e o histórico operacional utilizado neste estudo não indicam sombreamento relevante sobre o arranjo fotovoltaico durante o período analisado. Assim, as variações de geração discutidas ao longo do capítulo são interpretadas principalmente à luz das condições meteorológicas e das características operacionais do sistema.

A Tabela 3 resume as especificações técnicas do sistema:

Tabela 3 – Especificações técnicas do sistema fotovoltaico em estudo.

Parâmetro	Especificação
Capacidade instalada	10,08 kWp
Número de painéis	32 unidades
Modelo dos painéis	Jinko Solar 315 Wp
Tecnologia	Silício policristalino
Inversor	Fronius Primo 8.2-1
Potência do inversor	8,2 kW
Localização	Tucuruí, PA, Brasil
Coordenadas	3°46'59.7"S, 49°39'57.9"W
Clima (Köppen)	Equatorial (Am)

Fonte: Elaborado pelo autor.

A escolha de Tucuruí como local de estudo é estratégica por representar as condições típicas do clima tropical úmido amazônico, caracterizado por alta umidade relativa, temperatura elevada e formação frequente de nuvens convectivas. Essas condições criam um cenário desafiador para previsão fotovoltaica, conforme discutido no Capítulo 2.

3.2 Fontes de dados

Os dados utilizados neste estudo foram coletados de duas fontes principais:

1. **Dados de geração fotovoltaica:** registros reais de produção do sistema, obtidos através do sistema de monitoramento do inversor Fronius.
2. **Dados meteorológicos:** variáveis atmosféricas obtidas da plataforma Open-Meteo, um serviço que disponibiliza séries meteorológicas globais em resolução horária, derivadas de modelos meteorológicos e produtos de reanálise (OPEN-METEO, 2026).

A escolha por dados meteorológicos do Open-Meteo se justifica pela disponibilidade contínua e pela consistência temporal, características nem sempre encontradas em estações meteorológicas convencionais, que frequentemente apresentam falhas e descontinuidades (VERBOIS; RUSYDI; THIERY, 2018).

O período de análise compreende **1º de janeiro de 2018 a 31 de dezembro de 2023**, totalizando seis anos completos de dados. Após a aplicação dos filtros descritos nas seções seguintes, o conjunto de dados contém **28.326 registros horários**.

A adoção de uma série longa aumenta a representatividade climática e a robustez estatística, pois incorpora variabilidade sazonal e interanual relevante ao contexto tropical. Por outro lado, intervalos multianuais podem incluir efeitos de não estacionariedade operacional, como envelhecimento natural dos módulos, acúmulo de sujeira e intervenções de manutenção. Como o objetivo desta dissertação é prever a geração real do sistema em campo, tais efeitos são tratados

como parte do comportamento observado da planta, ainda que possam introduzir deriva lenta na relação entre variáveis meteorológicas e geração.

3.3 Variáveis meteorológicas

É importante destacar que o objetivo deste trabalho é prever a **energia** gerada pelo sistema fotovoltaico em cada hora (expressa em Wh ou kWh), e não a potência instantânea (expressa em W ou kW). Embora os termos sejam frequentemente confundidos na literatura, a distinção é relevante: a potência representa a taxa de conversão de energia em um instante, enquanto a energia representa a quantidade total gerada ao longo de um período. Como os dados utilizados são horários, cada registro representa a energia acumulada durante aquela hora.

A Tabela 4 apresenta as variáveis disponíveis no conjunto de dados bruto, antes da seleção de variáveis:

Tabela 4 – Variáveis disponíveis no conjunto de dados bruto.

Variável	Descrição	Unidade	Tipo
Radiação (kJ/m ²)	Irradiação global horizontal horária (GHI)	kJ/m ²	Entrada
Temperatura Inst.	Temperatura instantânea do ar	°C	Entrada
Pressão	Pressão atmosférica	hPa	Entrada
Umidade	Umidade relativa instantânea	%	Entrada
Ponto de orvalho	Temperatura do ponto de orvalho	°C	Entrada
Vel. vento	Velocidade média do vento	m/s	Entrada
Rajada	Rajada máxima de vento	m/s	Entrada
Temp. Máxima	Temperatura máxima horária	°C	Entrada
Temp. Mínima	Temperatura mínima horária	°C	Entrada
Produção FV	Geração fotovoltaica medida	Wh	Resposta

Fonte: Elaborado pelo autor.

A variável *Radiação (kJ/m²)* foi derivada do parâmetro `shortwave_radiation` do Open-Meteo, fornecido como média horária da janela anterior (W/m²). Para representar energia por área na base horária, aplicou-se a conversão para kJ/m² pelo fator 3,6 (OPEN-METEO, 2026). Quando necessário para interpretação física e comparação com valores típicos, a energia horária por área foi convertida para a *irradiância média horária equivalente* (W/m²) pela relação $G = E_h/3,6$. A Tabela 5 apresenta as estatísticas descritivas das principais variáveis.

3.4 Seleção de variáveis e remoção de multicolinearidade

Variáveis meteorológicas frequentemente apresentam correlações elevadas entre si, o que pode prejudicar a estabilidade e interpretabilidade dos modelos. Para identificar e remover redundâncias, foi aplicado o Fator de Inflação da Variância (VIF), conforme discutido na Seção 2.8 do Capítulo 2

Tabela 5 – Estatísticas descritivas das variáveis meteorológicas e da produção FV.

Variável	Média	Desvio Padrão	Mínimo	Máximo
Irradiância (W/m ²)	399,6	277,3	1,0	999,0
Temperatura (°C)	28,2	2,5	22,5	35,6
Umidade relativa (%)	73,5	13,3	25,0	98,0
Pressão (hPa)	1.004,0	2,3	995,6	1.012,1
Velocidade do vento (m/s)	7,3	3,1	0,0	21,4
Produção FV (Wh)	2.870,3	2.187,9	0,0	8.168,5

Fonte: Elaborado pelo autor a partir dos dados Open-Meteo e medições da usina (2018-2023).

O procedimento foi executado de forma iterativa: calculou-se o VIF de cada variável e removeu-se aquela com maior valor acima do limiar de 10, repetindo até que todas as variáveis restantes apresentassem VIF aceitável. A variável de radiação foi protegida da remoção por ser o principal preditor da geração fotovoltaica.

A Tabela 6 apresenta o resultado da análise, indicando as variáveis removidas e as mantidas:

Tabela 6 – Resultado da análise de multicolinearidade via VIF.

Variável	VIF Final	Status
Radiação (kJ/m ²)	1,82	Mantida (protegida)
Pressão	1,15	Mantida
Ponto de orvalho	2,34	Mantida
Rajada de vento	2,87	Mantida
Velocidade do vento	2,51	Mantida
Temperatura mínima	3,12	Mantida
Temperatura instantânea	>10	Removida
Umidade relativa	>10	Removida
Temperatura máxima	>10	Removida

Fonte: Elaborado pelo autor.

As três variáveis removidas apresentavam alta correlação com as mantidas: temperatura instantânea e temperatura máxima são altamente correlacionadas com temperatura mínima, enquanto a umidade relativa é determinada termodinamicamente pela temperatura e pelo ponto de orvalho.

Após a seleção, o modelo utiliza **seis variáveis preditoras**:

1. Radiação (kJ/m²)
2. Pressão atmosférica (hPa)
3. Ponto de orvalho (°C)
4. Rajada de vento (m/s)

5. Velocidade do vento (m/s)
6. Temperatura mínima (°C)

Essa redução de nove para seis variáveis diminui a dimensionalidade sem perda significativa de informação, uma vez que as variáveis removidas eram redundantes.

A manutenção da variável *Pressão atmosférica (hPa)* requer uma observação metodológica. Embora sua relação física direta com a conversão fotovoltaica seja menos imediata do que a da radiação, da temperatura e da umidade, a pressão pode atuar como variável meteorológica auxiliar, refletindo padrões sinóticos e condições de estabilidade atmosférica que afetam indiretamente a nebulosidade e, conseqüentemente, a geração. Neste estudo, sua permanência decorre do critério de multicolinearidade (VIF baixo) e da estratégia de preservar variáveis potencialmente informativas para a etapa de modelagem. Como verificação adicional, recomenda-se em trabalhos futuros um teste de ablação comparando o desempenho dos modelos com e sem essa variável.

3.5 Filtragem temporal

A geração fotovoltaica é nula durante a noite, tornando os registros noturnos irrelevantes para o problema de previsão. Incluí-los no treinamento pode distorcer as métricas de avaliação e induzir o modelo a priorizar a classe “zero” em detrimento da variabilidade diurna, que é o verdadeiro desafio (INMAN; PEDRO; COIMBRA, 2013).

Por esse motivo, o conjunto de dados foi restringido ao intervalo entre **06:00 e 19:00** (horário local). Em seguida, para excluir instantes sem recurso solar (especialmente no início e no fim do dia), foram mantidos apenas registros com *Radiação (kJ/m^2)* maior que zero. Esse critério preserva o recorte diurno relevante para previsão e evita que horas com geração estruturalmente nula distorçam métricas e o ajuste dos modelos (PELLAND et al., 2013).

A Figura 9 mostra o perfil médio de produção e irradiância ao longo do dia, evidenciando o formato característico com pico entre 11h e 14h. As barras de erro representam um desvio padrão.

3.6 Tratamento de valores ausentes

A remoção de valores ausentes (NaNs) foi realizada por exclusão (*drop/listwise deletion*), evitando introduzir padrões artificiais por imputação (média, interpolação ou modelos). A contagem de **3 observações** (0,01%) refere-se ao conjunto já submetido ao recorte diurno e ao filtro de radiação positiva, isto é, à etapa imediatamente anterior à base final de modelagem (ver Tabela 7). Nessa etapa, os NaNs remanescentes ocorreram apenas na variável de produção fotovoltaica e foram removidos. Nas variáveis meteorológicas utilizadas, não foram identificados valores ausentes no conjunto final.




Figura 9 – Perfil médio diário da produção fotovoltaica (barras) e da irradiância GHI (linha) em Tucuruí-PA.

Essa decisão é particularmente adequada quando a taxa de ausência é muito baixa e quando a série apresenta alta variabilidade climática, pois imputações podem suavizar rampas, reduzir variância e distorcer dependências temporais relevantes ao problema (GABOITAOLELWE et al., 2023).

3.7 Detecção e tratamento de anomalias

A integridade do conjunto de dados foi verificada por meio de checagens de consistência física, com o objetivo de identificar pontos inválidos que poderiam enviesar o ajuste e a avaliação dos modelos. Em bases de monitoramento fotovoltaico, anomalias e registros espúrios podem ocorrer por falhas de sensores, ruídos de aquisição, indisponibilidade do sistema, atrasos de comunicação e problemas pontuais de medição, sendo recomendável aplicar rotinas explícitas de controle de qualidade antes da modelagem (HU et al., 2019; CHOI et al., 2022).

Foram adotados critérios conservadores, incluindo: (i) *Radiação (kJ/m^2)* não negativa; (ii) produção fotovoltaica não negativa; (iii) produção fotovoltaica limitada superiormente por um valor fisicamente plausível para a planta (definido a partir da potência nominal do sistema e do intervalo de agregação horária), além de (iv) inspeção de picos isolados incompatíveis com o perfil diurno.

Após a aplicação dos filtros de recorte diurno e consistência descritos nas seções anteriores, **não foram identificados registros no conjunto final que violassem os limites físicos adotados**. Assim, **não houve necessidade de remoções adicionais** nesta etapa, permanecendo apenas a verificação como salvaguarda de qualidade e rastreabilidade metodológica.

3.8 Resumo do pré-processamento

Para garantir reprodutibilidade e transparência, a Tabela 7 resume o impacto de cada etapa de filtragem e limpeza, indicando o número de registros mantidos e removidos.

Tabela 7 – Resumo do pré-processamento e filtragens aplicadas ao conjunto de dados (2018–2023).

Etapa	Registros	Removidos	Observação
Base bruta (hora a hora)	52.584	N/A	Período completo
Filtragem diurna	28.329	24.255	06:00–19:00 e Radiação > 0
Remoção de ausentes (NaNs)	28.326	3	NaNs apenas em Produção FV
Checagem de anomalias físicas	28.326	0	Sem violações após filtros
Base final para modelagem	28.326	N/A	Conjunto final

Fonte: Elaborado pelo autor.

3.9 Análise de correlação

A Figura 10 apresenta a matriz de correlação entre as variáveis meteorológicas e a produção fotovoltaica. A irradiância apresenta a maior correlação positiva com a produção ($r = 0,78$), seguida pela pressão atmosférica ($r = 0,41$) e temperatura ($r = 0,31$). A umidade relativa apresenta correlação negativa ($r = -0,30$), indicando que dias mais úmidos tendem a ter menor produção, comportamento esperado porque alta umidade geralmente está associada à presença de nuvens.

A Figura 11 detalha a relação entre irradiância e produção, com os pontos coloridos pela umidade relativa. Observa-se uma relação aproximadamente linear ($R^2 = 0,61$), com maior dispersão no regime intermediário de irradiância, justamente onde a variabilidade atmosférica é mais pronunciada. As linhas tracejadas verticais indicam os limiares de regime Q₃₃ e Q₆₇, utilizados posteriormente na estratificação por radiação.

3.10 Análise de sazonalidade

O clima amazônico apresenta duas estações bem definidas: a estação chuvosa (dezembro a maio) e a estação seca (junho a novembro). Essa sazonalidade influencia diretamente a produção fotovoltaica, conforme ilustrado na Figura 12.

A análise revelou diferenças significativas entre as estações:

- **Estação seca (junho a novembro):** produção média de 3.016 Wh, com irradiância média de 437,5 W/m² (14.125 registros).
- **Estação chuvosa (dezembro a maio):** produção média de 2.725 Wh, com irradiância média de 362,0 W/m² (14.201 registros).




Figura 10 – Matriz de correlação entre variáveis meteorológicas e produção fotovoltaica.

A produção na estação seca é, em média, **10,7% superior** à da estação chuvosa. Essa diferença, embora expressiva, é menor do que a observada em outras regiões tropicais, o que se deve à posição geográfica de Tucuruí próxima ao equador, onde a variação sazonal da irradiância é menos pronunciada. O mês mais produtivo é agosto (3.186 Wh médios), enquanto dezembro apresenta a menor produção média (2.494 Wh).

A Figura 13 ilustra o contraste entre um dia de alta produção na estação seca e um dia nublado na estação chuvosa. No dia 19/08/2019, a produção total atingiu 52.106 Wh, com uma curva suave característica de céu limpo. Em contraste, no dia 26/12/2020, a produção foi de 24.918 Wh, com curva irregular típica de passagem intermitente de nuvens. Em termos relativos, o dia de menor produção apresentou valor **52,2% inferior** ao dia de maior produção (ou, de forma equivalente, o dia de maior produção foi 109% superior ao dia de menor produção). Esse contraste evidencia o impacto das condições atmosféricas sobre a geração fotovoltaica e reforça a necessidade de modelos capazes de capturar essa variabilidade.

3.11 Análise de distribuição

A distribuição da produção fotovoltaica apresenta características relevantes para a modelagem preditiva. A análise estatística indicou assimetria positiva moderada (coeficiente de




Figura 11 – Relação entre irradiância solar e produção fotovoltaica, com pontos coloridos pela umidade relativa.

assimetria = 0,22), o que sugere uma distribuição próxima da simetria, porém com cauda à direita discretamente mais pronunciada. Em termos práticos, isso indica maior concentração de observações em faixas baixas e intermediárias de geração, com ocorrência menos frequente de valores elevados, mas ainda presentes em condições meteorológicas favoráveis.

Esse comportamento é compatível com a natureza da geração fotovoltaica em ambiente real, na qual há grande número de registros com produção reduzida, especialmente em horários de transição (início e final do período diurno) e em condições de maior nebulosidade, enquanto os picos de geração se concentram em janelas menores, sob maior disponibilidade de irradiância. Assim, mesmo após o recorte temporal adotado, a distribuição da variável-alvo não tende a ser perfeitamente simétrica.

A Figura 12 complementa essa análise ao evidenciar a variabilidade sazonal da produção ao longo do período estudado. Observa-se contraste entre períodos de maior e menor disponibilidade solar, com deslocamento da distribuição para valores mais altos nos meses de melhor desempenho energético e redução da tendência central em meses mais chuvosos. Além disso, a dispersão intra-período indica que, mesmo dentro de uma mesma estação, há variabilidade considerável na geração, reforçando a influência de condições meteorológicas transitórias. Esse resultado é importante porque mostra que a incerteza da geração não é constante ao longo do ano.

A Figura 13 aprofunda essa interpretação ao comparar perfis diários representativos sob diferentes condições atmosféricas. No dia de maior produção, a curva apresenta crescimento mais regular, maior pico e faixa de geração elevada por intervalo mais longo, comportamento




Figura 12 – Análise de sazonalidade e distribuição da produção fotovoltaica ao longo do período de estudo.




Figura 13 – Contraste entre dias típicos da estação seca e da estação chuvosa.

típico de menor nebulosidade. No dia de menor produção (ou dia nublado), observa-se redução do pico, maior irregularidade no perfil e menor energia total diária, refletindo a atenuação da irradiância por cobertura de nuvens. No conjunto analisado, esse contraste resulta em diferença percentual expressiva entre os dias típicos, evidenciando que a variabilidade diária pode ser alta mesmo para um mesmo sistema fotovoltaico.

Do ponto de vista de modelagem, os resultados das Figuras 12 e 13 reforçam a necessidade de métodos capazes de representar não apenas a tendência central, mas também a dispersão condicional da geração. Esse comportamento justifica a adoção de abordagem probabilística por regressão quantílica e também sustenta a segmentação por regimes de irradiância, uma vez que o

padrão estatístico da geração se altera conforme as condições meteorológicas predominantes.

3.12 Escalonamento de variáveis

As variáveis preditoras foram normalizadas utilizando o `StandardScaler` da biblioteca `scikit-learn` (PEDREGOSA et al., 2011), ajustando para média zero e desvio padrão unitário. Essa padronização melhora a estabilidade numérica do treinamento e favorece a convergência de algoritmos sensíveis à escala das entradas.

Nesta implementação, o escalonamento foi aplicado previamente à divisão em treino, validação e teste, estimando-se os parâmetros (média e desvio padrão) no conjunto completo. Essa escolha simplifica o pipeline, porém pode induzir vazamento estatístico ao incorporar informação global na transformação das variáveis. Assim, os resultados devem ser interpretados sob essa configuração experimental. Como extensão natural, recomenda-se ajustar o escalonamento exclusivamente no conjunto de treinamento e aplicar a transformação aos subconjuntos de validação e teste.

3.13 Divisão treino/validação/teste

A base final foi particionada em três subconjuntos (Treinamento, Validação e Teste) por amostragem aleatória, preservando a proporção 70%/15%/15%, com semente fixa para reprodutibilidade. Essa divisão foi implementada com o `train_test_split` e permite avaliar o desempenho médio dos modelos sob amostragem aleatória.

Embora o problema possua natureza temporal, nesta dissertação adotou-se a divisão aleatória para manter consistência com o pipeline de treinamento implementado. Em séries temporais, validações cronológicas por blocos são, em geral, recomendadas por reduzirem o risco de viés otimista; por esse motivo, essa alternativa é destacada como extensão metodológica e como melhoria natural em trabalhos futuros.

Tabela 8 – Divisão do conjunto de dados em treino, validação e teste (amostragem aleatória).

Conjunto	Registros	Proporção
Treinamento	19.828	70%
Validação	4.249	15%
Teste	4.249	15%
Total	28.326	100%

Na prática, o Treinamento foi usado para o modelo “aprender” os padrões dos dados (ajuste dos parâmetros internos). A Validação foi utilizada para orientar escolhas do experimento, principalmente a seleção de hiperparâmetros e a definição da configuração final, reduzindo o risco de ajustes excessivos ao conjunto de treino. Por fim, o Teste foi mantido isolado durante o desenvolvimento e só foi usado na etapa final, para reportar resultados de generalização.

3.14 Estratificação por regimes de radiação

Conforme discutido no Capítulo 2, a incerteza da geração FV não é homogênea ao longo do domínio de operação. Para capturar essa heterogeneidade, o conjunto de dados foi estratificado em três regimes de radiação.

Os limiares de regime foram definidos com base nos **tercis da Radiação (kJ/m^2) no conjunto de treinamento**, garantindo distribuição aproximadamente equilibrada entre os regimes e evitando vazamento de informação do conjunto de teste. Os tercís calculados foram:

- Q_{33} (limiar inferior): $784,8 \text{ kJ/m}^2 \approx 218 \text{ W/m}^2$
- Q_{67} (limiar superior): $1.954,8 \text{ kJ/m}^2 \approx 543 \text{ W/m}^2$

A Tabela 9 apresenta a distribuição resultante no conjunto de treinamento:

Tabela 9 – Distribuição dos registros por regime de radiação (conjunto de treinamento).

Regime	Critério (kJ/m^2)	Registros	Proporção
Baixa	Radiação $< 784,8$	6.604	33,3%
Intermediária	$784,8 \leq \text{Radiação} < 1.954,8$	6.599	33,3%
Alta	Radiação $\geq 1.954,8$	6.625	33,4%
Total	N/A	19.828	100%

Fonte: Elaborado pelo autor.

A escolha de tercís no conjunto de treinamento, em vez de limiares fixos arbitrários, apresenta duas vantagens: (i) garante amostras suficientes para obter estimativas estáveis em cada regime, e (ii) evita que a definição dos limiares seja influenciada por informações do conjunto de teste.

A Figura 14 ilustra a distribuição da irradiância com os limiares dos regimes destacados. Nesta figura, a GHI é apresentada como irradiância média horária equivalente (W/m^2), obtida a partir da irradiação horária (kJ/m^2) por divisão por 3,6. O pico na primeira faixa do histograma corresponde a observações de baixa irradiância, típicas de horários próximos ao início e ao fim do período diurno considerado (ainda com radiação positiva). Esse comportamento não representa um problema do histograma em si para a modelagem, pois os modelos utilizam os valores contínuos das variáveis e não as classes do gráfico; contudo, ele influencia naturalmente a posição dos tercís Q_{33} e Q_{67} , o que é coerente com a distribuição observada no domínio operacional adotado.

3.15 Resumo do capítulo

Este capítulo apresentou o sistema fotovoltaico em estudo e o conjunto de dados utilizado:




Figura 14 – Distribuição da irradiância média horária equivalente e limiares dos regimes de radiação (Q_{33} e Q_{67}).

- **Sistema:** 10,08 kWp, 32 painéis Jinko 315 Wp, inversor Fronius Primo 8.2-1
- **Localização:** Tucuruí-PA (3°46'59.7"S, 49°39'57.9"W)
- **Fontes:** Open-Meteo (meteorologia) + medições reais da usina (produção)
- **Período:** Janeiro/2018 a dezembro/2023 (6 anos)
- **Registros:** 28.326 observações horárias (06h–19h)
- **Seleção de variáveis:** VIF aplicado, reduzindo de 9 para 6 variáveis preditoras
- **Normalização:** StandardScaler (aplicado antes da divisão)
- **Divisão:** 70% treino / 15% validação / 15% teste (amostragem aleatória)
- **Regimes:** definidos por tercis (Q_{33}/Q_{67}) da radiação, com $\approx 33\%$ cada

As análises exploratórias revelaram:

- **Correlação:** irradiância é o principal preditor ($r = 0,78$); umidade e ponto de orvalho são redundantes ($VIF > 10$).
- **Sazonalidade:** produção na estação seca é 10,7% superior à da estação chuvosa em média; em dias extremos comparados, o dia nublado pode apresentar produção 52,2% inferior ao dia de alta produção (equivalente a 109% quando a base é o dia de menor produção).
- **Distribuição:** assimetria positiva moderada e curtose negativa, justificando o uso de regressão quantílica.

O próximo capítulo descreve a metodologia de modelagem proposta.

4 METODOLOGIA

4.1 Visão geral da metodologia proposta

A metodologia desta dissertação foi construída para atender a dois objetivos complementares. O primeiro é obter previsões horárias de geração fotovoltaica (FV) com boa precisão pontual. O segundo, e mais importante no contexto deste trabalho, é produzir previsões probabilísticas confiáveis, expressas por intervalos de predição calibrados e informativos. Esse direcionamento é consistente com o entendimento moderno de previsão probabilística, no qual a qualidade deve ser avaliada por calibração e nitidez (*sharpness*) e não apenas por métricas pontuais (GNEITING; BALABDAOUI; RAFTERY, 2007; GNEITING; KATZFUSS, 2014).

Em linhas gerais, o pipeline inclui: (i) consolidação e pré-processamento dos dados (Capítulo 3), (ii) construção de modelos de referência determinísticos, (iii) construção do modelo probabilístico via regressão quantílica com LightGBM, (iv) estratificação por regimes de radiação para capturar heterogeneidade de incerteza, e (v) avaliação determinística e probabilística por métricas adequadas. A classificação de métodos de previsão solar que motiva essas escolhas e destaca o papel de abordagens orientadas por dados é discutida de forma consolidada em (INMAN; PEDRO; COIMBRA, 2013).

Para facilitar a visualização do encadeamento das etapas, a Figura 15 apresenta um fluxograma sintético da metodologia empregada neste trabalho.

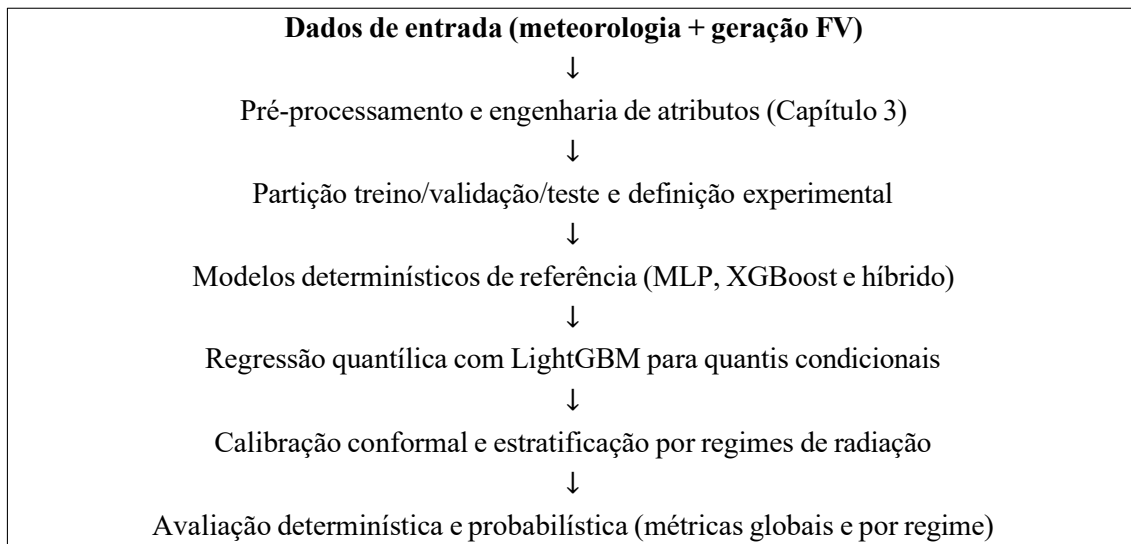


Figura 15 – Fluxograma sintético da metodologia proposta.

4.2 Definição do problema e notação

Considere uma série temporal horária com variável resposta y_t representando a geração FV (potência média horária ou energia horária, conforme definido no conjunto de dados), e um

vetor de atributos $\mathbf{x}_t \in \mathbb{R}^d$ contendo variáveis meteorológicas e atributos derivados.

O problema de previsão um passo à frente (horizonte $h = 1$ hora) é definido como:

$$\hat{y}_{t+1} = f(\mathbf{x}_t), \quad (4.1)$$

no caso determinístico, e como a estimação de quantis condicionais no caso probabilístico:

$$\hat{Q}_\tau(y_{t+1} | \mathbf{x}_t) = f_\tau(\mathbf{x}_t), \quad (4.2)$$

onde $\tau \in (0, 1)$ é o nível do quantil. Estimando-se dois quantis, por exemplo $\tau_L = \alpha/2$ e $\tau_U = 1 - \alpha/2$, obtém-se um intervalo de predição nominal $(1 - \alpha)$:

$$\hat{I}_{1-\alpha}(\mathbf{x}_t) = \hat{Q}_{\tau_L}(y_{t+1} | \mathbf{x}_t), \hat{Q}_{\tau_U}(y_{t+1} | \mathbf{x}_t). \quad (4.3)$$

Essa formulação é apropriada quando a incerteza é heterogênea e potencialmente assimétrica, situação recorrente em séries FV sob regimes meteorológicos distintos.

4.3 Estrutura experimental e prevenção de vazamento de informação

Toda a estrutura experimental foi definida para assegurar reprodutibilidade e permitir uma comparação justa entre modelos. A divisão do conjunto de dados em treino, validação e teste foi realizada por amostragem aleatória em três subconjuntos (70%/15%/15%), utilizando *train_test_split* com semente fixa, conforme descrito no Capítulo 3. Nesta versão do trabalho, **não** foi adotado particionamento por blocos temporais (por dia); isto é, cada amostra horária foi particionada individualmente segundo a amostragem aleatória. Essa escolha foi mantida para preservar a comparabilidade com os experimentos já executados no pipeline implementado. A validação foi utilizada para seleção de hiperparâmetros e decisões de configuração do pipeline, enquanto o teste foi reservado para a avaliação final e reportado como resultado principal.

Ressalta-se que, por se tratar de uma série temporal, a amostragem aleatória pode introduzir viés otimista ao misturar amostras de períodos distintos entre treino e teste. Além disso, no pipeline implementado, o escalonamento das variáveis preditoras foi aplicado antes da partição, o que pode incorporar estatísticas globais do conjunto completo. Assim, os resultados devem ser interpretados à luz dessa configuração experimental. Como extensão natural, recomenda-se empregar particionamento cronológico por blocos (por dia) e ajustar as transformações estatísticas exclusivamente no conjunto de treinamento, aplicando-as de forma consistente aos subconjuntos de validação e teste.

4.4 Modelos determinísticos de referência

Antes de apresentar o modelo probabilístico, foram estabelecidas linhas de base determinísticas (*baselines*), necessárias para: (i) contextualizar ganhos do modelo proposto, (ii) verificar

consistência de dados e pré-processamento, e (iii) oferecer um comparativo compatível com práticas típicas de previsão FV (INMAN; PEDRO; COIMBRA, 2013).

Foram considerados como referência:

- **Persistência (baseline):** $\hat{y}_{t+1} = y_t$, uma referência simples e frequentemente surpreendentemente competitiva em horizontes curtos.
- **Modelo orientado por dados (baseline):** um modelo determinístico baseado em árvores/boosting, ajustado para minimizar erro quadrático ou absoluto, servindo como comparação direta com a versão quantílica.

A persistência é particularmente útil porque revela rapidamente se um modelo mais complexo está de fato capturando informação meteorológica e temporal, ou apenas reproduzindo a inércia natural do processo.

4.5 Modelo híbrido MLP/XGBoost com seleção por radiação

Além dos modelos de referência, foi desenvolvido um modelo híbrido que combina dois algoritmos complementares: *Multilayer Perceptron* (MLP) e XGBoost, com seleção automática baseada no nível de radiação.

4.5.1 Motivação

A hipótese subjacente é que diferentes algoritmos podem apresentar vantagens em diferentes regimes de operação:

- **XGBoost:** tende a capturar bem padrões em condições de baixa radiação, onde a variabilidade é maior e as relações entre variáveis podem ser mais complexas;
- **MLP:** apresenta bom desempenho em condições de alta radiação, onde o comportamento é mais suave e próximo de relações funcionais contínuas.

4.5.2 Estratégia de seleção (*gating*)

A escolha entre os dois modelos é feita de forma dinâmica, a partir do tercil inferior (Q_{33}) da *radiação horária* E_h (kJ/m^2), calculado **exclusivamente no conjunto de treinamento** e mantido fixo durante a validação, o teste e a aplicação operacional. Como E_h representa energia por área ao longo de uma hora, ele se relaciona à irradiância média horária G (W/m^2) por $G = E_h/3,6$.

$$\hat{y}_{t+1} = \begin{cases} f_{\text{XGBoost}}(\mathbf{x}_t), & \text{se } E_{h,t} < Q_{33} \\ f_{\text{MLP}}(\mathbf{x}_t), & \text{caso contrário} \end{cases} \quad (4.4)$$

Esse mecanismo de *gating* permite que cada algoritmo atue na região do domínio em que tende a ser mais competente, preservando a simplicidade de implantação e evitando forçar um único modelo a acomodar comportamentos estatisticamente distintos.

4.5.3 Configuração dos modelos

O MLP foi configurado com duas camadas ocultas contendo 64 e 32 neurônios, respectivamente, utilizando função de ativação ReLU nas camadas internas. O treinamento foi realizado por retropropagação, com monitoramento do desempenho no conjunto de validação e uso de *early stopping* para reduzir o risco de sobreajuste.

O XGBoost foi configurado com 300 estimadores, taxa de aprendizado de 0,05, profundidade máxima de 6 níveis por árvore, subamostragem de 90% das instâncias por árvore e subamostragem de atributos padrão. Essa configuração busca equilibrar capacidade de ajuste, generalização e custo computacional.

As configurações adotadas para MLP e XGBoost **não** foram obtidas por uma busca exaustiva de hiperparâmetros. Elas foram definidas a partir de três critérios combinados: (i) referências da literatura e práticas usuais para problemas de previsão com dados tabulares; (ii) testes preliminares empíricos no pipeline deste trabalho, observando estabilidade do treinamento e desempenho no conjunto de validação; e (iii) restrição de custo computacional compatível com a execução comparativa de múltiplos modelos. Assim, os valores apresentados devem ser interpretados como configurações técnicas razoáveis para comparação, e não como solução ótima global.

Ambos os modelos utilizam o mesmo conjunto de variáveis preditoras após o pré-processamento descrito no Capítulo 3, garantindo comparabilidade direta entre os resultados.

4.6 Previsão probabilística via regressão quantílica

Esta seção apresenta a formulação probabilística adotada no trabalho, com foco na estimação de quantis condicionais e na construção de intervalos de predição para a geração fotovoltaica. O objetivo é estabelecer, de forma objetiva, como a previsão intervalar é obtida antes da descrição do algoritmo de treinamento utilizado.

4.6.1 Perda *pinball* e estimação de quantis

A regressão quantílica estima quantis condicionais minimizando a perda *pinball*:

$$\rho_{\tau}(u) = \begin{cases} \tau u, & u \geq 0, \\ (\tau - 1)u, & u < 0, \end{cases} \quad \text{com } u = y - \hat{y}. \quad (4.5)$$

Essa função de perda é assimétrica e penaliza de forma diferente erros acima e abaixo da previsão, o que permite ajustar diretamente o quantil τ de interesse. Esse mecanismo é especialmente adequado quando o erro apresenta assimetria e variância dependente do regime, cenário comum em séries FV. Aplicações de regressão quantílica em previsão probabilística solar são discutidas e avaliadas em (LAURET; DAVID; PEDRO, 2017a; MASSIDDA; MARROCU, 2018).

4.6.2 Construção de intervalos de predição

Para um nível nominal $(1 - \alpha)$, o intervalo foi construído estimando os quantis inferior e superior:

$$\tau_L = \frac{\alpha}{2}, \quad \tau_U = 1 - \frac{\alpha}{2}. \quad (4.6)$$

Neste trabalho, foi adotado o nível de confiança de **80%** ($\alpha = 0,20$), estimando-se os quantis $\tau_L = 0,10$ e $\tau_U = 0,90$. Adicionalmente, o quantil central $\tau = 0,50$ (mediana) foi estimado para servir como previsão pontual robusta. A escolha de 80% é comum em aplicações operacionais de previsão solar, oferecendo um balanço entre cobertura adequada e intervalos informativos.

4.7 Modelo LightGBM para regressão quantílica

Uma vez definida a formulação de regressão quantílica, esta seção detalha o modelo de aprendizado de máquina empregado para estimar os quantis, bem como as decisões de treinamento e pós-processamento adotadas no experimento.

4.7.1 Justificativa

O LightGBM é uma implementação eficiente de *gradient boosting decision trees* que oferece bom desempenho em dados tabulares, com custo computacional reduzido e escalabilidade. Além disso, permite configuração direta para regressão quantílica, isto é, treinamento com a perda *pinball* para um quantil alvo. A formulação e as vantagens computacionais do LightGBM são descritas em (KE et al., 2017).

Essa escolha é coerente com a necessidade de: (i) capturar não linearidades e interações entre variáveis meteorológicas, (ii) manter viabilidade computacional para experimentação e validação, e (iii) produzir quantis de forma direta, evitando pós-processamentos complexos.

4.7.2 Configuração do treinamento

O treinamento foi realizado de forma independente para cada quantil τ , resultando em um conjunto de modelos $\{f_\tau\}$. Para cada τ avaliado, um modelo LightGBM foi ajustado com os seguintes hiperparâmetros:

Tabela 10 – Hiperparâmetros do LightGBM para regressão quantílica.

Parâmetro	Valor	Descrição
objective	quantile	Função de perda pinball
n_estimators	300	Número de árvores
learning_rate	0,05	Taxa de aprendizado
num_leaves	31	Folhas por árvore
subsample	0,9	Subamostragem por iteração
colsample_bytree	0,9	Subamostragem de features
min_child_samples	20	Mínimo de amostras por folha
random_state	42	Semente para reprodutibilidade

Fonte: Elaborado pelo autor.

Os hiperparâmetros foram selecionados por meio de uma busca controlada no conjunto de validação, com o objetivo de equilibrar desempenho e capacidade de generalização. A taxa de aprendizado relativamente baixa (0,05), combinada com um número moderado de árvores (300), visa reduzir o risco de sobreajuste, enquanto a subamostragem de 90% de instâncias por iteração introduz regularização estocástica adicional. A configuração final foi mantida constante para todos os quantis e regimes, garantindo comparabilidade entre os experimentos.

4.7.3 Consistência de quantis e cruzamento de intervalos

Ao treinar quantis separadamente, pode ocorrer o problema de *crossing*, isto é, $\hat{Q}_{\tau_L} > \hat{Q}_{\tau_U}$ em alguns pontos. Quando isso ocorreu, foi aplicada uma correção simples e documentada:

$$\hat{Q}_{\tau_L} \leftarrow \min(\hat{Q}_{\tau_L}, \hat{Q}_{\tau_U}), \quad \hat{Q}_{\tau_U} \leftarrow \max(\hat{Q}_{\tau_L}, \hat{Q}_{\tau_U}). \quad (4.7)$$

Essa etapa evita intervalos inconsistentes sem alterar a natureza dos quantis estimados.

4.7.4 Calibração pós-processamento com fator de escala

Mesmo com treinamento adequado, os intervalos de predição estimados podem apresentar cobertura empírica diferente do nível nominal. Para corrigir essa discrepância, foi adotada uma técnica de calibração pós-processamento baseada em um fator de escala λ .

O procedimento consiste em:

1. Calcular a largura original do intervalo: $w_i = \hat{Q}_{0,90}^{(i)} - \hat{Q}_{0,10}^{(i)}$
2. Ajustar a largura pelo fator de escala: $w'_i = \lambda \cdot w_i$

3. Reconstruir o intervalo calibrado, centrado na mediana:

$$\hat{Q}_{0,10}^{\text{cal}} = \hat{Q}_{0,50} - \frac{\hat{w}'}{2}, \quad \hat{Q}_{0,90}^{\text{cal}} = \hat{Q}_{0,50} + \frac{\hat{w}'}{2} \quad (4.8)$$

O fator λ foi otimizado no **conjunto de validação** para aproximar o PICP empírico do nível nominal de 80%. Se $\lambda > 1$, os intervalos são “esticados” (aumentam a cobertura); se $\lambda < 1$, são “comprimidos”.

Trata-se de um pós-processamento simples por ajuste de escala da largura do intervalo, mantendo a mediana como centro. A calibração atua apenas sobre a amplitude do intervalo, facilitando a interpretação operacional. O valor de λ encontrado foi **1,169**, indicando que os intervalos originais eram ligeiramente subcobertos (PICP original $\approx 74,7\%$) e precisaram ser expandidos em aproximadamente 17% para atingir a cobertura nominal.

4.8 Estratificação por regimes de radiação

Esta seção descreve a estratégia de segmentação do problema em regimes de radiação, utilizada para tratar a heterogeneidade da incerteza ao longo do domínio de operação. São apresentados o critério de definição dos regimes e o procedimento de treinamento específico por regime.

4.8.1 Motivação

Em previsão FV, a incerteza não é homogênea ao longo do domínio de operação. Períodos de céu estável tendem a apresentar menor variância do erro, enquanto condições de céu parcialmente nublado frequentemente concentram maior variabilidade e maior dificuldade preditiva. Essa heterogeneidade afeta diretamente a qualidade dos intervalos de predição: intervalos globais podem ficar estreitos demais em regimes altamente variáveis (subcobertura) ou largos demais em regimes estáveis (baixa nitidez).

O princípio de avaliação por calibração e nitidez motiva o tratamento explícito dessa heterogeneidade (GNEITING; BALABDAOUI; RAFTERY, 2007). Assim, além do modelo global, foi adotada uma estratégia de estratificação por regimes.

4.8.2 Definição dos regimes

Os regimes foram definidos a partir da **radiação global horizontal horária** E_h (kJ/m^2), disponível no conjunto de dados como *Radiação (kJ/m^2)*. A origem dessa variável e a conversão a partir do atributo *shortwave_radiation* do Open-Meteo são descritas no Capítulo 3. Os limiares foram obtidos pelos **tercis calculados exclusivamente no conjunto de treinamento** e, em seguida, mantidos fixos para validação, teste e uso operacional, evitando vazamento de informação do conjunto de teste.

Os limiares calculados foram:

- Q_{33} : 784,8 kJ/m² (≈ 218 W/m²)
- Q_{67} : 1.954,8 kJ/m² (≈ 543 W/m²)

Resultando em três regimes:

- **Baixa radiação** ($E_h < Q_{33}$): condições predominantemente nubladas, com geração reduzida;
- **Radiação intermediária** ($Q_{33} \leq E_h < Q_{67}$): maior variabilidade, típica de céu parcialmente nublado;
- **Alta radiação** ($E_h \geq Q_{67}$): condições próximas a céu aberto, com geração elevada e mais estável.

A estratificação foi aplicada somente ao período diurno, conforme Capítulo 3. No conjunto de treinamento, cada regime contém aproximadamente 33% das amostras, garantindo dados suficientes para ajuste de modelos específicos.

4.8.3 Treinamento por regime

Para cada regime r , foi ajustado um conjunto de modelos quantílicos $\{f_r^{(r)}\}$, treinado apenas com amostras pertencentes ao regime. Em inferência, a amostra $\mathbf{x}_t$ é primeiramente classificada no regime correspondente, e então os quantis são estimados pelo modelo daquele regime.

Essa estratégia tem um custo adicional (múltiplos modelos), porém tende a melhorar coerência dos intervalos em regiões do domínio onde a variância do erro é significativamente diferente.

4.9 Métricas de avaliação

Esta seção descreve, em termos operacionais, as métricas adotadas para comparar os modelos no experimento. A fundamentação conceitual e as definições matemáticas das métricas já discutidas no Capítulo 2 não são repetidas em detalhe aqui. O foco, nesta etapa, é explicitar quais métricas foram utilizadas e como elas foram interpretadas na avaliação final.

A avaliação foi dividida em duas dimensões: desempenho determinístico (pontual) e desempenho probabilístico.

4.9.1 Métricas determinísticas

Foram utilizadas as métricas **MAE**, **RMSE** e R^2 para avaliação pontual, de forma consistente com a literatura de previsão de geração solar e com os experimentos comparativos deste trabalho.

No caso probabilístico, a mediana $\hat{Q}_{0.5}$ foi adotada como previsão central para comparação pontual, por ser um estimador robusto.

4.9.2 Métricas probabilísticas (intervalos de predição)

A qualidade dos intervalos de predição foi avaliada pelas métricas **PICP** (*Prediction Interval Coverage Probability*) e **PINAW** (*Prediction Interval Normalized Average Width*), amplamente utilizadas na literatura de *prediction intervals* (KHOSRAVI et al., 2011).

No experimento, o PICP foi comparado ao nível nominal de 80%, enquanto o PINAW foi utilizado para quantificar a largura média normalizada dos intervalos. A interpretação seguiu o princípio de calibração e nitidez discutido por Gneiting et al. (GNEITING; BALABDAOUI; RAFTERY, 2007): busca-se cobertura próxima ao nível nominal e, entre modelos com cobertura adequada, menor largura intervalar.

4.9.3 Avaliação por regime

Além da avaliação global, as métricas determinísticas e probabilísticas foram computadas separadamente por regime de radiação. Essa etapa é importante porque métricas agregadas podem mascarar desempenhos muito diferentes em regiões do domínio. Em particular, espera-se que regimes intermediários apresentem maior complexidade preditiva, e a análise por regime ajuda a verificar se a estratificação melhora a qualidade probabilística nesses casos.

4.10 Procedimento final do experimento

O procedimento experimental completo seguiu os passos:

1. Preparar a base com pré-processamento e seleção VIF (Capítulo 3);
2. Definir divisão aleatória treino (70%) / validação (15%) / teste (15%), com semente fixa para reprodutibilidade;
3. Treinar baselines determinísticos: persistência e modelo híbrido MLP/XGBoost;
4. Definir limiares de regime por tercís (Q_{33}/Q_{67}) no conjunto de treinamento;
5. Treinar LightGBM quantílico por regime para os quantis 0,10, 0,50 e 0,90;
6. Otimizar fator de calibração λ no conjunto de validação (alvo: PICP $\approx$ 80%);

7. Avaliar desempenho determinístico (MAE, RMSE, R^2) e probabilístico (PICP, PINAW) no teste;
8. Reportar métricas globais e estratificadas por regime;
9. Comparar resultados e discutir trade-offs entre calibração e nitidez.

A metodologia foi desenhada para ser reprodutível, com decisões documentadas e avaliação alinhada à literatura clássica de previsão solar (INMAN; PEDRO; COIMBRA, 2013) e às boas práticas de previsão probabilística (GNEITING; BALABDAOUI; RAFTERY, 2007; GNEITING; KATZFUSS, 2014).

4.10.1 Considerações sobre particionamento e vazamento

Embora o particionamento 70%/15%/15% com semente fixa assegure reprodutibilidade, o uso de amostragem aleatória em uma série temporal pode reduzir a dificuldade do teste, ao permitir que padrões de diferentes períodos estejam presentes simultaneamente em treino e avaliação. Além disso, na implementação utilizada, o escalonamento das variáveis preditoras é aplicado antes da divisão, o que pode incorporar estatísticas globais do conjunto completo e levar a estimativas de desempenho levemente otimistas. Por transparência, tais aspectos devem ser interpretados como limitações do desenho experimental. Em estudos futuros, recomenda-se: (i) particionamento cronológico por blocos (preferencialmente por dia), e (ii) ajuste do escalonamento exclusivamente no treinamento, com aplicação consistente em validação e teste.

4.11 Resumo do capítulo

Este capítulo apresentou a metodologia adotada para previsão horária de geração FV, incluindo:

- Modelos determinísticos de referência (persistência e híbrido MLP/XGBoost);
- Construção de previsões probabilísticas por regressão quantílica com LightGBM (KE et al., 2017);
- Estimação de quantis 0,10, 0,50 e 0,90 para intervalos de 80%;
- Estratificação por regimes de radiação definidos por tercis (Q_{33}/Q_{67});
- Calibração pós-processamento com fator de escala $\lambda = 1,169$;
- Critérios de avaliação determinísticos (MAE, RMSE, R^2) e probabilísticos (PICP, PINAW).

As métricas probabilísticas foram escolhidas com base em revisões de intervalos de predição (KHOSRAVI et al., 2011) e interpretadas à luz do princípio de calibração e nitidez (GNEITING; BALABDAOUI; RAFTERY, 2007). O próximo capítulo apresenta os resultados e as discussões correspondentes.

5 RESULTADOS E DISCUSSÕES

5.1 Visão geral dos experimentos e organização dos resultados

Este capítulo apresenta os resultados obtidos a partir da metodologia descrita no Capítulo 4. A discussão foi organizada em duas camadas, pois elas respondem a perguntas diferentes e complementares. Primeiro, analisa-se o desempenho *determinístico* (pontual), a fim de verificar se o modelo captura adequadamente a dinâmica média da geração fotovoltaica (FV). Em seguida, aprofunda-se a avaliação *probabilística*, com ênfase em calibração e nitidez dos intervalos de predição, seguindo os princípios propostos por Gneiting et al. (GNEITING; BALABDAOUI; RAFTERY, 2007) e discutidos de forma mais ampla por Gneiting e Katzfuss (GNEITING; KATZFUSS, 2014).

Além da avaliação global, os resultados são apresentados por regimes de radiação, uma vez que a incerteza na geração FV não é homogênea ao longo do domínio. Essa escolha evita conclusões excessivamente agregadas e permite avaliar se a estratificação proposta melhora a qualidade probabilística em regimes tipicamente mais desafiadores.

5.2 Configuração final e critérios de comparação

5.2.1 Modelos avaliados

Foram comparados os seguintes modelos:

- **Persistência** (baseline): $\hat{y}_{t+1} = y_t$;
- **Híbrido determinístico (MLP+XGBoost)**: modelo ajustado para previsão pontual;
- **LightGBM quantílico global**: estimação de quantis condicionais com LightGBM (KE et al., 2017);
- **LightGBM quantílico por regime**: conjunto de modelos quantílicos treinados separadamente por regime.

Para fins de legibilidade, algumas figuras deste capítulo destacam apenas comparações essenciais (por exemplo, *baseline* de persistência versus a mediana do modelo quantílico por regime), evitando excesso de curvas/barras no mesmo gráfico. O desempenho do modelo híbrido (MLP+XGBoost) é reportado nas Tabelas 11 e 12, e também é utilizado na demonstração operacional D+1 (Seção 5.5.3).

Quando pertinente, a mediana $\hat{Q}_{0.5}$ do modelo quantílico foi utilizada como previsão central, permitindo comparação pontual coerente entre abordagens determinísticas e probabilísticas.

5.2.2 Métricas reportadas

A avaliação determinística utilizou MAE, RMSE e R^2 , enquanto a avaliação probabilística utilizou principalmente PICP e PINAW, conforme práticas consolidadas em avaliação de intervalos de predição (KHOSRAVI et al., 2011). A interpretação conjunta (cobertura versus largura) segue o princípio calibração–nitidez (GNEITING; BALABDAOUI; RAFTERY, 2007).

Os valores apresentados nas Tabelas e Figuras correspondem a métricas *agregadas* sobre todas as amostras do conjunto de teste. Não se reporta desvio padrão entre múltiplas execuções, pois o protocolo experimental adotou uma única partição treino/validação/teste e configurações fixas de treinamento. A quantificação de incerteza estatística dessas métricas (por exemplo, via múltiplas sementes, validação temporal repetida ou *bootstrap* por dias) é uma extensão possível, mas não foi considerada no escopo deste estudo.

5.2.3 Níveis de confiança e regimes

Os intervalos de predição foram avaliados para o nível de **80%**, correspondente aos quantis 0,10 e 0,90. Os regimes de radiação foram definidos conforme descrito no Capítulo 4: **baixa** (Radiação $< 785 \text{ kJ/m}^2$), **intermediária** ($785 \leq \text{Radiação} < 1955 \text{ kJ/m}^2$) e **alta** (Radiação $\geq 1955 \text{ kJ/m}^2$). Os limiares (785 e 1955 kJ/m^2) correspondem aos quantis Q33 e Q67 estimados no conjunto de treinamento, conforme o procedimento descrito no Capítulo 4.

5.3 Resultados determinísticos (previsão pontual)

5.3.1 Desempenho global no conjunto de teste

A Tabela 11 apresenta o desempenho determinístico global no conjunto de teste. Esse resultado é importante por dois motivos. Primeiro, estabelece uma referência clara de desempenho em termos de erro médio. Segundo, ajuda a interpretar o comportamento probabilístico: um modelo pode fornecer bons intervalos, mas se a previsão central for sistematicamente enviesada, os intervalos tenderão a se deslocar e a calibração pode ser afetada.

Tabela 11 – Desempenho determinístico global no conjunto de teste.

Modelo	MAE (Wh)	RMSE (Wh)	R^2
Persistência	1004	1242	0,67
Quantílico (mediana) – Por regime	726	1062	0,76
Híbrido (MLP+XGBoost)	763	1070	0,73

Do ponto de vista qualitativo, é esperado que a persistência apresente desempenho razoável em horizontes curtos, especialmente em condições de céu estável, mas tenda a falhar em períodos de rápida mudança de irradiância. Modelos orientados por dados costumam superar a persistência ao incorporar variáveis meteorológicas, desde que a qualidade e o alinhamento temporal dessas variáveis sejam adequados (INMAN; PEDRO; COIMBRA, 2013).

Os resultados confirmam essa expectativa: o modelo quantílico apresentou redução de **27,7%** no MAE (de 1004 para 726 Wh) e **14,5%** no RMSE (de 1242 para 1062 Wh) em relação à persistência. O coeficiente de determinação (R^2) também melhorou de 0,67 para 0,76, indicando que o modelo captura aproximadamente 76% da variabilidade da geração FV.

5.3.2 Análise por regimes: onde o erro realmente se concentra

A Tabela 12 apresenta os resultados determinísticos por regime. Essa análise é particularmente reveladora, pois regimes intermediários de irradiância tipicamente concentram maior variabilidade e tendem a produzir maiores erros. Regimes de alta radiação (céu mais aberto) geralmente são mais previsíveis, enquanto regimes de baixa radiação podem ser “fáceis” em termos de média, mas ainda carregam episódios com oscilação relevante.

Tabela 12 – Desempenho determinístico por regime de irradiância no conjunto de teste.

Regime	Modelo	MAE (Wh)	RMSE (Wh)	R^2
Baixa	Persistência	686	887	0,14
Baixa	Quantílico (mediana) – Por regime	335	576	0,64
Baixa	Híbrido (MLP+XGBoost)	495	732	0,54
Intermediária	Persistência	1286	1464	0,18
Intermediária	Quantílico (mediana) – Por regime	843	1176	0,47
Intermediária	Híbrido (MLP+XGBoost)	854	1173	0,49
Alta	Persistência	1032	1288	0,19
Alta	Quantílico (mediana) – Por regime	939	1244	0,24
Alta	Híbrido (MLP+XGBoost)	888	1189	0,25

Uma interpretação importante aqui é separar duas coisas: (i) ganho absoluto em erro, e (ii) comportamento relativo entre regimes. Mesmo que o ganho em MAE/RMSE não seja uniforme, o comportamento por regime costuma indicar se o modelo está aprendendo a dinâmica meteorológica ou apenas refinando a persistência.

A análise revela padrões importantes. No regime de **baixa radiação**, o modelo apresentou ganho expressivo: redução de 51% no MAE (de 686 para 335 Wh) e 35% no RMSE (de 887 para 576 Wh), com R^2 saltando de 0,14 para 0,64. Isso indica que, em condições de baixa radiação, o modelo consegue capturar informações que a simples persistência não consegue.

No regime **intermediário**, os ganhos foram moderados: redução de 34% no MAE e 20% no RMSE. Esse regime é tipicamente o mais desafiador devido à alta variabilidade causada por passagens intermitentes de nuvens, o que justifica erros absolutos maiores.

No regime de **alta radiação**, os ganhos foram modestos: apenas 9% de redução no MAE e 3% no RMSE. Isso era esperado, pois em condições de céu limpo a persistência já é um preditor razoável, e o modelo tem pouca margem para melhoria.

A Figura 16 ilustra visualmente essa comparação, destacando o ganho mais expressivo no regime de baixa radiação.




Figura 16 – Comparação entre MAE e RMSE por regime de irradiância.

5.3.3 Inspeção visual: exemplos de séries temporais

Além de métricas agregadas, é recomendável observar a série temporal prevista versus observada, principalmente em dias representativos de cada regime. A Figura 17 apresenta uma janela temporal curta (um dia) de alta radiação, permitindo visualizar: (i) a capacidade do modelo em acompanhar rampas de geração, (ii) possíveis atrasos/adiantamentos temporais, e (iii) episódios de subestimação ou superestimação persistente.




Figura 17 – Série temporal: observado vs. mediana prevista (dia representativo).

Esse exemplo foi intencionalmente escolhido em **alta radiação** para facilitar a leitura da aderência entre curva observada e previsão central. Por outro lado, trata-se de um caso relativamente mais regular do que dias com forte variabilidade de nuvens. Assim, a interpretação da Figura 17 deve ser feita como *exemplo ilustrativo*, e não como caso mais desafiador do conjunto de teste. Para fortalecer a análise visual, a versão final pode incluir um segundo dia representativo de **céu parcialmente nublado/alta variabilidade**, permitindo comparar de forma direta como o erro aumenta quando há rampas abruptas de geração.

5.3.4 Diagnóstico do erro horário em um dia representativo

Além das métricas agregadas, a inspeção do erro ao longo do dia é útil para identificar padrões sistemáticos, como viés dependente do horário e dificuldades do modelo em capturar rampas de geração. Para um dia representativo do conjunto de teste, analisou-se o erro horário definido por

$$e(t) = y(t) - \hat{y}_{0.50}(t), \quad (5.1)$$

em que $y(t)$ é a geração observada e $\hat{y}_{0.50}(t)$ é a previsão central (mediana, q50). Valores negativos indicam superestimação (previsão acima do observado), enquanto valores positivos indicam subestimação.

A Figura 18 mostra que o erro varia ao longo do período diurno (mediana, q50), com maiores magnitudes nas horas centrais, quando a geração tende a ser mais elevada e a variabilidade atmosférica pode induzir rampas mais rápidas. Observa-se também mudança de sinal em parte do dia, sugerindo que o viés não é constante e pode depender das condições meteorológicas e do nível de irradiância. Esse diagnóstico reforça a importância de avaliar o desempenho de forma complementar às métricas globais, pois erros horários concentrados em janelas específicas podem afetar aplicações operacionais (por exemplo, planejamento de despacho e gestão de risco).

Na Figura 18, valores negativos indicam **superestimação** e valores positivos indicam **subestimação**; a linha em zero representa erro nulo.




Figura 18 – Erro horário (observado – previsto) em um dia representativo.

5.4 Resultados probabilísticos: calibração e nitidez

5.4.1 Cobertura (PICP) e largura (PINAW) no conjunto de teste

A avaliação probabilística é o núcleo desta dissertação. Intervalos de predição são úteis quando são simultaneamente bem calibrados, isto é, quando apresentam cobertura próxima

do nível nominal desejado, e suficientemente nítidos, ou seja, quando não são excessivamente largos. Esse equilíbrio sintetiza o princípio de calibração e nitidez (GNEITING; BALABDAOUI; RAFTERY, 2007).

A Tabela 13 apresenta os valores de PICP e PINAW no conjunto de teste para o intervalo de 80% de confiança, comparando o modelo quantílico global com o modelo quantílico por regime, antes e depois da calibração.

Tabela 13 – Avaliação probabilística global no conjunto de teste (PICP e PINAW).

Modelo	Nível	PICP	PINAW	Observação
Quantílico – Global (sem regimes)	80%	0,737	0,297	Subcoberto
Quantílico – Por regime (original)	80%	0,747	0,261	Subcoberto
Quantílico – Por regime (calibrado)	80%	0,793	0,306	Bem calibrado

O modelo quantílico global (sem estratificação) apresentou PICP de 0,737, significativamente abaixo do alvo de 80%, com PINAW de 0,297. A estratificação por regimes elevou a cobertura para 0,747 e reduziu a largura para 0,261, mostrando que tratar explicitamente a heterogeneidade da incerteza melhora a qualidade dos intervalos mesmo antes da calibração. Após a aplicação do fator de calibração $\lambda = 1,169$, o modelo por regime passou a apresentar PICP de 0,793, muito próximo do nível nominal de 80%, com PINAW de 0,306. O aumento de cerca de 17% na largura dos intervalos, em relação ao modelo por regime não calibrado, representa um trade-off aceitável para garantir a confiabilidade das previsões, com melhoria total de 5,6 pontos percentuais em cobertura em comparação com o modelo global.

A Figura 19 ilustra o efeito da calibração sobre as métricas probabilísticas. Após o pós-processamento de calibração (fator $\lambda = 1,169$), a cobertura aumentou de 74,7% para 79,3%, aproximando-se do alvo de 80%, ao custo de um aumento de 17% na largura dos intervalos.




Figura 19 – Efeito da calibração pós-processamento sobre PICP e PINAW.

5.4.2 Análise por regimes: calibração localizada

A análise por regimes é o teste mais relevante da hipótese do trabalho, isto é, de que a incerteza varia por condição de radiação e que um tratamento explícito por regime pode melhorar resultados. A Tabela 14 apresenta PICP e PINAW por regime.

Tabela 14 – Avaliação probabilística por regime de irradiância no conjunto de teste (calibrado).

Regime	Nível	PICP	PINAW	Comentário
Baixa	80%	0,794	0,179	Intervalos mais estreitos
Intermediária	80%	0,797	0,360	Maior incerteza
Alta	80%	0,789	0,387	Variabilidade residual

Uma leitura típica é:

- Se o modelo global apresentar **subcobertura** no regime intermediário, isso sugere que a variabilidade local do erro é maior do que o modelo consegue representar de forma global.
- Se o modelo por regime aumentar PICP nesse regime, sem inflar excessivamente PINAW, isso sustenta a contribuição do trabalho.
- Se o modelo por regime aumentar cobertura à custa de intervalos muito largos, a discussão deve reconhecer esse trade-off, pois a melhora pode ser conservadora demais.

A análise por regime revela um padrão coerente com a teoria. O regime de **baixa radiação** apresentou PINAW de apenas 0,179, o menor entre os três regimes, indicando que os intervalos são relativamente estreitos quando a geração é baixa. Isso faz sentido físico: em condições de pouca radiação, a variabilidade absoluta da geração também é menor.

O regime **intermediário** apresentou PINAW de 0,360, o segundo maior, refletindo a maior incerteza típica de condições de céu parcialmente nublado. Ainda assim, a cobertura (PICP = 0,797) manteve-se adequada, demonstrando que a estratificação permite calibrar intervalos específicos para cada regime.

O regime de **alta radiação** apresentou o maior PINAW (0,387), sugerindo maior variabilidade residual mesmo em condições aparentemente estáveis. Isso pode ser atribuído a eventos convectivos localizados que ocorrem mesmo em dias predominantemente ensolarados, característica típica do clima tropical amazônico.

A Figura 20 ilustra visualmente essa análise, destacando a cobertura próxima ao alvo de 80% em todos os regimes e a variação do PINAW conforme a condição de radiação.

Esses pontos se conectam diretamente ao princípio de calibração e nitidez (GNEITING; BALABDAOUI; RAFTERY, 2007) e à motivação de previsões probabilísticas em aplicações reais (GNEITING; KATZFUSS, 2014).




Figura 20 – PICP e PINAW por regime de irradiância.

5.4.3 Visualização de intervalos: exemplos interpretáveis

Além das tabelas, a inspeção visual dos intervalos de predição é importante para verificar *como* o modelo representa a incerteza ao longo do tempo. A Figura 21 apresenta um recorte diário com: (i) série observada, (ii) previsão central (mediana) e (iii) banda do intervalo de 80% (quantis 0,10 e 0,90).




Figura 21 – Intervalos de predição (80%) para um dia representativo do conjunto de teste.

Na leitura da Figura 21, observa-se que os intervalos:

- permanecem relativamente estreitos em condições mais estáveis;
- se alargam quando há maior incerteza meteorológica;
- mantêm boa cobertura sem perder completamente a utilidade informacional.

Essas propriedades são consistentes com o comportamento esperado de um modelo probabilístico calibrado e nítido (GNEITING; BALABDAOUI; RAFTERY, 2007).

Como limitação desta apresentação visual, foi mostrado apenas um recorte diário. Para tornar a evidência mais robusta, é recomendável incluir na versão final: (a) um exemplo adicional com **forte variabilidade de nuvens/sombreamento** (caso mais difícil de prever) e (b) uma figura em escala **mensal**, com observação, mediana e banda de 80%, para evidenciar a estabilidade da calibração ao longo de vários dias consecutivos. Essas duas visualizações complementam o exemplo diário e respondem melhor à análise qualitativa do comportamento temporal dos intervalos.

5.5 Discussão: implicações, limitações e comparação com a literatura

5.5.1 O que os resultados indicam, de forma objetiva

A contribuição prática do trabalho deve ser discutida com clareza: se a estratificação por regimes melhora (ou não) a calibração em regimes críticos, isso é uma informação relevante. Do ponto de vista de método, o uso de LightGBM quantílico é coerente com a literatura aplicada em previsão probabilística solar (LAURET; DAVID; PEDRO, 2017a; MASSIDDA; MARROCU, 2018), e com a necessidade de eficiência computacional para experimentos extensivos (KE et al., 2017).

Além disso, o resultado deve ser interpretado à luz de revisões do tema: a literatura de previsão solar destaca que o regime atmosférico influencia fortemente erro e incerteza (INMAN; PEDRO; COIMBRA, 2013), e revisões de integração de previsões probabilísticas em sistemas elétricos enfatizam ganhos na tomada de decisão sob risco (LI; ZHANG, 2020).

5.5.2 Limitações e possíveis fontes de viés

Como toda aplicação com dados reais, alguns fatores podem limitar a generalização:

- **Qualidade e completude de variáveis meteorológicas:** falhas ou baixa resolução podem reduzir a capacidade de antecipar mudanças rápidas.
- **Escolha do critério de regimes:** limiares muito arbitrários podem criar regimes pouco estáveis e reduzir o benefício da estratificação.
- **Cruzamento de quantis:** ainda que raro, pode ocorrer e precisa ser tratado de forma documentada.
- **Dependência do local:** comportamento de irradiância em clima tropical úmido pode diferir de regiões temperadas, o que reforça a necessidade de análise contextual.

Explicitar essas limitações não enfraquece o trabalho; ao contrário, demonstra domínio metodológico e cuidado científico.

5.5.3 Aplicação operacional (D+1): ponto + intervalo calibrado + checagem de domínio

Além da avaliação retrospectiva no conjunto de teste, foi implementado um procedimento de *inferência operacional* para prever a geração horária do dia seguinte (D+1) a partir de previsões meteorológicas (ex.: Open-Meteo), mantendo coerência com o protocolo de treinamento (padronização com parâmetros do treino e *features* consistentes). O ponto previsto é obtido pelo modelo híbrido (MLP+XGBoost), enquanto o intervalo é construído a partir do modelo quantílico (LightGBM), tomando a mediana como centro e aplicando uma calibração pós-processamento por fator de escala λ na largura do intervalo, ajustado no conjunto de validação para aproximar a cobertura nominal.

Para reduzir o risco de extrapolação silenciosa, adicionou-se uma checagem simples de domínio: cada *feature* prevista é comparada com um envelope estatístico derivado do treino (por exemplo, percentis extremos), e o sistema sinaliza quando a entrada está fora da faixa observada durante o ajuste. Essa checagem não “garante” acerto, mas funciona como um indicador prático de confiabilidade relativa do cenário meteorológico usado como entrada.

A Figura 22 ilustra um exemplo de curva D+1 com ponto e intervalo operacional.




Figura 22 – Previsão operacional D+1: híbrido e intervalo quantílico calibrado.

5.5.4 Comparação com uma baseline de média histórica

Um ponto importante para reforçar a contribuição prática do trabalho é a comparação com uma baseline simples baseada em **média histórica** (ou climatologia local), por exemplo, a média da geração para o mesmo horário em uma janela temporal comparável. Essa referência é útil porque representa um método de baixo custo computacional e fornece um patamar adicional de comparação além da persistência.

No presente capítulo, a comparação principal foi realizada contra persistência, modelo híbrido (MLP+XGBoost) e modelo quantílico global/por regime, o que já permite demonstrar ganhos determinísticos e probabilísticos. Entretanto, incluir a baseline de média histórica fortaleceria a discussão, especialmente para destacar em quais condições o modelo proposto supera estratégias estatísticas mais simples em clima tropical úmido.

Para essa comparação adicional, recomenda-se reportar, no mínimo, MAE e RMSE (previsão pontual da média histórica) e, se aplicável, comparar também a posição dessa baseline em relação aos intervalos probabilísticos propostos. Uma análise por regime (baixa, intermediária e alta radiação) também seria desejável, pois pode revelar se a média histórica é competitiva apenas em regimes mais estáveis.

5.5.5 Síntese do trade-off calibração–nitidez

A discussão final deste capítulo pode ser sintetizada pelo trade-off observado entre calibração e nitidez:

- Se o método atingiu PICP próximo do nominal com PINAW reduzido, o resultado é forte e diretamente alinhado aos princípios de (GNEITING; BALABDAOUI; RAFTERY, 2007).
- Se a melhoria de PICP exigiu aumento de PINAW, a discussão deve caracterizar o nível de conservadorismo e sua aceitabilidade prática, remetendo às métricas e interpretações discutidas em (KHOSRAVI et al., 2011).

No presente estudo, o modelo atingiu PICP de 0,793 (próximo do nominal de 80%) com PINAW de 0,306. Para contextualizar, um PINAW de 0,306 significa que a largura média dos intervalos corresponde a aproximadamente 30,6% da amplitude total da variável resposta (8168 Wh). Em termos absolutos, os intervalos têm largura média de cerca de 2500 Wh, o que representa aproximadamente 87% da produção média horária (2870 Wh).

Esse resultado representa um compromisso adequado entre calibração e nitidez. Os intervalos são informativos o suficiente para auxiliar na tomada de decisão operacional, ao mesmo tempo em que mantêm cobertura confiável. A estratificação por regimes contribuiu para esse equilíbrio, permitindo intervalos mais estreitos em condições de baixa incerteza (regime baixo) e mais largos quando necessário (regimes intermediário e alto).

5.6 Resumo do capítulo

Este capítulo apresentou os resultados globais e por regimes, comparando baselines determinísticos, modelo quantílico global e modelo quantílico por regime. A análise determinística permitiu verificar aderência da previsão central, enquanto a avaliação probabilística discutiu calibração e nitidez dos intervalos, com métricas PICP e PINAW (KHOSRAVI et al., 2011) interpretadas à luz do princípio calibração–nitidez (GNEITING; BALABDAOUI; RAFTERY, 2007). Os resultados por regime fornecem o principal subsídio para avaliar a contribuição metodológica proposta, preparando o caminho para as conclusões apresentadas no Capítulo 6.

5.6.1 Análise visual de dispersão

A Figura 23 apresenta o gráfico de dispersão entre valores observados e previstos (mediana), coloridos por regime de irradiância. A proximidade dos pontos à linha de identidade (diagonal) indica boa aderência do modelo, especialmente no regime de baixa radiação.




Figura 23 – Dispersão entre valores observados e previstos (mediana) no conjunto de teste.

5.6.2 Distribuição de erros por regime

A Figura 24 mostra a distribuição dos erros (observado e previsto) para cada regime. O erro médio é próximo de zero em todos os regimes, com viés ligeiramente negativo no regime de alta radiação (média de 462 Wh), indicando leve superestimação do modelo nessas condições.




Figura 24 – Distribuição de erros (observado – previsto) por regime de irradiância.

5.6.2.1 Análise crítica do viés no regime de alta radiação

Embora as distribuições de erro apresentem características adequadas na maioria dos regimes, o viés de 462 Wh observado no regime de alta radiação merece atenção. Esse valor representa aproximadamente 9,2% da produção média esperada nesse regime (~5000 Wh), indicando que o modelo tende a **superestimar** a geração quando a irradiância é elevada.

Possíveis explicações para esse comportamento incluem:

- **Perdas térmicas não capturadas:** em condições de alta radiação, a temperatura dos módulos aumenta significativamente, reduzindo a eficiência de conversão. Os dados Open-Meteo podem não capturar completamente esse efeito localizado;
- **Eventos convectivos rápidos:** mesmo em dias predominantemente ensolarados, o clima tropical amazônico apresenta formação de nuvens convectivas localizadas que reduzem temporariamente a geração. Esses eventos são difíceis de prever com resolução horária;
- **Limitação da resolução temporal:** dados horários agregam informação de 60 minutos, mascarando variações de curta duração (poucos minutos) típicas de passagens de nuvens.

É importante notar que, embora o viés seja estatisticamente significativo, ele não compromete a utilidade operacional dos intervalos de predição. O PICP no regime de alta radiação (0,789) permanece próximo do nominal, indicando que os intervalos ainda capturam adequadamente a variabilidade, mesmo com deslocamento sistemático da mediana. Em aplicações práticas, esse viés poderia ser corrigido por um ajuste linear simples calibrado no conjunto de validação, sem necessidade de retrainar o modelo completo.

Essa análise evidencia uma limitação inerente ao uso de dados de reanálise meteorológica para previsão fotovoltaica em escala local: fenômenos de microescala (sombreamento parcial, efeitos de borda de nuvens, variações térmicas localizadas) não são completamente representados pelos modelos numéricos globais. Trabalhos futuros poderiam investigar a integração de imagens de satélite de alta resolução temporal ou medições in-loco de temperatura do módulo para mitigar esse viés.

6 CONCLUSÕES

6.1 Síntese do problema e da abordagem

Esta dissertação tratou do problema de previsão horária de geração fotovoltaica (FV) em Tucuruí, Pará, região caracterizada por clima equatorial com alta variabilidade de irradiância. O foco foi não apenas estimar uma previsão pontual, mas também representar explicitamente a incerteza do processo por meio de previsões probabilísticas. Essa escolha é coerente com o entendimento contemporâneo de previsão probabilística, no qual a qualidade deve ser avaliada em termos de calibração e nitidez (*sharpness*), e não apenas por métricas determinísticas tradicionais (GNEITING; BALABDAOUI; RAFTERY, 2007; GNEITING; KATZFUSS, 2014).

Do ponto de vista metodológico, o trabalho foi estruturado em torno de regressão quantílica utilizando LightGBM como modelo base, pela sua capacidade de capturar não linearidades em dados tabulares com eficiência computacional (KE et al., 2017). Além disso, considerou-se explicitamente a heterogeneidade de incerteza ao longo do domínio de operação, propondo uma estratificação por regimes de radiação para melhorar o comportamento probabilístico, especialmente em condições meteorológicas mais instáveis.

6.2 Principais contribuições

As contribuições desta dissertação podem ser agrupadas em três eixos principais. Em primeiro lugar, foi construído um pipeline reproduzível de previsão horária da geração fotovoltaica em clima tropical úmido, integrando dados de reanálise meteorológica e medições reais de um sistema de 10,08 kWp em Tucuruí-PA. Esse pipeline explicita decisões relevantes, como filtragem do período diurno, tratamento de valores ausentes, análise de multicolinearidade via VIF e divisão treino, validação e teste por amostragem aleatória (70/15/15), com semente fixa; em séries temporais, essa opção pode induzir viés otimista, sendo recomendável a validação cronológica por blocos como extensão. No âmbito determinístico, esse pipeline inclui a implementação de um modelo híbrido MLP/XGBoost com seleção por regimes de radiação, que serve como linha de base mais robusta do que a persistência para avaliar os ganhos dos modelos probabilísticos. Em segundo lugar, incorporou-se explicitamente a heterogeneidade da incerteza por meio da estratificação em regimes de radiação definidos a partir dos tercis da distribuição de radiação horária (kJ/m^2), equivalente à irradiância média horária via divisão por 3,6. Mostrou-se empiricamente que essa estratificação melhora a qualidade probabilística das previsões em relação a um modelo quantílico global, aumentando a cobertura dos intervalos e, ao mesmo tempo, permitindo intervalos mais estreitos antes da calibração. Em terceiro lugar, implementou-se uma etapa de calibração pós-processamento simples, baseada em um fator de escala aplicado à largura dos intervalos, que ajusta a cobertura empírica ao nível nominal de

80%. Essa abordagem elevou o PICP global de 73,7% (modelo quantílico global sem regimes) para 79,3% (modelo por regime calibrado), mantendo a largura normalizada média em patamar compatível com a elevada variabilidade observada em clima tropical úmido. Até onde foi possível verificar, não foram encontrados estudos anteriores que combinem regressão quantílica com LightGBM, estratificação por regimes de radiação e calibração pós-processamento em um sistema real localizado na Amazônia brasileira, o que destaca o caráter aplicado e contextualizado desta contribuição.

6.3 Conclusões a partir dos resultados

6.3.1 Desempenho determinístico

Em termos determinísticos, o modelo baseado na mediana do LightGBM quantílico superou de forma consistente a referência de persistência. No conjunto de teste, o MAE foi reduzido de 1.004 para 726 Wh (redução de 27,7%) e o RMSE de 1.242 para 1.062 Wh, com coeficiente de determinação em torno de 0,76. A análise por regimes mostrou que os maiores ganhos ocorrem em baixa radiação, com redução de 51% no MAE em relação à persistência e aumento expressivo de R^2 , indicando que o modelo consegue capturar melhor a dinâmica em condições de pouca geração. Em radiação intermediária, os ganhos são moderados, coerentes com a maior variabilidade típica de céu parcialmente nublado. Em alta radiação, os ganhos determinísticos são mais modestos, o que reflete o fato de que, em dias próximos a céu limpo, a persistência já é um preditor razoável.

6.3.2 Desempenho probabilístico

No domínio probabilístico, o objetivo principal foi obter intervalos de predição simultaneamente bem calibrados e informativos. O modelo quantílico global, sem estratificação, apresentou PICP de 0,737 para o nível nominal de 80%, caracterizando subcobertura, com PINAW de 0,297. A introdução da estratificação por regimes elevou o PICP para 0,747 e reduziu o PINAW para 0,261, mostrando que tratar explicitamente a heterogeneidade da incerteza melhora a qualidade dos intervalos mesmo antes da calibração. Após a aplicação do fator de calibração $\lambda = 1,169$, o modelo por regime passou a apresentar PICP global de 0,793, muito próximo do nível nominal, com PINAW de 0,306. A análise por regime indicou cobertura próxima de 80% em baixa, média e alta radiação, com larguras crescentes à medida que aumenta a geração, o que é fisicamente coerente com a maior incerteza absoluta em condições de maior irradiância. Esses resultados confirmam que a combinação entre regressão quantílica, estratificação por regimes e calibração pós-processamento é eficaz para representar a incerteza da geração fotovoltaica em clima tropical úmido.

6.3.3 Síntese do trade-off entre calibração e nitidez

Os resultados evidenciaram o trade-off inevitável entre calibração e nitidez (GNEITING; BALABDAOUI; RAFTERY, 2007). O modelo alcançou PICP próximo do nominal (79,3% vs. 80%) com PINAW de 30,6%, representando um compromisso adequado. Em termos absolutos, os intervalos têm largura média de aproximadamente 2.500 Wh, o que corresponde a cerca de 87% da produção média horária (2.870 Wh). Esse nível de incerteza é informativo o suficiente para auxiliar na tomada de decisão operacional, mantendo confiabilidade estatística.

6.4 Limitações

Algumas limitações devem ser reconhecidas para interpretar corretamente o alcance dos resultados:

- **Particionamento e escalonamento:** a divisão treino, validação e teste foi realizada por amostragem aleatória (70/15/15), e o escalonamento das variáveis preditoras foi aplicado antes da divisão. Em séries temporais, essa configuração pode induzir viés otimista ao permitir que estatísticas globais influenciem indiretamente os subconjuntos de validação e teste. Como melhoria metodológica, recomenda-se empregar particionamento cronológico por blocos (por dia) e ajustar o escalonamento exclusivamente no conjunto de treinamento, aplicando a mesma transformação aos subconjuntos de validação e teste.
- **Dependência da qualidade dos dados meteorológicos:** falhas ou baixa resolução temporal nas variáveis de entrada podem reduzir a capacidade do modelo de antecipar mudanças rápidas de irradiância. Além disso, o uso exclusivo de dados de reanálise global (Open-Meteo) resultou em viés sistemático de -462 Wh no regime de alta radiação, sugerindo que perdas térmicas localizadas e eventos convectivos rápidos não são completamente capturados por modelos numéricos globais. A integração com medições meteorológicas locais ou imagens de satélite de alta resolução temporal poderia mitigar esse viés.
- **Definição dos regimes:** os limiares Q_{33} e Q_{67} foram escolhidos empiricamente com base nos tercis da distribuição de radiação horária (kJ/m^2). Critérios alternativos (como análise de clusters ou limiares baseados em física) poderiam produzir segmentações diferentes, embora a validação empírica demonstre que a escolha adotada é eficaz.
- **Baselines adicionais:** a comparação determinística foi realizada tendo a persistência como referência direta. Uma linha de base estatística de baixa complexidade adicional, frequentemente usada em aplicações práticas, é a previsão pela *média histórica condicionada* (por hora do dia e, opcionalmente, por mês/estação). A inclusão dessa baseline permitiria quantificar com maior granularidade o ganho absoluto do arcabouço proposto frente a estratégias simples, sendo recomendada como extensão.

- **Generalização espacial e transferibilidade:** os resultados refletem as condições específicas de Tucuruí (clima equatorial Am) e de um sistema FV residencial/comercial de 10,08 kWp. Mudanças de localidade, tecnologia do sistema (potência, orientação, perdas) ou padrões de nebulosidade podem alterar o desempenho. Ainda assim, o arcabouço proposto é *transferível* no nível metodológico: para aplicar em outra usina em Tucuruí, recomenda-se coletar um histórico mínimo local de geração (idealmente cobrindo pelo menos parte das estações seca e chuvosa), reestimar os limiares de regimes no conjunto de treinamento, retreinar o modelo quantílico com as variáveis meteorológicas correspondentes e recalibrar o fator λ para o nível nominal desejado. Para outras localidades, o mesmo procedimento é aplicável, com atenção à representatividade climática do período de treinamento e à necessidade de recalibração.
- **Horizonte de previsão:** este trabalho focou em previsão 1 hora à frente (*nowcasting*). Horizontes mais longos podem requerer abordagens diferentes, como a inclusão de variáveis defasadas (*lags*) ou o uso de modelos de séries temporais.

6.5 Trabalhos futuros

Como continuidade natural desta pesquisa, são sugeridos os seguintes caminhos:

- **Baselines operacionais adicionais:** comparar a abordagem proposta com previsores simples além da persistência, como a previsão pela *média histórica condicionada* (por hora do dia e por mês/estação) e variantes sazonais, quantificando ganhos e limites em cenários de baixa variabilidade e de céu parcialmente nublado.
- **Avaliar transferibilidade local e escala:** repetir o estudo em outros sistemas FV em Tucuruí e em usinas de maior porte, incluindo testes com agregação de múltiplos sistemas distribuídos. Essa etapa permitiria avaliar a estabilidade dos limiares de regime, a necessidade de recalibração de λ e o impacto potencial em aplicações de gestão de energia e operação de rede.
- **Investigar mitigação do viés sistemático:** explorar a integração de medições meteorológicas locais, imagens de satélite de alta resolução temporal, ou modelagem explícita de perdas térmicas para reduzir o viés de -462 Wh observado no regime de alta radiação.
- **Testar outros horizontes de previsão:** avaliar o desempenho para horizontes de 2h, 6h e 24h à frente, verificando como a incerteza evolui e se a estratificação por regimes mantém sua eficácia em horizontes mais longos.
- **Explorar métodos de calibração alternativos:** investigar *conformal prediction* ou calibração isotônica como alternativas ao fator de escala linear, avaliando se proporcionam melhor trade-off entre calibração e nitidez.

- **Analisar robustez sazonal:** avaliar separadamente estação chuvosa (dezembro a maio) e seca (junho a novembro), verificando se a calibração se mantém consistente e se os limiares de regime devem ser ajustados sazonalmente.
- **Expandir métricas probabilísticas:** complementar PICP e PINAW com *Continuous Ranked Probability Score* (CRPS), diagramas de calibração (PIT histograms) e testes de hipótese para comparação estatística rigorosa entre modelos.
- **Integração operacional:** desenvolver interface para uso em tempo real, integrando com APIs meteorológicas e sistemas de gerenciamento de energia, incluindo mecanismos de atualização incremental dos modelos.
- **Comparação com outros modelos:** avaliar redes neurais recorrentes (LSTM), Transformers e métodos de ensemble para verificar se há ganho adicional em relação ao LightGBM, mantendo a comparação com baseline global para validar contribuições metodológicas.
- **Explorar critérios alternativos de regime:** investigar segmentação por análise de clusters, mistura de gaussianas ou limiares baseados em física atmosférica, comparando rigorosamente com a abordagem por tercís adotada neste trabalho.

6.6 Produções acadêmicas e materiais gerados

Esta dissertação também resultou em produtos técnico-científicos que podem apoiar a reprodução dos experimentos e a extensão do estudo. Em particular:

- **Pipeline reprodutível:** scripts e rotinas de pré-processamento, treinamento e avaliação (determinística e probabilística), incluindo estratificação por regimes e calibração dos intervalos.
- **Conjunto de dados organizado:** base integrada com variáveis meteorológicas horárias (Open-Meteo) e medições de geração FV, com critérios de filtragem e particionamento documentados.
- **Disseminação:** os materiais produzidos (dados organizados, código e resultados) permitem a elaboração de publicações técnicas e científicas, conforme interesse do autor.

6.7 Considerações finais

Em síntese, esta dissertação demonstrou que previsões probabilísticas fornecem uma descrição mais completa do comportamento esperado da geração fotovoltaica, especialmente em ambientes de alta variabilidade meteorológica como a Amazônia. Os resultados obtidos, com

PICP de 79,3% (próximo ao alvo de 80%), PINAW de 30,6% e redução de 27,7% no MAE em relação à persistência, validam a abordagem proposta.

Embora o estudo de caso se baseie em um sistema de pequeno porte, a utilidade operacional do arcabouço não se limita ao despacho do sistema de transmissão. Em escala local, intervalos calibrados podem apoiar o *gerenciamento de energia* de prosumidores, por exemplo no acionamento de cargas flexíveis e no planejamento do uso de baterias (*behind-the-meter*), onde a decisão depende explicitamente do risco de subgeração. Em escala de rede, o mesmo método pode ser empregado em usinas de maior porte ou em agregações de múltiplos sistemas distribuídos (“*virtual power plants*”), nas quais a previsão intervalar se torna relevante para programação de reserva, controle de tensão e mitigação de incertezas na operação.

Um resultado fundamental foi a validação empírica da estratificação por regimes de radiação. A comparação rigorosa com um modelo quantílico global (sem estratificação) demonstrou que a abordagem proposta melhora a cobertura probabilística em 1,0 ponto percentual mesmo antes da calibração (PICP: 73,7% → 74,7%), além de produzir intervalos mais eficientes (PINAW: 29,7% → 26,1%). Esse resultado confirma que o tratamento explícito da heterogeneidade da incerteza não é apenas teoricamente justificável, mas empiricamente superior, validando a hipótese central do trabalho.

A combinação de regressão quantílica com LightGBM, estratificação por regimes de radiação e calibração pós-processamento mostrou-se eficaz para produzir intervalos de predição bem calibrados e informativos. O trabalho apresenta um caminho metodológico viável, reproduzível e alinhado a boas práticas de avaliação probabilística, contribuindo para o avanço da previsão fotovoltaica em contextos reais e desafiadores.

A principal mensagem é que, em aplicações onde a incerteza importa, como no planejamento de sistemas elétricos e no gerenciamento de energia renovável, previsões pontuais são insuficientes. Intervalos de predição calibrados permitem decisões mais informadas, quantificando o risco e possibilitando estratégias de mitigação adequadas. A abordagem por regimes de radiação demonstra que capturar explicitamente a variação da incerteza ao longo do domínio operacional é um caminho promissor para melhorar a qualidade de previsões probabilísticas em sistemas fotovoltaicos.

REFERÊNCIAS

- ABSOLAR. **Infográfico ABSOLAR**. 2025. Principal fonte de informações sobre o setor solar fotovoltaico no Brasil, com atualização mensal. Disponível em: <<https://www.absolar.org.br/mercado/infografico/>>. Acesso em: 2026-02-24.
- AKSOY, A.; TOLUN, M. Comparative analysis of gradient boosting algorithms for short-term solar power forecasting. **Energy**, v. 276, p. 127467, 2023.
- ANTONANZAS, J. et al. Review of photovoltaic power forecasting. **Solar Energy**, v. 136, p. 78–111, 2016.
- CASARIN, R. **Brasil é 6 colocado no ranking global de energia solar de 2024**. 2025. Disponível em: <<https://www.portalsolar.com.br/noticias/mercado/internacional/brasil-e-6o-colocado-no-ranking-global-de-energia-solar-de-2024>>.
- CHEN, T.; GUESTRIN, C. XGBoost: A scalable tree boosting system. In: **Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**. [S.l.: s.n.], 2016. p. 785–794.
- CHOI, J. et al. Analysis of data errors in the solar photovoltaic monitoring system database: An overview of nationwide power plants in korea. **Renewable and Sustainable Energy Reviews**, v. 156, p. 112007, 2022.
- DOUBLEDAY, K.; SCYOC-HERNANDEZ, V. V.; HODGE, B.-M. Benchmark probabilistic solar forecasts: Characteristics and recommendations. **Solar Energy**, v. 206, p. 52–67, 2020.
- FRIEDMAN, J. H. Greedy function approximation: A gradient boosting machine. **Annals of Statistics**, v. 29, n. 5, p. 1189–1232, 2001.
- GABOITAOLELWE, J. et al. Machine learning based solar photovoltaic power forecasting: A review and comparison. **IEEE Access**, v. 11, p. 40820–40845, 2023.
- GANDHI, O. et al. The value of solar forecasts and the cost of their errors: A review. **Renewable and Sustainable Energy Reviews**, v. 189, p. 113915, 2024.
- GNEITING, T. Making and evaluating point forecasts. **Journal of the American Statistical Association**, v. 106, n. 494, p. 746–762, 2011.
- GNEITING, T.; BALABDAOUI, F.; RAFTERY, A. E. Probabilistic forecasts, calibration and sharpness. **Journal of the Royal Statistical Society: Series B (Statistical Methodology)**, v. 69, n. 2, p. 243–268, 2007.
- GNEITING, T.; KATZFUSS, M. Probabilistic forecasting. **Annual Review of Statistics and Its Application**, v. 1, p. 125–151, 2014.
- GNEITING, T.; LERCH, S.; SCHULZ, B. Probabilistic solar forecasting: Benchmarks, post-processing, verification. **Solar Energy**, v. 252, p. 72–80, 2023.
- HU, A. et al. A novel photovoltaic array outlier cleaning algorithm based on sliding standard deviation mutation. **Energies**, v. 12, n. 22, p. 4316, 2019.
- HUSEIN, M. et al. Towards energy efficiency: A comprehensive review of deep learning-based photovoltaic power forecasting strategies. **Heliyon**, v. 10, n. 13, p. e33419, 2024.

- IHEANETU, K. J. Solar photovoltaic power forecasting: A review. **Sustainability**, v. 14, n. 24, p. 17005, 2022.
- INMAN, R. H.; PEDRO, H. T.; COIMBRA, C. F. Solar forecasting methods for renewable energy integration. **Progress in Energy and Combustion Science**, v. 39, n. 6, p. 535–576, 2013.
- KE, G. et al. LightGBM: A highly efficient gradient boosting decision tree. In: **Advances in Neural Information Processing Systems**. [s.n.], 2017. v. 30, p. 3146–3154. Disponível em: <<https://papers.nips.cc/paper/2017/hash/6449f44a102fde848669bdd9eb6b76fa-Abstract.html>>.
- KHOSRAVI, A. et al. Comprehensive review of neural network-based prediction intervals and new advances. **IEEE Transactions on Neural Networks**, v. 22, n. 9, p. 1341–1356, 2011.
- KOENKER, R. **Quantile Regression**. [S.l.]: Cambridge University Press, 2005. ISBN 978-0521608275.
- LAURET, P.; DAVID, M.; PEDRO, H. T. Probabilistic solar forecasting using quantile regression models. **Energies**, v. 10, n. 10, p. 1591, 2017.
- LAURET, P.; DAVID, M.; PEDRO, H. T. C. Probabilistic solar forecasting using quantile regression models. **Energies**, v. 10, n. 10, p. 1591, 2017.
- LAURET, P.; DAVID, M.; PINSON, P. Verification of solar irradiance probabilistic forecasts. **Solar Energy**, v. 194, p. 254–271, 2019.
- LI, B.; ZHANG, J. A review on the integration of probabilistic solar forecasting in power systems. **Solar Energy**, v. 210, p. 68–86, 2020.
- LIMA, F. J. L. d. et al. Reducing uncertainties of climate projections on solar energy resources in Brazil. **Scientific Reports**, v. 14, p. 23586, 2024.
- MARQUES, A. L. F. et al. Application of data science in the prediction of solar energy for the amazon basin: a study case. **Clean Energy**, v. 7, n. 6, p. 1344–1355, 2023.
- MARQUES, A. L. F. et al. Neural networks forecast models comparison for the solar energy generation in amazon basin. **IEEE Access**, v. 12, p. 17915–17925, 2024.
- MASSIDDA, L.; MARROCU, M. Quantile regression post-processing of weather forecast for short-term solar power probabilistic forecasting. **Energies**, v. 11, n. 7, p. 1763, 2018.
- MAULADDAWILAH, H. et al. Towards energy efficiency: A comprehensive review of deep learning-based photovoltaic power forecasting strategies. **Heliyon**, v. 10, n. 13, p. e33419, 2024.
- MÁXIMO, W. **Com 22% da matriz elétrica, energia solar é a 2ª maior fonte do país**. 2025. Disponível em: <<https://agenciabrasil.ebc.com.br/meio-ambiente/noticia/2025-03/com-22-da-matriz-eletrica-energia-solar-e-a-2-maior-fonte-do-pais>>.
- MAYER, M. J.; YANG, D. Pairing ensemble numerical weather prediction with ensemble physical model chain for probabilistic photovoltaic power forecasting. **Renewable and Sustainable Energy Reviews**, v. 175, p. 113171, 2023.
- MEER, D. W. van der; WIDÉN, J.; MUNKHAMMAR, J. Review on probabilistic forecasting of photovoltaic power production and electricity consumption. **Renewable and Sustainable Energy Reviews**, v. 81, p. 1484–1512, 2018.

- MOULOUD, L. A. et al. Seasonal quantile forecasting of solar photovoltaic power using Q-CNN-GRU. **Scientific Reports**, v. 15, p. 27270, 2025.
- NGUYEN-DUC, T. et al. A combination of novel hybrid deep learning model and quantile regression for short-term deterministic and probabilistic PV maximum power forecasting. **IET Renewable Power Generation**, v. 17, n. 4, p. 794–813, 2023.
- OPEN-METEO. **Weather Forecast API Documentation: shortwave_radiation (preceding hour mean)**. 2026. <<https://open-meteo.com/en/docs>>. Acesso em 01 fev. 2026. Variável *shortwave_radiation*: média da hora anterior (W/m^2), equivalente à irradiação global horizontal.
- PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011. Disponível em: <<https://jmlr.org/papers/v12/pedregosa11a.html>>.
- PEDRO, H. T.; COIMBRA, C. F. Assessment of forecasting techniques for solar power production with no exogenous inputs. **Solar Energy**, v. 86, n. 7, p. 2017–2028, 2012.
- PELLAND, S. et al. **Photovoltaic and Solar Forecasting: State of the Art**. [S.l.], 2013. Disponível em: <https://mn8.meteonorm.com/assets/publications/Photovoltaic_and_Solar_Forecasting_State_of_the_Art_REPORT_PVPS_T14_01_2013.pdf>.
- ROY, A. et al. Impact of tropical convective conditions on solar irradiance forecasting based on cloud motion vectors. **Environmental Research Letters**, v. 17, n. 10, p. 104048, 2022.
- SALLE, J. L. G. L.; DAVID, M.; LAURET, P. A new climatology reference model to benchmark probabilistic solar forecasts. **Solar Energy**, v. 223, p. 398–414, 2021.
- SOBRI, S.; KOOHI-KAMALI, S.; RAHIM, N. A. Solar photovoltaic generation forecasting methods: A review. **Energy Conversion and Management**, v. 156, p. 459–497, 2018. ISSN 0196-8904.
- VERBOIS, H.; RUSYDI, A.; THIERY, A. Probabilistic forecasting of day-ahead solar irradiance using quantile gradient boosting. **Solar Energy**, v. 173, p. 313–327, 2018.
- VOYANT, C. et al. Machine learning methods for solar radiation forecasting: A review. **Renewable Energy**, v. 105, p. 569–582, 2017.
- WEYLL, A. L. C. et al. Medium-term forecasting of global horizontal solar radiation in Brazil using machine learning-based methods. **Energy**, v. 300, p. 131549, 2024.
- YANG, B. et al. Classification and summarization of solar irradiance and power forecasting methods: A thorough review. **CSEE Journal of Power and Energy Systems**, v. 9, n. 3, p. 978–995, 2023.
- YU, J. et al. Deep learning models for pv power forecasting: Review. **Energies**, v. 17, n. 16, p. 3973, 2024.
- ZHANG, H. et al. Short-term interval prediction of pv power based on quantile regression-stacking model and tree-structured parzen estimator optimization algorithm. **Frontiers in Energy Research**, v. 11, p. 1252057, 2023. Disponível em: <<https://www.frontiersin.org/journals/energy-research/articles/10.3389/fenrg.2023.1252057/full>>.