



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

RICARDO MOURA DE SOUZA

**Variabilidade de Potência em Geração Fotovoltaica:
Métodos de Suavização, Métricas e Caracterização**

Recife

2024

RICARDO MOURA DE SOUZA

**Variabilidade de Potência em Geração Fotovoltaica:
Métodos de Suavização, Métricas e Caracterização**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de mestre em Engenharia Elétrica.

Área de concentração: Processamento de Energia.

Orientador: Prof. Dr. Rafael Cavalcanti Neto

Recife

2024

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Souza, Ricardo Moura de.

Variabilidade de Potência em Geração Fotovoltaica: Métodos de Suavização, Métricas e Caracterização / Ricardo Moura de Souza. - Recife, 2024.

105p.: il.

Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Engenharia Elétrica. Orientação: Prof. Dr. Rafael Cavalcanti Neto.

1. Engenharia Elétrica; 2. Fontes renováveis de energia; 3. Intermittência; 4. Sistemas de Armazenamento de Energia; 5. Suavização de Potência; 6. Variabilidade de Potência. I. Cavalcanti Neto, Rafael orientador. II. Título.

UFPE-Biblioteca Central

CDD 621.3

RICARDO MOURA DE SOUZA

“VARIABILIDADE DE POTÊNCIA EM GERAÇÃO FOTOVOLTAICA: MÉTODOS DE SUA VIZAÇÃO, MÉTRICAS E CARACTERIZAÇÃO”

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica, na área de concentração em Processamento de Energia.

Aprovada em: 27/02/2024

BANCA EXAMINADORA

Prof. Dr. Rafael Cavalcanti Neto
(Orientador e Examinador Interno)
Universidade Federal de Pernambuco

Prof. Dr. José Filho da Costa Castro
(Examinador Interno)
Universidade Federal de Pernambuco

Prof. Dr. Juliano Bandeira Lima
(Examinador Interno)
Universidade Federal de Pernambuco

Prof. Dr. Fernando Aparecido de Assis
(Examinador Externo)
Universidade Federal de São João Del-Rei

AGRADECIMENTOS

Expresso minha total gratidão aos meus pais, Agilson e Maria Elza, pelo empenho e capacidade de estimular o desejo pelo aprendizado através da educação, do amor e do exemplo.

Agradeço aos meus avós – Israel (*in memoriam*), Josinete (*in memoriam*), Josué (*in memoriam*) e Maria Pereira – e ao meu irmão, Lucas, por serem corresponsáveis na criação de um ambiente propício ao meu desenvolvimento.

À minha namorada, Emília, que, nos momentos de maior dificuldade, fez-se incondicionalmente presente através de sua paciência incomparável e de seu suporte singular.

Ao meu orientador, Rafael, pela confiança depositada em meu trabalho, pela humanidade no tratamento e pelo genuíno interesse em meu desenvolvimento acadêmico. Agradeço, também, aos demais professores do Grupo de Eletrônica de Potência e Acionamentos Elétricos (GEPAE), que contribuíram direta ou indiretamente para este trabalho.

A todos os amigos de curso e de laboratório, sem os quais eu não teria sido capaz de alcançar esta conquista. Agradeço, nominalmente, a Antonio, Carol, Camila, Duda, Eduardo, Ericles, Gustavo, Néstor, Renato, Tiago e Valdemar. Agradeço, em especial, a Felipe, em função de suas contribuições diretas durante o desenvolvimento deste trabalho.

Ao meu amigo de mais de uma década, Daniel, com quem tive a honra de compartilhar os estudos durante o ensino médio e na graduação em Engenharia Elétrica.

Agradeço, também, à Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), cujo fomento viabilizou a execução deste trabalho.

Por fim, exponho meu reconhecimento a todos os funcionários que compõem a Universidade Federal de Pernambuco, pela excelência no dever de promover pesquisa e ensino públicos.

RESUMO

As mudanças climáticas induzidas por atividades humanas, causadas principalmente pelas emissões de gases de efeito estufa, representam uma ameaça significativa para a sustentabilidade da vida na Terra. Nesse contexto, as fontes renováveis de energia (RESs), como a geração eólica e a fotovoltaica, cresceram em relevância como alternativas economicamente viáveis. As quedas recentes nos custos dessas tecnologias aceleraram a sua adoção, tornando-as parcelas relevantes da capacidade instalada dos países. Embora relativamente limpas, essas alternativas não estão isentas de impactos negativos, especialmente no que diz respeito à sua integração nas redes elétricas. Relatos na literatura destacam questões como flutuações de tensão, desvios de frequência e a necessidade de maiores reservas operativas, todas decorrentes da natureza estocástica e intermitente dessas fontes. No cenário descrito, este trabalho aborda um desses impactos, o crescimento da variabilidade de potência, dando ênfase ao uso de sistemas de armazenamento de energia em microrredes CA visando a suavização de potência. A revisão da literatura destaca trabalhos que abordam a problemática da variabilidade de potência, métodos de geração de referência para suavização de potência e a caracterização da variabilidade através de funções de densidade de probabilidade, fornecendo subsídios teóricos para a avaliação de métricas vigentes e para a proposição de alternativas. Nesse contexto, faz-se uso de um conjunto de dados experimentais oriundos do NREL (*National Renewable Energy Laboratory*), a partir do qual são expostas as limitações das métricas comumente utilizadas para avaliar os métodos de geração de referência para suavização de potência. Também com base nos dados, este trabalho avalia os métodos de caracterização da variabilidade de potência baseados em distribuições de probabilidade a partir da implementação de um subconjunto dos métodos mais comuns na literatura. Com base nas limitações encontradas neste trabalho, novas métricas são elaboradas tomando como referência boas práticas do campo da Estatística.

Palavras-chave: fontes renováveis de energia; intermitência; sistemas de armazenamento de energia; taxa de rampa; variabilidade de potência.

ABSTRACT

Human-induced climate change, primarily caused by greenhouse gas emissions, poses a significant threat to the sustainability of life on Earth. To mitigate this problem, renewable energy sources (RESs), such as photovoltaic (PV) and wind generation, have gained substantial relevance as economically viable alternatives. Recent price drops in these technologies have accelerated their adoption as significant contributors to countries' power grids. Although relatively clean, these alternatives are not free of negative impacts, particularly concerning their integration into power grids. Literature reports highlight issues such as voltage flickers, frequency deviations, and the need for larger power reserves, all stemming from the hard-to-anticipate nature of power variability. In the described scenario, this study addresses one of these impacts: the increase in power variability, with an emphasis on the use of energy storage systems in AC microgrids aimed at power smoothing. The literature review highlights works that tackle the issue of power variability, methods for generating reference signals for power smoothing, and the characterization of variability through probability density functions, providing theoretical support for the evaluation of current metrics and the proposal of alternatives. In this context, a set of experimental data from the NREL (National Renewable Energy Laboratory) is used, exposing the limitations of commonly used metrics to assess reference signal generation methods for power smoothing. Also, based on the data, an assessment of power variability characterization methods is conducted, employing a subset of the most common methods in the literature. Given the limitations found in this study, new metrics are developed, drawing on best practices from the field of Statistics.

Keywords: energy storage systems; intermittency; power variability; ramp rate; renewable energy sources.

LISTA DE FIGURAS

Figura 1 – Evolução da capacidade instalada das usinas eólicas e fotovoltaicas sob o controle do despacho centralizado e programado do ONS.	21
Figura 2 – Exemplo de sistema de suavização de potência com ESS.	28
Figura 3 – Classificação de sistemas de armazenamento de energia de acordo com a tecnologia empregada.	30
Figura 4 – Resultados encontrados no IEEE <i>Xplore</i> (por ano) ao buscar palavras-chaves relacionadas as tecnologias de ESS.	33
Figura 5 – Configuração simplificada de conexão de geração fotovoltaica e BESS em microrrede CC.	35
Figura 6 – Configuração simplificada de conexão de geração fotovoltaica e BESS em microrrede CA.	35
Figura 7 – Diagrama de blocos simplificado de um esquema de controle convencional para suavização de potência.	36
Figura 8 – Categorização de algoritmos de suavização de potência utilizados para geração fotovoltaica.	37
Figura 9 – Exemplo numérico da aplicação da Equação (1) para a obtenção de um conjunto suavizado de amostras de potência utilizando SMA, $P_{SMA,k}$. Diferentes tamanhos de janela móvel (parâmetro n) são considerados.	39
Figura 10 – Efeito da escolha de diferentes janelas de cálculo sobre o desempenho do método SMA na suavização de sinais.	39
Figura 11 – Fluxograma para determinação do parâmetro n do SMA, considerando os métodos determinístico e probabilístico.	40
Figura 12 – Exemplo numérico da aplicação da Equação (3) para obtenção de um conjunto suavizado de amostras de potência utilizando RR, $P_{RR,k}$. Diferentes valores de λ são considerados.	42
Figura 13 – Efeito da escolha de diferentes valores de λ sobre o desempenho do método RR na suavização de sinais.	42
Figura 14 – Definições da intensidade das variações (marcadas em vermelho): (a) cálculo de forma média; (b) extremos de geração em um dado período; e (c) desvio em relação à média móvel.	43
Figura 15 – Propriedades de uma distribuição Gaussiana.	45
Figura 16 – Exemplo de uso da análise visual para comparação do impacto dos algoritmos SMA e RR na suavização de potência. Avaliação feita para um perfil diário de geração fotovoltaica.	46
Figura 17 – Exemplos de distribuições de probabilidade.	47
Figura 18 – Efeito da variação de μ	48

Figura 19 – Efeito da variação de σ	48
Figura 20 – Localização das instalações avaliadas neste trabalho.	50
Figura 21 – Fluxograma da validação e tratamento dos dados.	51
Figura 22 – Histograma das variações de potência ativa em Cocoa (resultado sem aplicação de técnicas de suavização). Valores normalizados pela densidade de probabilidade.	53
Figura 23 – Histograma das variações de potência ativa em Eugene (resultado sem aplicação de técnicas de suavização). Valores normalizados pela densidade de probabilidade.	53
Figura 24 – Perfil diário de geração para diferentes condições de irradiância antes e pós-suavização (Cocoa).	54
Figura 25 – Perfil diário de geração para diferentes condições de irradiância antes e pós-suavização (Eugene).	54
Figura 26 – Histograma das variações de potência ativa em Cocoa, antes e pós-suavização. Valores normalizados pela densidade de probabilidade.	54
Figura 27 – Histograma das variações de potência ativa em Eugene, antes e pós-suavização. Valores normalizados pela densidade de probabilidade.	55
Figura 28 – CDF das variações de potência ativa em Cocoa (antes e pós-suavização) e Gaussiana de mesma média e desvio padrão para referência.	56
Figura 29 – CDF das variações de potência ativa em Eugene (antes e pós-suavização) e Gaussiana de mesma média e desvio padrão para referência.	56
Figura 30 – Valor esperado de $\Delta P_{\text{máx}}$ a cada iteração considerando a variabilidade natural da planta fotovoltaica (Cocoa), em que um dia de medições compreende 144 amostras.	59
Figura 31 – Valor esperado de $\Delta P_{\text{máx}}$ a cada iteração considerando a variabilidade natural da planta fotovoltaica (Eugene), em que um dia de medições compreende 144 amostras.	59
Figura 32 – Valor esperado de $\Delta P_{\text{máx}}$ e coeficiente de variação a cada iteração (Cocoa). Em vermelho, é indicada a quantidade de amostras sugerida pelo Algoritmo 2 para garantir um valor estatisticamente significativo.	64
Figura 33 – Valor esperado de $\Delta P_{\text{máx}}$ e coeficiente de variação a cada iteração (Eugene). Em vermelho, é indicada a quantidade de amostras sugerida pelo Algoritmo 2 para garantir um valor estatisticamente significativo.	65
Figura 34 – Exemplo de ajuste dinâmico da Equação (12) para diferentes quantidades de amostras.	68
Figura 35 – Ajuste dinâmico dos parâmetros da curva de variabilidade máxima experimental. Dados de Cocoa.	68
Figura 36 – Ajuste dinâmico dos parâmetros da curva de variabilidade máxima experimental. Dados de Eugene.	69

Figura 37 – Variação do valor de VF entre iterações (dados de Cocoa). Em vermelho, está destacada a primeira iteração na qual o critério de parada é satisfeito.	70
Figura 38 – Variação do valor de VF entre iterações (dados de Eugene). Em vermelho, está destacada a primeira iteração na qual o critério de parada é satisfeito.	70
Figura 39 – Fluxograma do algoritmo para a determinação da Variabilidade Máxima com Horizonte Antecipado ($\Delta P_{\text{máx}}^{\text{HA}}$).	71
Figura 40 – Efeito da variação de μ	76
Figura 41 – Efeito da variação de σ	76
Figura 42 – Tentativas de estimação da distribuição experimental.	76
Figura 43 – Verossimilhança máxima.	77
Figura 44 – Resultado do uso da distribuição q-Exponencial para caracterizar flutuações de potência em (a) uma usina eólica e (b) uma usina fotovoltaica. Foram consideradas flutuações de intervalos de 15 e 60 min.	80
Figura 45 – Resultado do uso da função sigmoide para caracterizar flutuações de potência em uma usina fotovoltaica. Foram consideradas flutuações de intervalos de 5, 10, 15, 20 e 25 min.	83
Figura 46 – Comparação entre os percentis de probabilidade para as distribuições de Laplace e GEV. Os resultados da distribuição Gaussiana foram omitidos no artigo por limitação de espaço.	84
Figura 47 – Resultado do uso da distribuição de Laplace para caracterizar flutuações de potência num agregado de geração eólica.	85
Figura 48 – Resultado do uso da distribuição de Laplace para caracterizar flutuações de potência nos parques fotovoltaicos da Austrália: (a) Nyngan, (b) Moree, (c) Broken Hill e (d) Royalla.	86
Figura 49 – Histograma para um mesmo conjunto de dados representado em escala (a) linear e (b) semi-log.	86
Figura 50 – Resultado do uso da distribuição q-Exponencial para caracterizar flutuações de potência em (a) Cocoa e (b) Eugene.	87
Figura 51 – Resultado do uso da função sigmoide para caracterizar flutuações de potência em (a) Cocoa e (b) Eugene.	88
Figura 52 – Resultado do uso da distribuição gaussiana para caracterizar flutuações de potência em (a) Cocoa e (b) Eugene.	89
Figura 53 – Resultado do uso da distribuição GEV para caracterizar flutuações de potência em (a) Cocoa e (b) Eugene.	90
Figura 54 – Resultado do uso da distribuição de Laplace para caracterizar flutuações de potência em (a) Cocoa e (b) Eugene.	91
Figura 55 – Histograma das variações de potência em Cocoa normalizado pela densidade de probabilidade. Sobre o histograma, pode-se visualizar a PDF obtida a partir da caracterização com função sigmoide.	94

Figura 56 – Histogramas com diferentes números de barras considerando o mesmo conjunto de dados. Em roxo, vermelho e rosa, histogramas com, respectivamente, 30, 80 e 150 barras.	94
Figura 57 – Resultado do uso da distribuição q-Exponencial para caracterizar flutuações de potência em (a) Cocoa e (b) Eugene. Em ciano, azul e preto com, respectivamente, disponibilidades de 10%, 50% e 100% dos dados.	96

LISTA DE TABELAS

Tabela 1 – Categorização dos efeitos gerados pela variabilidade de potência de acordo com o período de tempo associado.	21
Tabela 2 – Requisitos de taxa de rampa máxima de potência ativa definidos nos códigos de rede de diversos países.	27
Tabela 3 – Características técnicas das principais tecnologias de ESSs de alta potência.	33
Tabela 4 – Detalhamento dos dados utilizados.	50
Tabela 5 – Índices numéricos antes e depois da suavização de potência.	55
Tabela 6 – Probabilidade de ocorrência de eventos extremos, $\mathbb{P}(\Delta P \geq x)$	58
Tabela 7 – Razão entre probabilidade de ocorrência do evento na distribuição empírica e em uma Gaussiana equivalente.	58
Tabela 8 – Resultados do Algoritmo 2 para diferentes valores de tolerância - Cocoa.	63
Tabela 9 – Resultados do Algoritmo 2 para diferentes valores de tolerância - Eugene.	64
Tabela 10 – Comparação qualitativa das métricas voltadas à análise da probabilidade das variações de potência.	72
Tabela 11 – Comparação qualitativa das métricas voltadas à análise da intensidade das variações de potência.	72
Tabela 12 – Distribuições de probabilidade utilizadas para caracterização das variações de potência na literatura.	79
Tabela 13 – Parâmetros da distribuição q-Exponencial para a caracterização das flutuações de potência em Cocoa e Eugene.	87
Tabela 14 – Parâmetros da função sigmoide para a caracterização das flutuações de potência em Cocoa e Eugene.	88
Tabela 15 – Parâmetros da distribuição Gaussiana para a caracterização das flutuações de potência em Cocoa e Eugene.	89
Tabela 16 – Parâmetros da distribuição GEV para a caracterização das flutuações de potência em Cocoa e Eugene.	90
Tabela 17 – Parâmetros da distribuição de Laplace para a caracterização das flutuações de potência em Cocoa e Eugene.	91
Tabela 18 – Comparação entre probabilidade de ocorrência dos eventos para as distribuições avaliadas (dados de Cocoa).	92
Tabela 19 – Comparação entre probabilidade de ocorrência dos eventos para as distribuições avaliadas (dados de Eugene).	92

LISTA DE ALGORITMOS

Algoritmo 1 – Estimador de Monte Carlo básico.	61
Algoritmo 2 – Estimador de Monte Carlo não sequencial adaptado.	62

LISTA DE ABREVIATURAS E SIGLAS

AEMO	<i>Australian Energy Market Operator</i>
ANEEL	Agência Nacional de Energia Elétrica
BESS	<i>Battery Energy Storage System</i>
BPA	<i>Bonneville Power Administration</i>
CA	Corrente Alternada
CC	Corrente Contínua
CDF	<i>Cumulative Distribution Function</i>
CEPRI	<i>China Electric Power Research Institute</i>
CLT	<i>Central Limit Theorem</i>
ERCOT	<i>Electric Reliability Council of Texas</i>
ESS	<i>Energy Storage System</i>
FC/ELZ	<i>Fuel Cell and Electrolyzer Hybrid System</i>
FESS	<i>Flywheel Energy Storage System</i>
FSEC	<i>Florida Solar Energy Center</i>
GEV	<i>Generalized Extreme Value</i>
HESS	<i>Hybrid Energy Storage System</i>
ISO	<i>Independent System Operator</i>
LLN	<i>Law of Large Numbers</i>
MCS	<i>Monte Carlo Simulation</i>
MLE	<i>Maximum Likelihood Estimation</i>
MPP	<i>Maximum Power Point</i>
NREL	<i>National Renewable Energy Laboratory</i>
PCC	<i>Point of Common Coupling</i>
PDF	<i>Probability Density Function</i>

RR	<i>Ramp Rate</i>
RES	<i>Renewable Energy Sources</i>
SCESS	<i>Supercapacitor Energy Storage System</i>
SIN	Sistema Interligado Nacional
SMA	<i>Simple Moving Average</i>
SMES	<i>Superconducting Magnetic Energy Storage</i>
SoC	<i>State of Charge</i>
UO	<i>University of Oregon</i>
VF	Valor Final

LISTA DE SÍMBOLOS

P	Conjunto de medições de potência ativa
Δt	Intervalo de tempo entre medições subsequentes
P_k	k -ésimo termo de uma série temporal de medições de potência
ΔP	Variação de potência entre medições subsequentes ou separadas por um intervalo de tempo predeterminado
$P_{PV}(t)$	Potência ativa oriunda de geração fotovoltaica em função do tempo
$P_{ESS}(t)$	Potência ativa injetada pelo ESS
$P_{ESS}(t)^*$	Referência de potência ativa para o ESS
$d(t)$	Ação de controle no ciclo de trabalho das chaves semicondutoras
$P_{suav}(t)$	Potência pós-suavização
$P_{SMA, k}$	k -ésimo elemento do conjunto de medições de potência quando da utilização do método SMA
n	Janela de suavização do método SMA
$P_{RR, k}$	k -ésimo elemento do conjunto de medições de potência quando da utilização do método Ramp Rate
$\Delta P_{m\acute{a}x}^{pos}$	Máxima variabilidade possível
$\Delta P_{m\acute{a}x}^{nat}$	Máxima variabilidade natural
$\Delta P_{m\acute{a}x}$	Variabilidade máxima
Ψ	Limiar predeterminado de probabilidade de ocorrência das variações
λ	Máxima variação de potência permitida no método Ramp Rate
$\Delta P_{m\acute{a}x, \%}$	Variabilidade máxima em termos percentuais
P_{nom}	Potência nominal
σ	Desvio padrão
σ_{Δ}	Desvio padrão das variações de potência
μ	Média

μ_{Δ}	Média das variações de potência
$\varphi(x)$	Função densidade de probabilidade
$\sigma_{\Delta,99.73\%}$	Desvio em relação à média que abarca 99.73% da probabilidade
$\mathbb{F}(x)$	Função distribuição acumulada
$\mathbb{P}(x)$	Probabilidade
$\bar{X}n$	Média de n variáveis aleatórias independentes
σ^2	Variância
\mathbb{E}	Esperança ou Valor Esperado
$\Delta P_{\text{máx}}^{\text{ES}}$	Variabilidade Máxima Estatisticamente Significativa
$\Delta P_{\text{máx}}^{\text{HA}}$	Variabilidade Máxima com Horizonte Antecipado
\mathbb{L}	Verossimilhança
f	Planicidade
h	Incremento infinitesimal
b	Parâmetro de escala da distribuição de Laplace

SUMÁRIO

1	INTRODUÇÃO	20
1.1	OBJETIVOS	22
1.1.1	Objetivos Específicos	22
1.2	ORGANIZAÇÃO DA DISSERTAÇÃO	23
2	FUNDAMENTAÇÃO TEÓRICA	25
2.1	VARIABILIDADE DE POTÊNCIA NA GERAÇÃO FOTOVOLTAICA	25
2.1.1	Regulações Normativas Associadas à Flutuação de Potência em Sistemas Fotovoltaicos	26
2.2	CARACTERÍSTICAS GERAIS DE SISTEMAS DE SUAVIZAÇÃO DE POTÊNCIA	27
2.2.1	Sistemas de Suavização de Potência Baseados em ESSs	28
2.2.2	Principais Tecnologias de ESSs Utilizadas em Potências Elevadas	29
2.2.2.1	Comentários Gerais Acerca das Tecnologias	32
2.2.3	Topologias Típicas de Sistemas com Geração Fotovoltaica e BESS	34
2.3	ALGORITMOS PARA GERAÇÃO DE REFERÊNCIA PARA SISTEMAS DE SUAVIZAÇÃO DE POTÊNCIA	36
2.3.1	Média Móvel Simples (SMA – <i>Simple Moving Average</i>)	37
2.3.1.1	Dimensionamento da Janela de Suavização para SMA	39
2.3.2	Taxa de Rampa (RR – <i>Ramp Rate</i>)	41
2.3.2.1	Dimensionamento da Janela de Suavização para RR	42
2.4	MÉTRICAS FREQUENTEMENTE UTILIZADAS	43
2.4.1	Quanto à Intensidade	43
2.4.2	Quanto à Probabilidade	44
2.4.3	Análise Visual	45
2.4.4	Métricas Baseadas em Irradiância	46
2.5	DISTRIBUIÇÕES DE PROBABILIDADE	46
2.5.1	Parâmetros de uma Distribuição	47
2.6	CONCLUSÕES PARCIAIS	48
3	ANÁLISE DE MÉTRICAS PARA AVALIAÇÃO DE ALGORITMOS DE GERAÇÃO DE REFERÊNCIA EM SUAVIZAÇÃO DE POTÊNCIA	49
3.1	DESCRIÇÃO DO CONJUNTO DE DADOS EXPERIMENTAIS	49
3.1.1	Processamento de Dados	50
3.1.2	Variabilidade Natural das Instalações Avaliadas	51
3.1.3	Resultados Pós-Suavização	52

3.2	ANÁLISE DAS LIMITAÇÕES DAS MÉTRICAS COMUMENTE UTILIZADAS	55
3.2.1	Limitações do Desvio Padrão	56
3.2.2	Limitações da Variabilidade Máxima	57
3.2.3	Limitações da Análise Visual	60
3.3	SIMULAÇÃO DE MONTE CARLO PARA AVALIAÇÃO DE PARÂMETROS DE SUAVIZAÇÃO	60
3.3.1	Aplicação de MCS para o Caso Estudado	61
3.4	PROPOSTAS DE MÉTRICAS ALTERNATIVAS	66
3.4.1	Variabilidade Máxima Estatisticamente Significativa	66
3.4.2	Variabilidade Máxima com Horizonte Antecipado	67
3.4.3	Comparação Qualitativa entre as Métricas	71
3.5	CONCLUSÕES PARCIAIS	72
4	ESTIMAÇÃO DE DISTRIBUIÇÃO DE PROBABILIDADE PARA VARIABILIDADE DE POTÊNCIA	74
4.1	ESTIMATIVA POR MÁXIMA VEROSSIMILHANÇA	75
4.2	MÉTODOS DE ESTIMAÇÃO ORIUNDOS DA LITERATURA	79
4.2.1	Caracterização Proposta por Anvari et al. (2016)	79
4.2.2	Caracterização Proposta por Mazumdar, Saquib e Das (2014)	81
4.2.3	Caracterização Proposta por Louie (2010)	83
4.2.4	Caracterizações Propostas por Lee e Baldick (2012), Raoofat et al. (2018) e Keeratimahat, Bruce e MacGill (2019)	84
4.2.5	Outras Abordagens Possíveis	85
4.3	APLICAÇÃO DOS MÉTODOS DE CARACTERIZAÇÃO SOBRE O CONJUNTO DE DADOS ESTUDADOS	86
4.3.1	Avaliação da Distribuição q-Exponencial	87
4.3.2	Avaliação da Distribuição Sigmoide	88
4.3.3	Avaliação da Distribuição Gaussiana	89
4.3.4	Avaliação da Distribuição GEV	90
4.3.5	Avaliação da Distribuição de Laplace	91
4.3.6	Análise Comparativa dos Resultados Obtidos	92
4.4	PROBLEMAS POTENCIAIS IDENTIFICADOS	93
4.4.1	Limitações da Análise do Histograma	93
4.4.2	Limitação por Ausência de Informações Futuras	94
4.5	CONCLUSÕES PARCIAIS	95
5	CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS	97
5.1	CONTRIBUIÇÕES DO AUTOR	98
5.2	TRABALHOS FUTUROS	98
5.3	PUBLICAÇÕES RESULTANTES DO MESTRADO	99

REFERÊNCIAS 100

1 INTRODUÇÃO

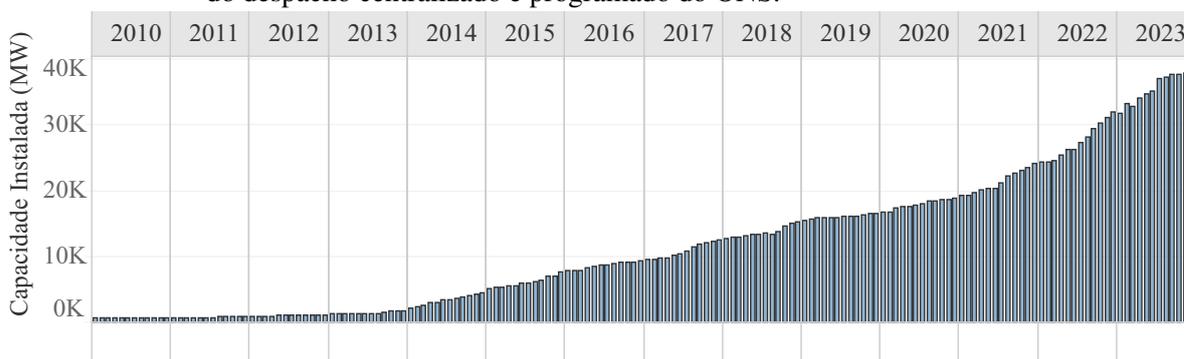
As últimas décadas foram marcadas pela construção gradual de um consenso científico, hoje solidificado, em torno da validade da hipótese da atividade humana enquanto causa primordial para as mudanças climáticas. Sabe-se, atualmente, que a temperatura média de superfície global é aproximadamente 1,1 °C superior àquela verificada durante a primeira metade do século XIX e que em nenhum outro intervalo de tempo nos últimos dois mil anos a temperatura aumentou tão rapidamente quanto no período entre 1970 e 2020 (IPCC, 2023). Esse aquecimento, causado principalmente pela emissão de gases do efeito estufa, possui impactos significativos não apenas sobre os ecossistemas terrestres, mas também sobre as sociedades humanas.

As mudanças climáticas têm potencial para afetar diversos aspectos das atividades humanas, uma vez que podem causar danos às infraestruturas, afetar a disponibilidade de água e de alimentos para as populações, além de gerar deslocamentos em massa. A situação se torna especialmente alarmante ao se considerar que, apesar de as emissões historicamente estarem concentradas nos países desenvolvidos, as nações mais vulneráveis são aquelas com menos emissões per capita e, também, aquelas que possuem menor disponibilidade de recursos para o enfrentamento do problema (IPCC, 2023).

O cenário descrito impõe a tomada de ações a nível global para a minimização das mudanças climáticas. Nesse contexto, o relatório mais recente divulgado pelo Painel Intergovernamental sobre Mudanças Climáticas (IPCC – *Intergovernmental Panel on Climate Change*) elenca opções de natureza variada para a mitigação das mudanças climáticas, classificando-as de acordo com a seu potencial de contribuição para a redução de emissões a curto prazo. As alternativas contemplam, por exemplo, medidas de eficiência energética, planejamento urbano, desenvolvimento e aplicação de novos materiais e a transição energética a partir de fontes de energia renováveis (RES – *Renewable Energy Sources*). Essa última alternativa, centrada na gerações eólica e fotovoltaica, é destacada no relatório como a que possui maior potencial para redução de emissões a curto prazo (IPCC, 2023).

A urgência em reduzir a emissão de gases do efeito estufa soma-se ao ganho em competitividade das tecnologias associadas às fontes renováveis, aos avanços na legislação e ao imenso potencial ainda não inteiramente explorado. Essa soma de fatores acabou criando o ambiente perfeito para o rápido crescimento das fontes de geração renovável (EPE, 2017b). Verifica-se, dessa forma, um contexto no qual a inserção das fontes renováveis são amplamente favorecidas, podendo atingir, tomando como base o cenário de referência nacional, uma capacidade instalada de 37,2 GW em 2031, no caso das micro e minigerações distribuídas (EPE, 2017a). Esse crescimento também é verificado na capacidade instalada das usinas sob o controle do despacho centralizado e programado do ONS (Operador Nacional do Sistema Elétrico), conforme ilustrado na Figura 1.

Figura 1 – Evolução da capacidade instalada das usinas eólicas e fotovoltaicas sob o controle do despacho centralizado e programado do ONS.



Fonte: Adaptada de (ONS, 2024).

Esse aumento expressivo, no entanto, também possui impactos negativos sobre a rede, uma vez que interfere em aspectos fundamentais do seu funcionamento. Um dos problemas mais notórios da inserção de RES em sistemas elétricos é o seu caráter intermitente, o que resulta no aumento da variabilidade de potência em seu ponto de conexão à rede. Os efeitos dessa variabilidade, inerentes ao processo de produção de energia através de geração eólica e fotovoltaica, podem ser categorizados de acordo com o período de tempo associado a sua ocorrência. Alguns desses efeitos são listados na Tabela 1. Como consequência da ocorrência desses efeitos, alguns países (na figura de seus Operadores de Sistema) já impõem requisitos de variabilidade máxima em seus códigos de rede (DIAZ, 2019) (CRACIUN et al., 2012).

Diversas soluções já foram propostas na literatura para os desafios associados à variabilidade de potência em RES. As abordagens tradicionais focam, principalmente, em esquemas de controle, como controle de inércia, de ângulo de inclinação e de tensão do barramento CC. No entanto, esses métodos requerem, em algum grau, dissipação de energia, já que carecem da possibilidade de armazenamento da energia gerada. Como alternativa, outras abordagens, mais recentes na literatura, dão ênfase a métodos de suavização baseados em sistemas de armazenamento de energia, através da utilização de tecnologias como *flywheels*, supercapacitores e, mais comumente, sistemas de armazenamento baseados em baterias (BESS – *Battery Energy Storage System*) ou implementações híbridas (BARRA et al., 2021).

Tabela 1 – Categorização dos efeitos gerados pela variabilidade de potência de acordo com o período de tempo associado.

Tempo	Efeito
0,1-1 s	<i>Flicker</i> de tensão
0,02 s - 15 min	Desvios de frequência
1 min - 1 h	Aumento da necessidade de reservas operativas
>1 h	Erros no despacho de unidades

Fonte: Adaptada de (ASENSIO et al., 2021).

Paralelamente, viu-se, nos últimos anos, o crescimento significativo em competitividade dos BESSs, principalmente em decorrência do seu crescente uso na indústria eletrônica e, mais recentemente, na indústria automotiva. Quando comparado a outras alternativas, os BESSs se destacam por possuir maior densidade de energia, o que constitui uma vantagem para aplicações de suavização de potência (SUKUMAR et al., 2018). A análise da suavização de potência pode ser entendida como uma análise comparativa da variabilidade de potência antes e depois da aplicação da suavização. Por se tratar de um fenômeno complexo, a variabilidade de potência não deve ser analisada de forma unidimensional. Para que isso não aconteça, diversos aspectos devem ser avaliados para a construção de uma compreensão abrangente desse fenômeno. Portanto, as métricas para avaliar a eficácia de suavização de potência podem ser agrupadas, de forma generalista, em medidas associadas à intensidade das variações, à probabilidade de ocorrência das variações e à caracterização em frequência das variações (ASENSIO et al., 2021).

Ao examinar os artigos deste campo, no entanto, é evidente a prevalência da comparação visual como método predominante para avaliar os diferentes métodos de suavização (BARRA et al., 2021), enquanto a utilização de indicadores numéricos é escassa. Quando esses indicadores são empregados, observa-se que muitas vezes são aplicados de maneira que podem distorcer as comparações entre os métodos de suavização ou até mesmo levar a conclusões incorretas (ASENSIO et al., 2021), contrastando com as boas práticas encontradas na literatura especializada do campo da Estatística. Nesse contexto, estudos aprofundados acerca dos métodos de suavização e das métricas utilizadas para avaliá-los continuam sendo necessários. Além disso, é crucial uma caracterização adequada do fenômeno da variabilidade de potência, incorporando uma abordagem multidisciplinar que se baseie em trabalhos realizados nos campos da Física e da Estatística.

1.1 OBJETIVOS

Com base no cenário descrito acima, o presente trabalho tem como objetivo geral analisar o fenômeno da variabilidade de potência, dando ênfase à sua aplicação para a validação de métricas utilizadas na comparação de algoritmos de geração de referência para suavização de potência e no contexto de microrredes CA compostas por geração fotovoltaica e BESS.

1.1.1 Objetivos Específicos

Para atender ao objetivo principal, foram elencados os seguintes objetivos específicos a serem atendidos:

- Aplicar um algoritmo de geração de referência para suavização de cada família sobre um conjunto de dados experimentais;
- Fornecer subsídios, a partir do estudo da variabilidade de potência, para avaliar os indicadores comumente utilizados na literatura para comparar algoritmos de suavização;

- Propor, se necessário, novas métricas para avaliação de algoritmos de geração de referência;
- Aplicar, sobre um conjunto de dados experimentais, métodos da literatura de caracterização de suavização de potência baseados em funções densidade de probabilidade.

1.2 ORGANIZAÇÃO DA DISSERTAÇÃO

Esta dissertação está organizada em capítulos, tal qual especificado a seguir:

- **Capítulo 2:** Nesse capítulo, realiza-se uma introdução aos métodos de suavização de potência baseados em sistemas de armazenamento de energia, incluindo uma contextualização acerca da variabilidade de potência e dos requisitos presentes em códigos de rede. Para isso, as principais famílias de algoritmos de geração de referência para suavização de potência são apresentadas. Apresenta-se, também nesse capítulo, uma introdução a alguns conceitos pertinentes da Estatística, necessários ao entendimento do fenômeno da variabilidade de potência.
- **Capítulo 3:** Nesse capítulo, realiza-se uma análise comparativa, baseada em dados experimentais, de dois métodos de geração de referência para geração de potência. Essa análise subsidia a avaliação das métricas tipicamente utilizadas nesse contexto e suas limitações. Com base nas vulnerabilidades observadas, novas métricas são sugeridas.
- **Capítulo 4:** Nesse capítulo, tem-se como foco o uso de funções de densidade de probabilidade para caracterização de variabilidade de potência em fontes renováveis intermitentes. Busca-se realizar uma revisão da literatura em busca das propostas de caracterização já implementadas, utilizando-as no conjunto estudado de dados experimentais. Com base nos resultados obtidos, torna-se possível tecer comentários acerca das limitações encontradas e possibilidades de evolução.
- **Capítulo 5:** Por fim, nesse capítulo, são realizadas as considerações finais e as propostas para trabalhos futuros. Dá-se ênfase, também, às principais contribuições e aos frutos desta dissertação.

O presente trabalho é resultado de uma pesquisa desenvolvida durante o projeto "E-Lounge – Uma solução para o reabastecimento de veículos elétricos de frotas no Brasil", financiado pela EDP no contexto da Chamada Estratégia 22 (Mobilidade Elétrica) do programa de P&D (Pesquisa e Desenvolvimento) da ANEEL (Agência Nacional de Energia Elétrica). Inicialmente, foi planejado fazer um estudo de suavização da potência absorvida/injetada da rede elétrica pela microrrede que compõe o E-Lounge. Contudo, devido à diferença no cronograma entre a execução do P&D e o desenvolvimento do presente trabalho, o autor optou por utilizar dados públicos do Laboratório Nacional de Energias Renováveis dos Estados Unidos (NREL –*National Renewable Energy Laboratory*) para conduzir as análises. Entretanto, é crucial destacar que

todo o desenvolvimento e as contribuições associadas a este trabalho podem ser implementados no contexto de microrredes com fontes de geração renovável, estações de reabastecimento de veículos elétricos e sistemas de armazenamento de energia.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, a definição de variabilidade de potência, alguns conceitos pertinentes do campo da estatística e as principais características de um sistema de suavização de potência são apresentados. Além disso, também são introduzidos os principais algoritmos de cada família de geração de referência para suavização de potência, juntamente com as métricas comumente utilizadas para avaliá-los.

2.1 VARIABILIDADE DE POTÊNCIA NA GERAÇÃO FOTOVOLTAICA

Antes de tratar das características gerais dos sistemas de suavização de potência, é pertinente compreender satisfatoriamente o conceito de variabilidade de potência. Variabilidade de potência, no contexto deste trabalho, se refere à junção conceitual de duas características inerentes à geração fotovoltaica (também aplicáveis a geração eólica): seu caráter intermitente e estocástico. Por caráter intermitente, entende-se que a geração fotovoltaica é caracterizada por interrupções em seu fornecimento, tipicamente associadas à passagem de nuvens, capazes de gerar grandes variações em sua potência produzidas de forma abrupta. Já o caráter estocástico está associado à aleatoriedade dessas flutuações de potência, difíceis de prever com base apenas no estado anterior à variação.

A variabilidade de potência pode ser avaliada através da estatística dos seus incrementos. Esses incrementos – que também podem ser denominados de desvios, flutuações ou variações – são dados pelas diferenças entre duas medições separadas por um intervalo de análise específico, escolhido de acordo com o fenômeno que se deseja avaliar. Naturalmente, também é possível avaliar fenômenos com frequência inferior (ou período superior) à frequência de amostragem.

Mais formalmente:

Considere o conjunto de medidas de potência $P = \{P_1, P_2, \dots, P_N\}$, amostradas com uma frequência de $1/\Delta t$. As variações são dadas pela diferença entre medidas consecutivas — temporalmente separadas por um Δt —, ou seja, $\Delta P = P_k - P_{k-1}$. Os incrementos podem ser tanto positivos quanto negativos, dependendo da direção da variação. O valor escolhido para Δt determina a frequência e deve ser ajustado de acordo com a natureza do fenômeno a ser analisado.

Os códigos de rede, documentos que regem o funcionamento de sistemas de potência de grande porte como o Sistema Interligado Nacional (SIN), costumam limitar as variações de potência não com base em seu valor absoluto, mas com base em sua taxa de variação em relação à sua capacidade instalada. Na seção a seguir, a questão regulatória associada à limitação das variações de potência é brevemente discutida.

2.1.1 Regulações Normativas Associadas à Flutuação de Potência em Sistemas Fotovoltaicos

O crescimento da geração solar fotovoltaica e sua integração em larga escala nas redes elétricas ao redor do mundo têm levado os operadores dos sistemas elétricos a reavaliar e atualizar os requisitos e normas vigentes para a conexão desses sistemas às redes elétricas (LANDERA et al., 2023). Esses conjuntos de requisitos e normas são comumente conhecidos como procedimentos de rede ou códigos de rede.

Nesse contexto, os operadores do sistema desempenham um papel fundamental na gestão e operação dos sistemas elétricos, sendo responsáveis por manter a capacidade de reserva suficiente para prever discrepâncias entre a demanda e a oferta de energia elétrica. Assim, eles coordenam a operação dos sistemas de geração que estão conectados à Rede Básica, garantindo o equilíbrio entre geração e consumo de energia em tempo real (DIAZ, 2019).

Quando ocorrem variações rápidas de potência no sistema, gerando discrepâncias entre demanda e oferta, a inércia do sistema, decorrente principalmente da geração hidrelétrica, ajuda a manter o sistema estável. No entanto, mesmo com essa capacidade de resposta, essas discrepâncias acabam resultando em desvios de frequência, conforme discutido por Ackermann et al. (2013). À medida que a penetração da geração solar fotovoltaica aumenta, esses fenômenos se tornam cada vez mais críticos, devido à falta de inércia, à intermitência e à grande variabilidade de potência.

Nas últimas décadas, uma ampla gama de estudos tem sido conduzida nesse campo de pesquisa, abordando diversas questões relacionadas à integração de fontes de energia renovável nas redes elétricas. Esses estudos abrangem uma variedade de tópicos, desde códigos de rede para a incorporação de energia solar fotovoltaica (CRACIUN et al., 2012) até normas globais para a interconexão de sistemas fotovoltaicos (RANGARAJAN et al., 2017). Para lidar com as consequências negativas da alta penetração de usinas fotovoltaicas de grande porte no sistema, alguns operadores do sistema impuseram nos códigos de rede taxas de rampa ascendente e descendente limitadas para as usinas fotovoltaicas, as quais precisam ser respeitadas para que grandes sistemas fotovoltaicos sejam conectados à rede elétrica.

Exemplos de países que já estabeleceram regulamentações para taxa de rampa podem ser observados na Tabela 2, com destaque para Porto Rico, que foi o pioneiro na regulamentação dos limites para flutuação de potência gerada por parques fotovoltaicos. Observa-se ainda da Tabela 2 que, no Brasil, a regulamentação ainda está em andamento, não havendo limitações estabelecidas para a variação da potência injetada no sistema elétrico (DIAZ, 2019).

Como consequência dessas limitações, os proprietários de usinas enfrentam o desafio de garantir que suas instalações atendam aos requisitos de taxa de rampa máxima definidos nas normas de conexão à rede elétrica. No entanto, como as flutuações na geração de energia fotovoltaica podem ser significativas e imprevisíveis, encontrar e implementar soluções para suavizar essas variações de modo a cumprir os requisitos regulatórios não é uma tarefa simples. Nesse cenário, o desenvolvimento de sistemas de suavização de potência emerge como uma

solução promissora e de grande interesse para os operadores do sistema e proprietários de usinas fotovoltaicas.

Tabela 2 – Requisitos de taxa de rampa máxima de potência ativa definidos nos códigos de rede de diversos países.

País	Operador/ órgão	Rampa Ascendente	Rampa Descendente
Alemanha	E.ON	10%/min	Não requerido
China (< 30 MW)	CEPRI	3 MW/min	3 MW/min
China (30~150 MW)	CEPRI	Capacidade instalada divida por 10/min	Capacidade instalada divida por 10/min
China (> 150 MW)	CEPRI	15 MW/min	15 MW/min
Irlanda	EIRGIRD	30 MW/min	Não requerido
México	CENACE	2~5%/min	1~5%/min
Porto Rico	PREPA	10%/min	10%/min
Padrões Europeus	ENTSO-E	Não requerido	Não requerido
Brasil	ONS	Não regulamentado	Não regulamentado

Fonte: Adaptada de (DIAZ, 2019) e (CRACIUN et al., 2012).

2.2 CARACTERÍSTICAS GERAIS DE SISTEMAS DE SUAUIZAÇÃO DE POTÊNCIA

Conforme descrito anteriormente, com o aumento da penetração da geração baseada em fontes de energia renováveis, como solar e eólica, surge uma preocupação crescente em relação à variabilidade de potência despachada por essas fontes e ao seu impacto na rede elétrica. Nesse contexto, sistemas de suavização de potência podem ser utilizados para atenuar a variabilidade da potência, sem comprometer a geração baseada em energia renovável. Assim, para avançar no estado da arte nessa área de pesquisa, faz-se necessário revisar os principais algoritmos de geração de referência para suavização propostos na literatura e as principais figuras de mérito utilizadas em trabalhos científicos.

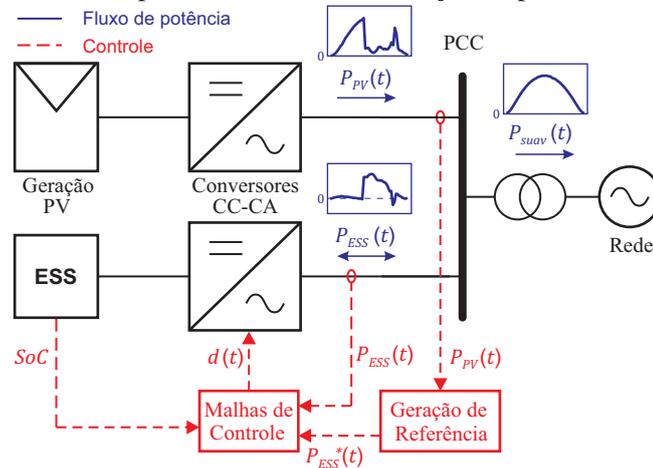
Contudo, para uma melhor contextualização da aplicação, antes de abordar os algoritmos de suavização e as métricas utilizadas para avaliá-los, é importante descrever os elementos que compõem um sistema de suavização de potência. Dessa forma, nesta seção, são abordadas: as principais tecnologias de armazenamento utilizadas nesse contexto; a topologia típica de um sistema de suavização; e a estrutura conceitual do esquema de controle utilizado.

2.2.1 Sistemas de Suavização de Potência Baseados em ESSs

A natureza intermitente das fontes renováveis, em especial a eólica e a fotovoltaica, impõe uma variabilidade indesejável sobre a rede elétrica a qual estão acopladas. Os métodos tradicionais para minimização desse problema baseiam-se na operação fora do ponto de máxima potência (MPP – *Maximum Power Point*), o que resulta na perda de parte da energia gerada. Exemplos de estratégias de suavização de potência que não são baseadas no uso de ESSs podem ser encontradas em (RAN; BUMBY; TAVNER, 2004), (SENJYU et al., 2006) e (UEHARA et al., 2011). Há, no entanto, diversas alternativas que são capazes de manter o sistema operando em sua capacidade de geração máxima e, simultaneamente, atingir o objetivo da suavização de potência.

No contexto apresentado, os sistemas de armazenamento de energia (ESS – *Energy Storage System*) desempenham um papel fundamental como solução para suavizar as variações de potência decorrentes da geração renovável, tanto a curto quanto a longo prazo, garantindo sua operação no MPP. Além de mitigar flutuações imediatas na geração, os ESSs permitem manter a eficiência operacional da fonte renovável ao otimizar continuamente seu ponto de operação (LAMSAL et al., 2019). Essa abordagem contribui significativamente para a estabilidade e confiabilidade do sistema de energia, proporcionando uma integração mais eficaz e sustentável das fontes renováveis na matriz energética. Um exemplo de sistema que contempla geração fotovoltaica e ESSs é apresentado na Figura 2.

Figura 2 – Exemplo de sistema de suavização de potência com ESS.



Fonte: Própria do Autor (2024).

Conforme pode ser observado na Figura 2, um sistema de suavização de potência com ESS é composto por um ESS e um conversor estático que o conecta ao ponto de acoplamento comum (PCC – *Point of Common Coupling*). Este sistema é responsável por injetar/absorver potência no PCC, de modo que a potência entregue à rede, $P_{suav}(t)$, esteja suavizada, respeitando as regulamentações normativas associadas à flutuação de potência. Ele possui um gerador de referências que, a partir da potência $P_{PV}(t)$, gerada pela fonte renovável, define a potência de referência a ser injetada pelo ESS, $P_{ESS}^*(t)$. Com a potência de referência determinada, o

conversor estático de interface do ESS é controlado para injetar/absorver a potência $P_{ESS}(t)$, por meio da definição dos ciclos de trabalho de suas chaves semicondutoras (aqui representadas por $d(t)$). É importante notar que o sistema de armazenamento não pode injetar potência na rede elétrica caso não possua energia armazenada suficiente, sendo, portanto, necessário avaliar também seu estado de carga (SoC, do inglês *State of Charge*). Além disso, na Figura 2, as medições de tensão e corrente foram omitidas, no entanto, é crucial destacar que essas informações são essenciais para viabilizar a implementação das malhas de controle.

Diferentes tecnologias de ESSs são atualmente empregadas no mercado. Cada tecnologia possui um conjunto próprio de características distintas. Contudo, para aplicação em sistemas de suavização de potência, é importante que os ESSs possuam:

- **Alta densidade de energia e de potência:** O sistema de armazenamento deve ser capaz de prover potência de modo suficiente a contrabalancear as flutuações da aplicação, bem como dispor de energia para isso. Um dos dois fatores, densidade de potência ou de energia, pode ser mais relevante, a depender do intervalo de tempo da suavização;
- **Vida útil longa:** Projetos de geração (ou do setor elétrico como um todo) são idealizados para operar durante longos períodos de tempo. Assim, espera-se que um equipamento voltado para essa aplicação seja capaz de operar por muitos anos;
- **Custo capital viável:** Os custos de capital de potência e de energia ditam a viabilidade econômica de um projeto. Em aplicações de suavização de curtíssimo prazo, o custo de potência é a variável mais importante, enquanto, para suavizações com maior horizonte, predomina a importância do custo de capital de energia;
- **Eficiência elevada:** Uma vez que a própria natureza da aplicação envolve a absorção e injeção de potência, espera-se que o sistema de armazenamento possua eficiência elevada;
- **Baixa taxa de autodescarga:** Especialmente para sistemas de suavização voltados para intervalos de tempo maiores, essa característica garante que não haverá perdas significativamente grandes da energia armazenada no decorrer do tempo.

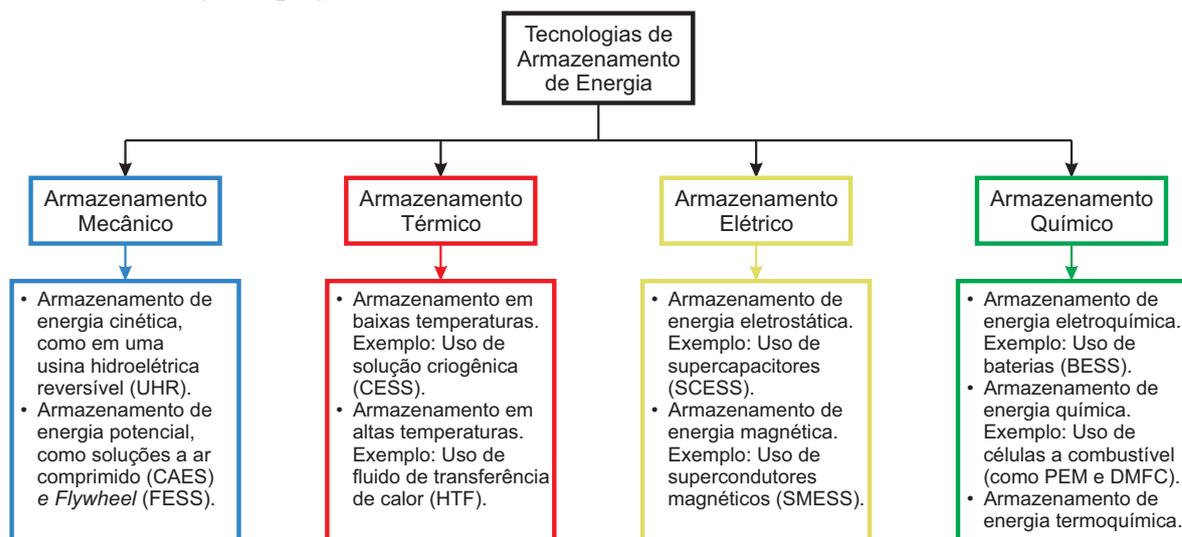
Deve-se ressaltar que os requisitos em questão devem ser avaliados no contexto de cada projeto, de modo que os seus pesos sobre a tomada de decisão variam com base nas circunstâncias da aplicação. Para atender a esses requisitos e escolher um ESS adequado para a aplicação, é de suma importância que se conheça as principais tecnologias de ESSs, conforme descrito na subseção a seguir.

2.2.2 Principais Tecnologias de ESSs Utilizadas em Potências Elevadas

São muitas as possíveis formas de se armazenar energia visando sua posterior utilização. A diversidade de tecnologias disponíveis para ESSs é refletida na Figura 3, que apresenta uma árvore de classificação de ESSs de acordo com a tecnologia empregada (CHEN et al., 2009). Esta classificação abrange desde sistemas baseados em baterias convencionais até soluções avançadas,

como o uso de armazenamento térmico e a célula a combustível. É fundamental compreender que cada tecnologia possui características distintas, sendo algumas mais adequadas que outras para as necessidades específicas de suavização de potência no contexto de geração de energia renovável.

Figura 3 – Classificação de sistemas de armazenamento de energia de acordo com a tecnologia empregada.



Fonte: Própria do Autor (2024).

Em (BARRA et al., 2021), os autores elencam as principais tecnologias de sistemas de armazenamento em potência elevada. A lista apresentada pode ser entendida como um subgrupo das diferentes tecnologias existentes, destacando aquelas mais viáveis para a suavização de potência. Os ESSs listados são: (i) baseado em supercondutores magnéticos (SMES – *Superconducting Magnetic Energy Storage*); (ii) baseado em flywheel (FESS – *Flywheel Energy Storage System*); (iii) baseado em supercapacitores (SCES – *Supercapacitor Energy Storage System*); (iv) baseados em baterias (BESS – *Battery Energy Storage System*); e (v) sistemas híbridos (HESS - *Hybrid Energy Storage System*). Uma classificação semelhante pode ser observada em (LAMSAL et al., 2019), com a adição uma categoria para sistemas baseados em células de combustível associadas a um eletrolizador (FC/ELZ – *Fuel Cell and Electrolyzer Hybrid System*). A seguir, as tecnologias mais comuns dentro do contexto de suavização de potência, listadas em (BARRA et al., 2021), são melhor detalhadas:

- i. Sistema de armazenamento baseado em supercondutores magnéticos (SMES):** Um SMES utiliza uma bobina supercondutora para acumular energia na forma de campo magnético. Para isso, a bobina deve ser resfriada para um valor abaixo de uma temperatura crítica, fazendo com que as perdas ôhmicas sejam virtualmente nulas devido a resistência insignificante da bobina super condutora (XUE; CHENG; SUTANTO, 2005). Um SMES típico possui baixa densidade de energia, alta densidade de potência, uma elevada vida útil de ciclos de carga e descarga e um tempo de resposta curto. Uma revisão detalhada sobre

essa tecnologia pode ser encontrada em (VULUSALA; MADICHETTY, 2017) e, com maior ênfase nas aplicações, em (ALI; WU; DOUGAL, 2010). No contexto da aplicação abordada neste trabalho, Said et al. (2019) fazem uso de um SMES para suavização de potência proveniente de geração fotovoltaica em uma microrrede.

Essa tecnologia se destaca positivamente por possuir uma vida útil desassociada de seu ciclo de trabalho, além de dispor de confiabilidade e eficiência elevadas. No entanto, suas desvantagens estão associadas ao seu alto custo, bem como à necessidade de um sistema de refrigeração. Adicionalmente, essa tecnologia requer a presença de campos magnéticos de alta magnitude para sua operação (KOOHI-FAYEGH; ROSEN, 2020).

- ii. Sistema de armazenamento baseado em *flywheel* (FESS):* Um FESS utiliza uma massa girante para armazenar a energia na forma de energia cinética. Para isso, a massa girante é mecanicamente conectada a uma máquina elétrica de velocidade variável, atuando ora como motor, ora como gerador, a depender da necessidade. O sistema é conectado eletricamente à rede através de conversores estáticos de potência. Uma revisão do estado da arte e das perspectivas futuras para essa tecnologia pode ser encontrada em (LI; PALAZZOLO, 2022). Em (DÍAZ-GONZÁLEZ et al., 2014) e (ZHENG et al., 2012), um FESS é utilizado para suavizar, respectivamente, as gerações de origens eólica e fotovoltaica.

Um FESS típico possui alta densidade de energia, alta densidade de potência, uma vida útil intermediária de ciclos de carga e descarga e um tempo de resposta curto. Entre os aspectos positivos dos FESSs, destacam-se a maturidade da tecnologia, a pequena área exigida para sua implementação e o seu baixo impacto ambiental. No entanto, do ponto de vista negativo, essa tecnologia apresenta elevado custo, além de suscitar questionamentos associados à poluição sonora e segurança no trabalho (KOOHI-FAYEGH; ROSEN, 2020).

- iii. Sistema de armazenamento baseado em supercapacitores (SCESS):* Um SCESS utiliza capacitores elétricos de camada dupla, uma classe de capacitores que possui capacitâncias e densidades de potência superiores às de capacitores comuns. Nessa tecnologia, a energia é armazenada na forma de um campo elétrico na interface que separa os eletrodos. As características elétricas, modelagem, aplicações e perspectivas futuras dessa tecnologia estão detalhadas em (BERRUETA et al., 2019). A título de exemplo, aplicações dessa tecnologia no contexto de suavização de potência e áreas correlatas podem ser observadas em (ABBEY; JOOS, 2007) e (AMMAR; JOÓS, 2014).

Um SCESS típico possui baixa densidade de energia, alta densidade de potência, uma longa vida útil de ciclos de carga e descarga e um tempo de resposta curto. Apesar de apresentar uma elevada densidade de potência, o que constitui seu aspecto mais atrativo, essa tecnologia possui algumas limitações. Entre elas, destacam-se: a associação entre vida útil e desbalanço de tensão entre as células/tensões máximas suportadas; impactos ambientais; e problemas associados à segurança (KOOHI-FAYEGH; ROSEN, 2020).

- iv. Sistema de armazenamento baseado em baterias (BESS):* Um BESS utiliza baterias

para armazenar a energia de forma eletroquímica, em que os ciclos de carga e descarga são realizados através de uma reação química reversível. Um BESS típico possui alta densidade de energia, baixa densidade de potência, uma pequena vida útil de ciclos de carga e descarga e um tempo de resposta lento. O uso de BESS, no entanto, ainda enfrenta dificuldades para sua disseminação em função do seu custo. Outro aspecto potencialmente problemático é a interdependência entre vida útil e níveis de carga e descarga (KOOHI-FAYEGH; ROSEN, 2020).

Dentre as diferentes variedades de bateria, as de íons de lítio (também conhecidas por íon-lítio) despontam como uma alternativa mais viável devido à sua alta densidade energética e baixa taxa de autodescarga. Uma revisão de sistemas de armazenamento baseados em baterias, dando ênfase em baterias de íon-lítio, pode ser encontrada em (ZUBI et al., 2018). Em (LI; HUI; LAI, 2013) e (ATIF; KHALID, 2020), BESSs são utilizados para suavizar a potência ativa oriunda de parques eólicos e fotovoltaicos.

- v. **Sistema de armazenamento baseado em sistemas híbridos (HESS):** Dado que existem diversas opções para a composição de um sistema de armazenamento, as especificidades de cada aplicação acabam por determinar a alternativa mais adequada. Em alguns casos, mais de uma classe de ESS pode ser utilizada em função das características complementares entre as tecnologias. A combinação mais comum envolve o uso, simultâneo, de BESS e SCESS, de modo a combinar a alta densidade de energia do BESS com a alta densidade de potência do SCESS. Como consequência, os dois sistemas, atuando em conjunto, são capazes de lidar com variações de alta e de baixa frequência simultaneamente. Os HESS, em suas diversas possíveis configurações, foram alvos de investigação em diversos trabalhos, tais como (HEMMATI; SABOORI, 2016) e (CHONG et al., 2016). No contexto da aplicação avaliada neste trabalho, em (WAN et al., 2021) e (ABDALLA et al., 2023) é possível observar exemplos da utilização dessa composição para fins de suavização de potência.

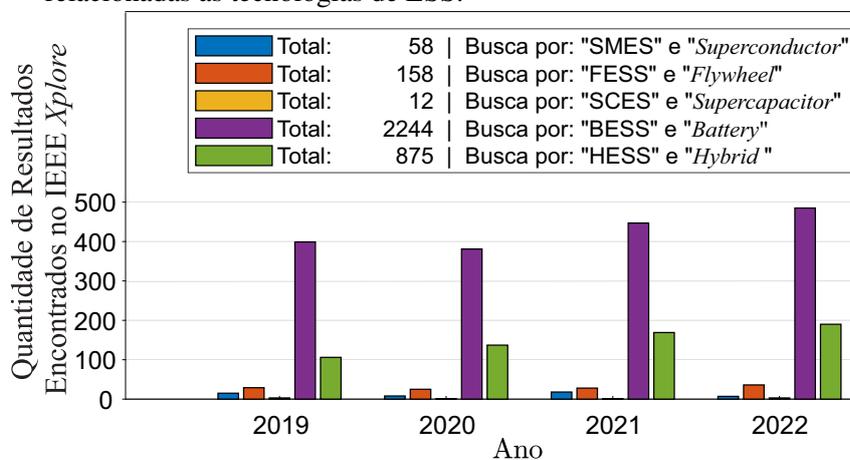
2.2.2.1 Comentários Gerais Acerca das Tecnologias

Dentre as tecnologias de ESS para potência elevada, o uso de BESS e de HESS vem ganhando cada vez mais destaque na literatura. Para entender a relevância dessas duas tecnologias no cenário recente de pesquisa, a Figura 4 apresenta a quantidade de trabalhos encontrados no banco de dados do IEEE *Xplore*, entre os anos de 2019 e 2023, ao buscar palavras-chave relacionadas às tecnologias de ESS elencadas por Barra et al. (2021). Os resultados apresentados na Figura 4 indicam que os campos de pesquisa associados BESS e HESS continuam relevantes.

Em (KOOHI-FAYEGH; ROSEN, 2020), é apresentada uma síntese das vantagens e desvantagens de cada tecnologia, bem como um sumário das principais características de cada tecnologia, tais como densidade de potência, densidade de energia por volume e por peso, eficiência dos ciclos e vida útil. Uma comparação simplificada dessas características para o

BESS, FESS, SCESS e SMES é apresentada na Tabela 3.

Figura 4 – Resultados encontrados no IEEE Xplore (por ano) ao buscar palavras-chaves relacionadas as tecnologias de ESS.



Fonte: Própria do Autor (2024).

Tabela 3 – Características técnicas das principais tecnologias de ESSs de alta potência.

Característica	BESS (Íon-lítio)	FESS	SCESS	SMES
Densidade espec. de energia (Wh/kg)	75-200	5-100	0,5-5	1-10
Densidade vol. de energia (kWh/m ³)	200-600	20-100	4-10	0,2-2,5
Densidade espec. de potência (W/kg)	150-500	500-4.000	1.000-10.000	500-2.000
Densidade vol. de potência (MW/m ³)	0,4-2	1-2,5	0,4-10	1-4
Custo de capital – Energia (US\$/kWh)	380-2.500	2.000-5.000	500-15.000	1.000-10.000
Custo de capital – Potência (US\$/kW)	1.200-4.000	150-400	100-400	200-500
Eficiência (%)	95-99	90-95	90-98	95-98
Tempo de descarga (s)	10-20.000	0,3-50	0,3-50	0,1-10
Temperatura de operação (°C)	-20/55	-40/40	-40/75	-50/60
Taxa de autodescarga (%/dia)	0,1-0,5	10-100	10-40	5-13
Vida útil (em anos)	5-20	15-20	5-15	15-25
Vida útil (em milhares de ciclos)	1-10	20-100	50-1.000	50-500

Fonte: Adaptada de (BARRA et al., 2021).

Os requisitos desejáveis para ESSs, conforme listados na subseção anterior, desempenham um papel crucial na orientação da escolha da tecnologia mais adequada para um sistema de suavização de potência. A análise da Tabela 3 fornece ao leitor uma visão abrangente das características técnicas de BESSs, FESSs, SMESs e SCESSs. Ao considerar cada requisito, torna-se evidente que BESSs destacam-se em vários aspectos essenciais. De fato, a densidade de energia, a eficiência e a taxa de autodescarga de BESSs são os principais atrativos dessa tecnologia.

Outro ponto importante a ser considerado é a maturidade de cada uma dessas tecnologias. A maturidade tecnológica do BESS é evidenciada pelo seu amplo uso em diversas aplicações

atuais, que vão desde a mitigação dos problemas de alta demanda de energia na rede causados por carregadores de veículos elétricos (POLAT et al., 2023) até sua utilização em microrredes (SUN et al., 2021). Embora o custo inicial associado à aquisição e instalação um BESS seja elevado, a crescente adoção dessa tecnologia tem impulsionado avanços em sua fabricação, resultando em uma tendência de redução de custos ao longo do tempo.

2.2.3 Topologias Típicas de Sistemas com Geração Fotovoltaica e BESS

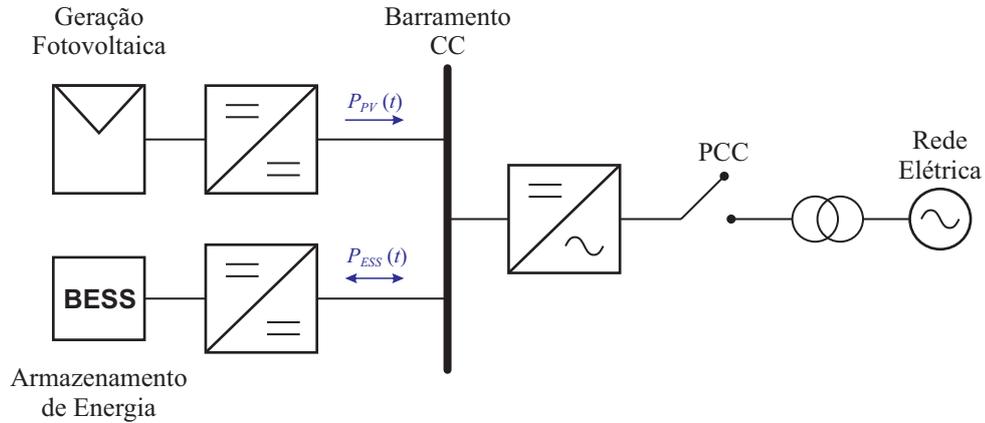
Atualmente, a maior parte da utilização de BESS está centrada em microrredes, onde esses elementos desempenham um papel fundamental na busca por maior confiabilidade e inércia. Em (ESKANDARI et al., 2022), os autores destacam que, por exemplo, a baixa inércia de unidades de geração distribuída conectadas a inversores, decorrentes de microgeração de resposta lenta e fontes renováveis intermitentes, pode ser melhorada pelo uso de BESS. Ao fornecer armazenamento de energia localmente, os BESSs podem reduzir a dependência da microrrede em fontes de energia externas e, assim, aumentar sua resiliência e confiabilidade operacional.

Nesse cenário, as microrredes são sistemas elétricos de potência que incorporam fontes de geração, armazenamento de energia e cargas, podendo ou não estar conectadas a uma rede principal através de um ponto de acoplamento comum (PCC). Quando o PCC está conectado à rede principal, a microrrede opera no modo conectado à rede (ou *grid-tied mode*). Por outro lado, quando o PCC não está conectado à rede principal, diz-se que essa opera no modo ilhado (ou *island mode*), sendo frequentemente utilizada em locais geograficamente isolados da rede elétrica principal (SUCH; MASADA, 2017). Essas microrredes ainda podem ser classificadas em microrredes CC, microrredes CA ou híbridas, dependendo do tipo de energia predominante em seu barramento principal. Essa distinção entre microrredes CC e CA influencia as estratégias de controle, a seleção de componentes e a operação desses sistemas. No contexto deste trabalho, ela também afeta o posicionamento do BESS no sistema.

Mesmo nas microrredes híbridas, devido à natureza dos sistemas fotovoltaicos e dos BESS de operarem em corrente contínua, suas conexões são geralmente restritas a duas configurações simplificadas: ambos conectados a um barramento CC único (Figura 5); ou ambos conectados a um barramento CA único (Figura 6).

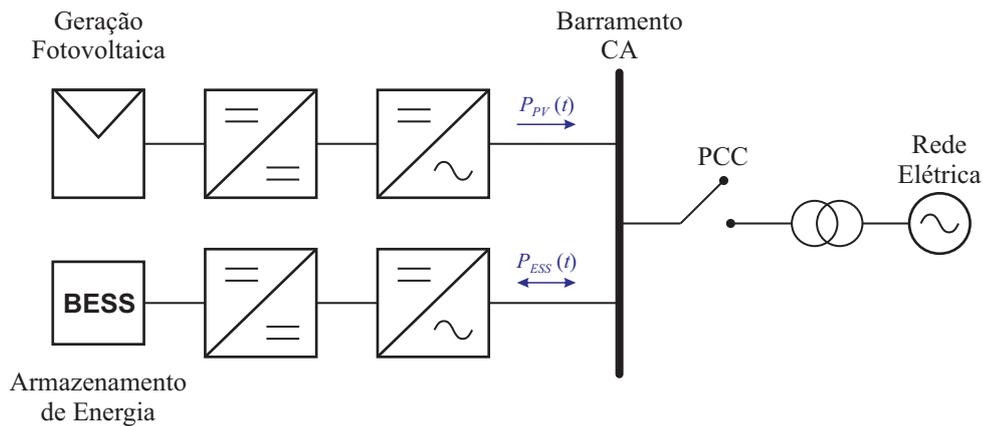
Ao considerar a conexão da geração fotovoltaica e do BESS em uma microrrede CC, conforme mostrado na Figura 5, observa-se que ambos os elementos apresentam um conversor CC/CC, utilizado como interface entre eles e o barramento CC. Nesse cenário, a potência é entregue ao barramento CC por meio de correntes e tensões contínuas. Por outro lado, ao considerar a conexão da geração fotovoltaica e do BESS em uma microrrede CA, como ilustrado na Figura 6, ambos os elementos apresentam um dois estágios de conversão para interface com o barramento CA, compostos por um conversor CC/CC e um conversor CC/CA. Nesse contexto, a potência é fornecida ao barramento CA por meio de correntes e tensões alternadas.

Figura 5 – Configuração simplificada de conexão de geração fotovoltaica e BESS em microrrede CC.



Fonte: Própria do Autor (2024).

Figura 6 – Configuração simplificada de conexão de geração fotovoltaica e BESS em microrrede CA.



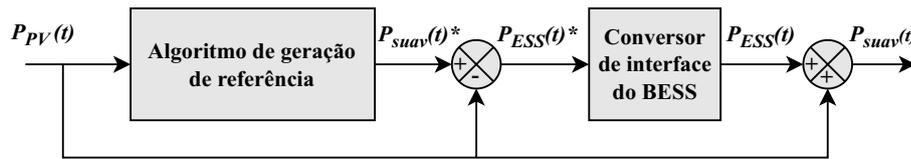
Fonte: Própria do Autor (2024).

Independentemente da natureza das correntes e tensões (contínuas ou alternadas), o perfil de potência ativa em sistemas elétricos permanece consistente. Portanto, do ponto de vista de suavização de potência, os algoritmos de geração de referência são válidos tanto para configurações com conexão de sistema fotovoltaico e BESS na microrrede através de barramento CC quanto através de barramento CA. Dessa forma, para a finalidade do estudo desenvolvido neste trabalho, o tipo de microrrede e sua topologia podem ser abstraídos. Contudo, ainda é necessário discutir o esquema de controle convencional utilizado para fins de suavização de potência.

Para garantir o correto funcionamento do BESS para suavização de potência, faz-se necessário controlar adequadamente os conversores de interface que conectam o BESS ao barramento CC ou CA. Nesse sentido, o esquema de controle convencional, normalmente utilizado em aplicações de suavização de potência, pode ser visualizado na Figura 7. O sistema de controle regula a transferência de energia entre o BESS e o barramento CC ou CA, gerando a referência de

potência $P_{BESS}^*(t)$ para os sistemas de controle de corrente e tensão do conversor de interface. A abordagem visa assegurar uma resposta eficaz às variações de potência, contribuindo para o cumprimento dos códigos de rede. Conforme exibido na Figura 7, o funcionamento desse esquema de controle depende da aplicação de algoritmos de geração de referência, os quais são abordados com mais detalhes na seção seguinte.

Figura 7 – Diagrama de blocos simplificado de um esquema de controle convencional para suavização de potência.



Fonte: Própria do Autor (2024).

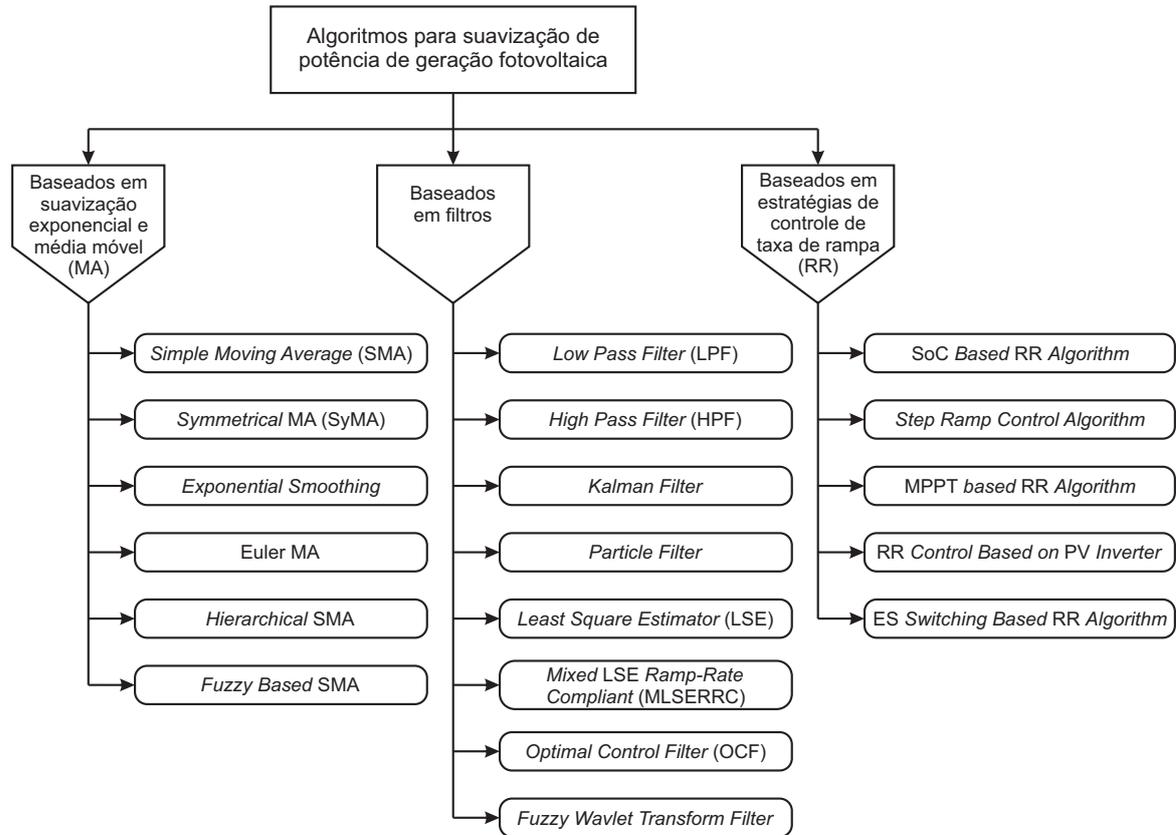
2.3 ALGORITMOS PARA GERAÇÃO DE REFERÊNCIA PARA SISTEMAS DE SUAVIZAÇÃO DE POTÊNCIA

Conforme apresentado no final da seção anterior, a quantidade de potência a ser absorvida/injetada pelo BESS é normalmente determinada por um algoritmo de geração de referência. Essa classe de algoritmos tem como objetivo primário mitigar a severidade das variações de potência. Matematicamente, isso se dá através da minimização da 1ª derivada de potência em relação ao tempo, podendo ser implementado de diferentes formas.

Na literatura, é possível encontrar diversas estratégias de suavização de potência baseadas em BESS, comumente classificadas pela família do algoritmo empregado na geração de referência (SUKUMAR et al., 2018). De acordo com essa forma de classificação, as técnicas podem ser divididas em: (i) abordagens baseadas em média móvel e suavização exponencial; (ii) técnicas baseadas em algoritmos de limitação de taxa de rampa; e (iii) métodos baseados no uso de filtros. Os principais métodos de cada uma dessas famílias são indicados na Figura 8.

Nesse contexto, a presente seção detalha os principais algoritmos de suavização de potência utilizados na literatura, indicando como são implementados e suas características operacionais, dando ênfase aos seguintes algoritmos: Média Móvel Simples e Taxa de Rampa.

Figura 8 – Categorização de algoritmos de suavização de potência utilizados para geração fotovoltaica.



Fonte: (SUKUMAR et al., 2018).

2.3.1 Média Móvel Simples (SMA – *Simple Moving Average*)

A média móvel é uma técnica de origem estatística que busca a suavização através do cálculo da média dos valores em uma janela móvel (MUYEEN; TAMURA; MURATA, 2009). Amplamente utilizada em áreas como Economia e Epidemiologia, essa técnica reduz a variabilidade e destaca padrões em sequências de dados. O subgrupo de técnicas baseadas em médias móveis contempla médias móveis duplas, exponenciais, cumulativas, ponderadas, adaptativas de Kaufman e a média móvel simples, sendo esta última a mais comum e, por esse motivo, escolhida para representar a família neste trabalho.

Na literatura, a Média Móvel Simples é comumente referida como SMA (do inglês *Simple Moving Average*), sendo calculada sobre um conjunto de n amostras consecutivas, comumente denominado “janela”. Para uma SMA parametrizada com uma janela de n amostras, a representação matemática do k -ésimo elemento ($P_{SMA,k}$) é dada por:

$$P_{SMA,k} = \frac{1}{n} \sum_{j=0}^{n-1} P_{k-j}, \quad (1)$$

em que $k \geq n$ e os elementos do conjunto de medições de potência ativa pré-suavização são representados por P_{k-j} .

Um dos parâmetros relevantes para a parametrização do método é a máxima variação de potência possível ($\Delta P_{\text{máx}}^{\text{pos}}$), já que, conforme mencionado anteriormente, seu valor é limitado em códigos de rede com o intuito de reduzir a variabilidade de potência. Matematicamente, $\Delta P_{\text{máx}}^{\text{pos}}$ é definida em função da máxima variabilidade natural ($\Delta P_{\text{máx}}^{\text{nat}}$) da planta e do número de amostras da janela móvel (PURI, 2014), tal que:

$$\Delta P_{\text{máx}}^{\text{pos}} = \frac{1}{n} \Delta P_{\text{máx}}^{\text{nat}}. \quad (2)$$

Note: Considere o conjunto P de medições de potência ativa após a suavização, dado por $P = \{P_{k-(n-1)}, P_{k-(n-2)}, \dots, P_{k-1}, P_k\}$. A variação de potência entre duas medições consecutivas para o k -ésimo termo é dada por:

$$\Delta P = \frac{1}{n} \cdot [P_{k-(n-2)} + \dots + P_{k-1} + P_k] - \frac{1}{n} \cdot [P_{k-(n-1)} + P_{k-(n-2)} + \dots + P_{k-1}]$$

$$\Delta P = \frac{1}{n} [P_k - P_{k-(n-1)}].$$

De modo a maximizar a equação acima, faz-se:

$$\Delta P_{\text{máx}} = \frac{1}{n} (\text{máx}[P_k] - \text{mín}[P_{k-(n-1)}]).$$

O mínimo valor possível é zero e o máximo valor possível é numericamente igual à capacidade de geração da planta. Assim, a máxima variação de potência é uma função da capacidade natural da planta e da janela de suavização escolhida. Naturalmente, é possível obter um resultado idêntico em módulo considerando valores de ΔP negativos.

Um exemplo numérico da aplicação da Equação (1) pode ser visualizado na Figura 9. Nesse exemplo, observam-se algumas características intrínsecas do uso de SMA em suavização de potência:

- A Equação (1) calcula a potência ativa pós-suavização para o instante k , representada por $P_{SMA,k}$, a partir da amostra atual e de amostras anteriores da sequência de potência ativa pré-suavização. Como consequência, a potência $P_{SMA,k}$ naturalmente representa as características passadas de geração do sistema, introduzindo um atraso de tempo no sinal pós-suavização em relação ao pré-suavização;
- Enquanto no conjunto original de dados a máxima variação foi de 39 (ocorrendo de $k = 5$ para $k = 6$), essa variação foi suavizada para 13,5 ao considerar $n = 2$, para 10,0 ao considerar $n = 3$ e para 3,0 ao considerar $n = 4$. Essa observação confirma que quanto maior for a janela móvel n , maior será a suavização.

Uma análise rápida das características listadas acima é suficiente para evidenciar o efeito da escolha do tamanho da janela móvel, definido pelo valor de n , sobre os valores obtidos. Portanto, é importante abordar também o dimensionamento da janela do filtro de média móvel para a suavização.

Figura 9 – Exemplo numérico da aplicação da Equação (1) para a obtenção de um conjunto suavizado de amostras de potência utilizando SMA, $P_{SMA,k}$. Diferentes tamanhos de janela móvel (parâmetro n) são considerados.

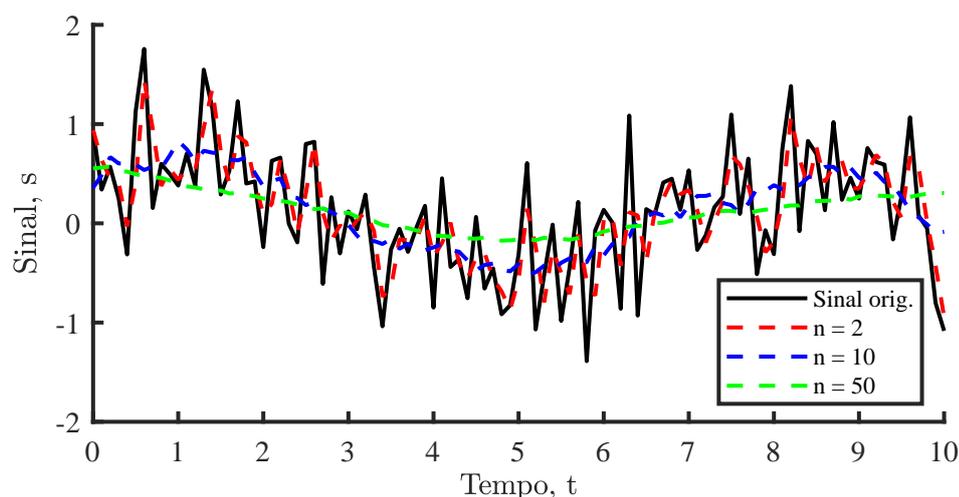
k		1	2	3	4	5	6	7	8
P_k		113	85	88	96	115	76	100	79
$P_{SMA,k}$	$n = 2$	-	99	86,5	92	105,5	95,5	88	89,5
	$n = 3$	-	-	95,3	89,7	99,7	95,7	97	85
	$n = 4$	-	-	-	95,5	96	93,8	96,8	92,5

Fonte: Própria do Autor (2024).

2.3.1.1 Dimensionamento da Janela de Suavização para SMA

Um exemplo visual do efeito do uso de diferentes tamanhos de janelas de cálculo pode ser visualizado na Figura 10. Na imagem, um sinal senoidal, acrescido de ruídos aleatórios, foi suavizado através da aplicação de uma SMA com tamanhos de janela de n de 2, 10 e 50. Em todos os casos, é possível constatar a ocorrência do fenômeno de suavização, já que a intensidade das flutuações foi reduzida.

Figura 10 – Efeito da escolha de diferentes janelas de cálculo sobre o desempenho do método SMA na suavização de sinais.



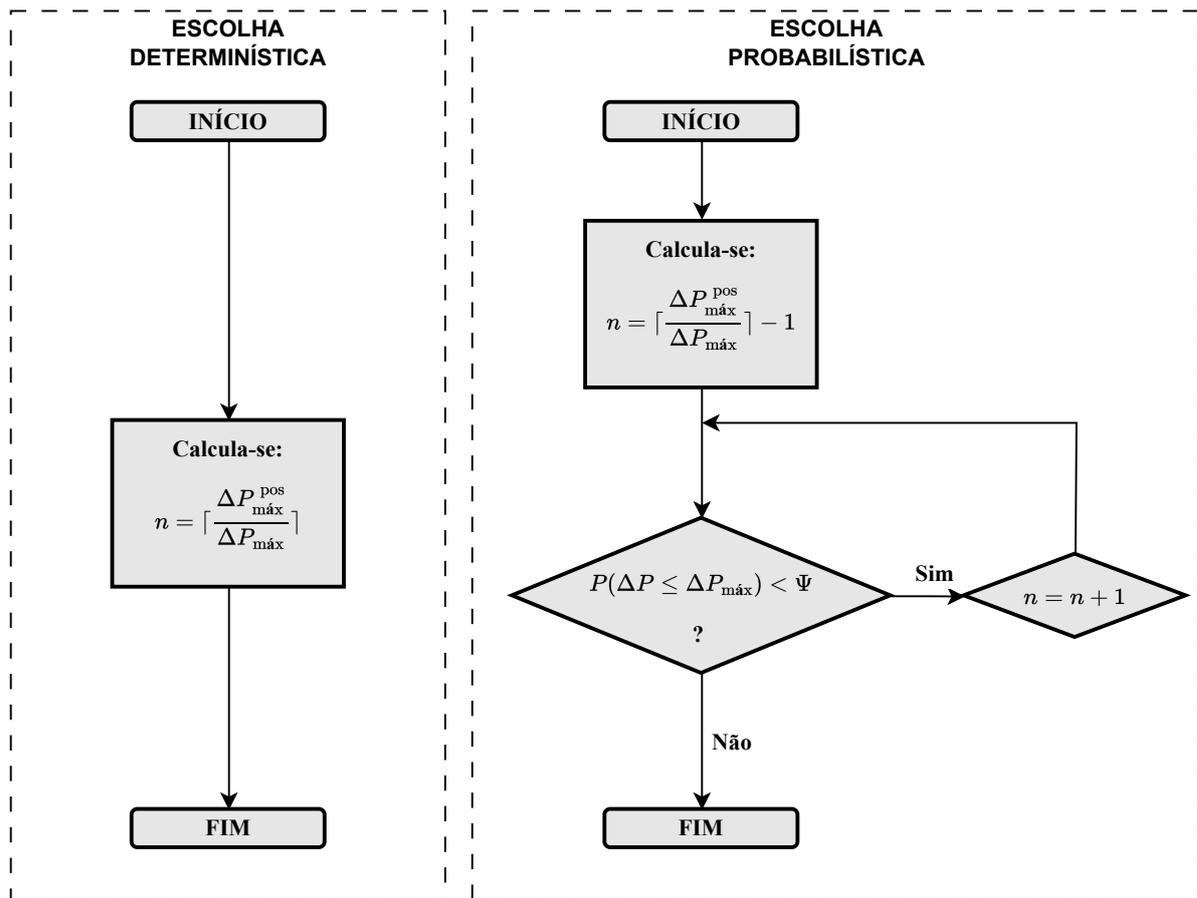
Fonte: Própria do Autor (2024)

O problema do dimensionamento da janela móvel de cálculo, portanto, deve ser entendido como o problema da determinação do quanto se deseja suavizar o sinal original; visto que quanto maior for a janela escolhida, maior será a redução verificada (vide Equação (2)). Em se tratando do campo de estudo da suavização de potência, um subdimensionamento da janela pode resultar

em uma suavização insatisfatória, enquanto um sobredimensionamento pode resultar no uso de sistemas de armazenamento desnecessariamente maiores e mais custosos (ASENSIO et al., 2021).

Conforme apresentado na Seção 2.1, a exigência de suavização de potência nos códigos de rede se dá de forma indireta, através da limitação das taxas de rampa de geração. Partindo do pressuposto de que há conhecimento das taxas de rampas máximas permitidas, o dimensionamento da janela móvel de cálculo pode ocorrer de forma determinística ou probabilística. Na forma determinística, pode-se fazer uso da Equação (2), para a qual escolhe-se um n de tal forma que $\Delta P_{\text{máx}}^{\text{pos}}$ seja inferior ao máximo valor admitido. Já na forma probabilística, o histórico de geração é utilizado como referência para escolher uma janela para a qual seja possível garantir um $\Delta P_{\text{máx}}$ menor que o admitido para uma dada probabilidade de ocorrência das variações (Ψ). Os dois modos são apresentados de forma estruturada na Figura 11¹.

Figura 11 – Fluxograma para determinação do parâmetro n do SMA, considerando os métodos determinístico e probabilístico.



Fonte: Própria do Autor (2024).

¹ **Notação:** $\lceil x \rceil$ denota a função teto $y = \text{ceil}(x)$, isto é, $y = \min\{n \in \mathbb{Z} : n \geq x\}$.

Vale ressaltar que o método probabilístico resulta, necessariamente, em um n igual ou inferior ao obtido pelo método determinístico. Um n maior, na prática, resulta em maior absorção e injeção de potência por parte do BESS e, conseqüentemente, maiores custos associados à aquisição e operação do sistema de armazenamento. Por outro lado, o método probabilístico exige conhecimento prévio do histórico de geração e não garante que 100% das variações de potência possíveis podem ser suavizadas para valores menores que $\Delta P_{\text{máx}}$, ainda que garanta que a maior parte das variações fique abaixo desse valor.

2.3.2 Taxa de Rampa (RR – *Ramp Rate*)

A técnica *Ramp Rate* confina as variações de potência ativa em uma banda a partir da limitação de sua variação dentro do intervalo de tempo escolhido (D'AMICO; PETRONI; VERGINE, 2022), lógica similar a de uma banda de histerese utilizada em controladores. Essa técnica restringe a injeção/absorção de energia na rede em um intervalo equivalente à máxima variação de potência permitida ($\pm\lambda$). Em sua forma mais simples, é representada matematicamente por:

$$P_{\text{RR},k} = \begin{cases} P_{\text{RR},k-1} + \lambda, & \text{se } \Delta P > \lambda; \\ P_{\text{RR},k-1} - \lambda, & \text{se } \Delta P < -\lambda; \\ P_k, & \text{caso contrário;} \end{cases} \quad (3)$$

fazendo com que:

$$\Delta P_{\text{máx}}^{\text{pos}} = \lambda. \quad (4)$$

Um exemplo numérico da aplicação da Equação (3) pode ser visualizado na Figura 12. Nesse exemplo, observam-se algumas características intrínsecas do uso de RR em suavização de potência:

- Devido ao fato dessa técnica não incluir a aplicação de filtros, o atraso temporal observado ao ser aplicado à SMA não é gerado;
- Enquanto que no conjunto original de dados a máxima variação foi de 39 (ocorrendo de $k = 5$ para $k = 6$), ela foi suavizada para 5 ao considerar $\lambda = 5$, para 10 ao considerar $\lambda = 10$ e para 20 ao considerar $\lambda = 20$, conforme esperado da Equação (4).

Uma análise rápida das características listadas acima é suficiente para evidenciar que, analogamente ao caso de uma SMA, em que a parametrização é feita a partir da escolha do valor de n , na técnica RR o parâmetro λ define a máxima variação de potência.

Vale ressaltar, ainda, que a versão do algoritmo apresentada constitui a sua forma mais simples. Outras versões podem incorporar informações como o estado de carga da bateria (SoC – *State of Charge*), o preço da energia ou quaisquer outros parâmetros que a aplicação demandar.

Figura 12 – Exemplo numérico da aplicação da Equação (3) para obtenção de um conjunto suavizado de amostras de potência utilizando RR, $P_{RR,k}$. Diferentes valores de λ são considerados.

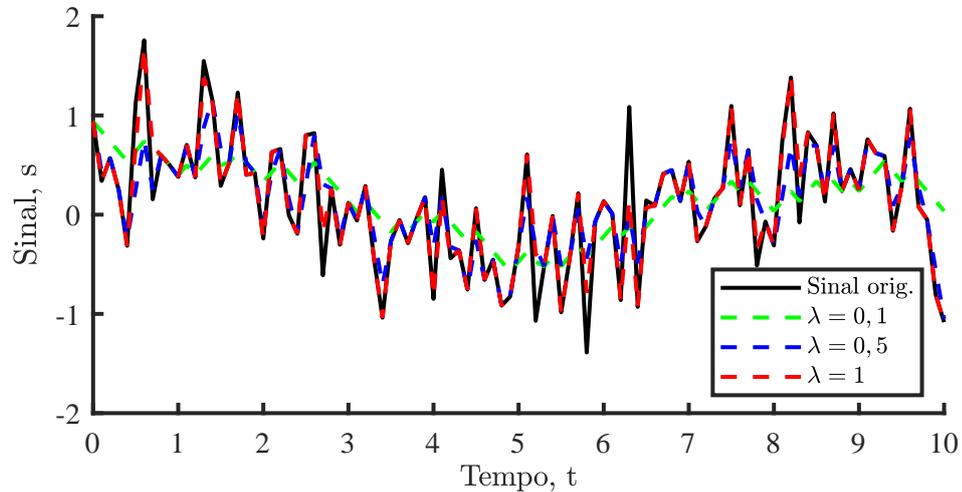
k		1	2	3	4	5	6	7	8
P_k		113	85	88	96	115	76	100	79
$P_{RR,k}$	$\lambda = 5$	113	108	103	98	103	98	100	95
	$\lambda = 10$	113	103	93	96	106	96	100	90
	$\lambda = 20$	113	93	88	96	115	95	100	80

Fonte: Própria do Autor (2024).

2.3.2.1 Dimensionamento da Janela de Suavização para RR

Um exemplo visual do efeito do uso de diferentes valores de λ pode ser visualizado na Figura 13. Na imagem, o mesmo sinal utilizado para avaliação do SMA foi suavizado através da aplicação da técnica RR com valores de λ de: 0, 1; 0, 5; e 1.

Figura 13 – Efeito da escolha de diferentes valores de λ sobre o desempenho do método RR na suavização de sinais.



Fonte: Própria do Autor (2024).

Tipicamente, o parâmetro λ é escolhido de forma determinística, já que atribui-se a ele o valor correspondente ao limite admitido pela aplicação. Se, por exemplo, o código de rede vigente para uma determinada aplicação impor um $\Delta P_{\text{máx}}$ de 10% do valor nominal da planta (P_{nom}), escolhe-se $\lambda = 0,1 \cdot P_{\text{nom}}$. Assim, λ é uma fração de P_{nom} , conforme a Equação (5) (D'AMICO; PETRONI; VERGINE, 2022).

$$\lambda = \left(\frac{\Delta P_{\text{máx},\%}}{100} \right) \cdot P_{\text{nom}}. \quad (5)$$

2.4 MÉTRICAS FREQUENTEMENTE UTILIZADAS

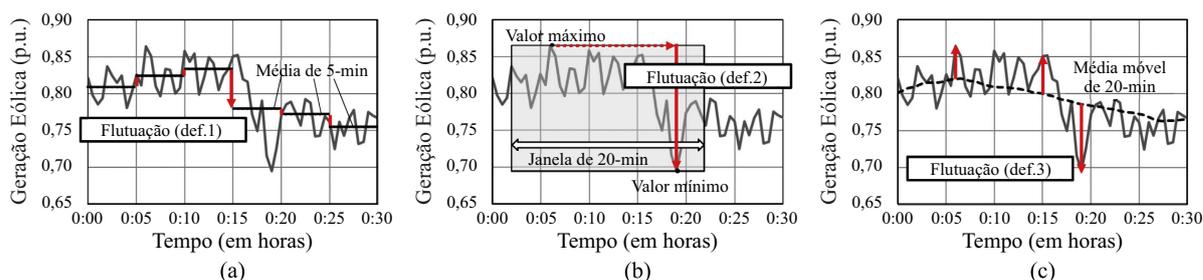
A escolha e a avaliação de algoritmos de geração de referência para suavização de potência são tarefas intrinsecamente interligadas, já que é crucial dispor de uma abordagem adequada para comparar o desempenho desses algoritmos. A análise da suavização de potência pode ser entendida como uma análise comparativa da variabilidade de potência antes e depois da aplicação da suavização. Por se tratar de um fenômeno complexo, a variabilidade de potência não pode ser analisada de forma unidimensional. Para que isso não aconteça, diversos aspectos devem ser avaliados para a construção de uma compreensão abrangente desse fenômeno.

Em (ASENSIO et al., 2021), os autores investigam algumas das métricas utilizadas para avaliar a variabilidade de potência e optam por dividi-las em três categorias, segregadas de acordo com o principal aspecto que se propõem a medir. As categorias são associadas à: (i) intensidade das variações; (ii) probabilidade das variações; e (iii) caracterização em frequência das variações. No presente estudo, as métricas em investigação estão especificamente associadas à severidade e à probabilidade das variações, uma vez que o intervalo de tempo do estudo, e seus efeitos associados, são predefinidos pela frequência de amostragem do conjunto de dados utilizado. Em um cenário ideal, dados de alta frequência seriam usados para que diferentes intervalos de tempo pudessem ser analisados.

2.4.1 Quanto à Intensidade

Sob à ótica dos órgãos de regulação, a intensidade das variações de potência é a sua característica de maior interesse. Tipicamente, as métricas que fazem parte dessa categoria envolvem o cálculo das taxas de variação de potência ativa no ponto de conexão à rede, conforme mencionado na Seção 2.1.1. Em (IKEGAMI et al., 2018), por exemplo, são apresentadas diferentes formas de cálculo para as rampas de potência (ilustradas na Figura 14), como realizar o cálculo de forma média (Figura 14a); considerando os extremos de geração dentro de um dado período (Figura 14b); ou medindo o desvio em relação à média móvel (Figura 14c). Para além dessas definições, a intensidade das variações pode ser, ainda, medida de forma instantânea.

Figura 14 – Definições da intensidade das variações (marcadas em vermelho): (a) cálculo de forma média; (b) extremos de geração em um dado período; e (c) desvio em relação à média móvel.



Fonte: Adaptado de (IKEGAMI et al., 2018).

Em (ASENSIO et al., 2021), os autores utilizam uma classificação semelhante à de Ikegami et al. (2018) ao tratar da intensidade das variações, notam que, no contexto da suavização de potência, aplicar a definição apresentada na Figura 14a pode gerar valores médios que não representam adequadamente a severidade real das variações. Já sobre as definições apresentadas nas Figuras 14b e 14c, os autores classificam-nas, respectivamente, como estimativas com cunho conservador e otimista. Os autores também observam que a definição apresentada na Figura 14a é a mais utilizada em função da sua simplicidade, ainda que os códigos de rede nem sempre deixem claro qual definição deve ser utilizada. Contudo, em se tratando do campo de estudo da suavização de potência, predomina a definição apresentada na Figura 14b.

Alternativamente às definições supracitadas, que levam em conta taxas de variação (com dimensão de W/t), também podem ser utilizadas as variações entre medições subsequentes (com dimensão W), conforme definido para o indicador Máxima Variação de Potência ($\Delta P_{\text{máx}}$):

- **Máxima Variação de Potência:** Em síntese, essa métrica consiste na variação máxima de potência observada entre medições sequenciais separadas por um intervalo de tempo predefinido, normalmente associado ao fenômeno que se deseja analisar ou a restrições operativas impostas. Estudos voltados à suavização de potência costumam analisar o $\Delta P_{\text{máx}}$ em um intervalo diário. O método de suavização empregado é considerado satisfatório quando é capaz de manter o valor de $\Delta P_{\text{máx}}$ abaixo de um limite predefinido ao longo do dia (ou outro intervalo escolhido). Exemplos da sua utilização para esse fim podem ser observados em (KINI et al., 2020), (MITCHELL et al., 2016) e (PINHEIRO et al., 2021).

2.4.2 Quanto à Probabilidade

Uma perspectiva adicional a ser analisada refere-se à probabilidade, cuja relevância torna-se evidente, sobretudo, devido ao impacto decorrente da introdução de incerteza à avaliação de variabilidade de potência. Avaliar esse impacto viabiliza, por exemplo, o dimensionamento das reservas operativas necessárias para assegurar o funcionamento adequado da rede. Além disso, a probabilidade de ocorrência das variações está intrinsicamente associada à parametrização de alguns dos métodos de suavização, conforme mencionado na Seção 2.3.

A obtenção de indicadores quantitativos, portanto, viabiliza avaliar os métodos de suavização quanto ao seu impacto sobre a necessidade de reservas operativas (ASENSIO et al., 2021; IKEGAMI et al., 2018). Asensio et al. (2021) e Ikegami et al. (2018) ressaltam a importância de analisar os percentis de probabilidade das variações de potência, bem como as funções densidade de probabilidade (PDF — *Probability Density Function*) e distribuição acumulada (CDF — *Cumulative Distribution Function*) para avaliar os métodos de suavização. Em artigos dedicados especificamente à suavização de potência, no entanto, o uso dessas abordagens não é comum. Nesses casos, o indicador associado à probabilidade mais empregado é o desvio padrão. Asensio et al. (2021) e Ikegami et al. (2018) alertam para a possibilidade de que as distribuições das variações de potência não serem adequadamente descritas por uma distribuição Gaussiana, o

que invalidaria o uso do desvio padrão em certos contextos. Nesse contexto, a métrica de desvio padrão é formalmente definida a seguir.

- **Desvio padrão:** O desvio padrão (σ) permite avaliar a probabilidade de variações. No caso de uma distribuição gaussiana, aproximadamente 68% dos valores estão contidos a uma distância de um desvio padrão da média (μ), como pode ser visto na Figura 15. Assim, σ e seus múltiplos são frequentemente utilizados para estimar o impacto da conexão de recursos intermitentes na necessidade de reservas operacionais (ASENSIO et al., 2021). O cálculo do desvio padrão das variações de potência (σ_{Δ}) pode ser realizado usando a seguinte expressão:

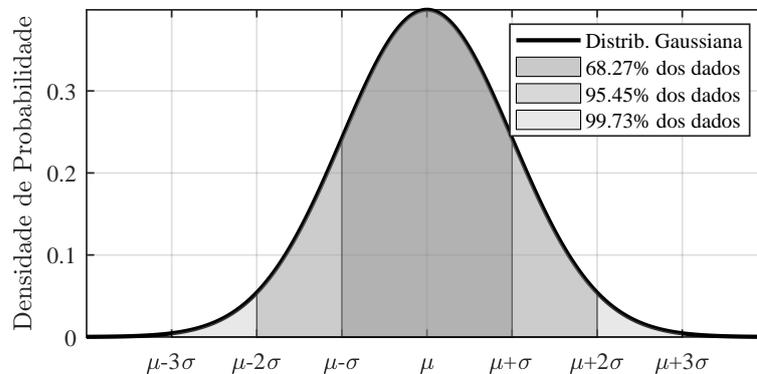
$$\sigma_{\Delta} = \sqrt{\frac{1}{N-1} \sum_{j=1}^N (P_j - \mu_{\Delta})^2}, \quad (6)$$

em que:

$$\mu_{\Delta} = \frac{1}{N} \sum_{j=1}^N P_j. \quad (7)$$

Exemplos ilustrativos do uso do desvio padrão nesse contexto podem ser encontrados em (PURI, 2014), (HOFF; PEREZ, 2010), (MOAVENI et al., 2013) e (MILLS; WISER, 2011).

Figura 15 – Propriedades de uma distribuição Gaussiana.



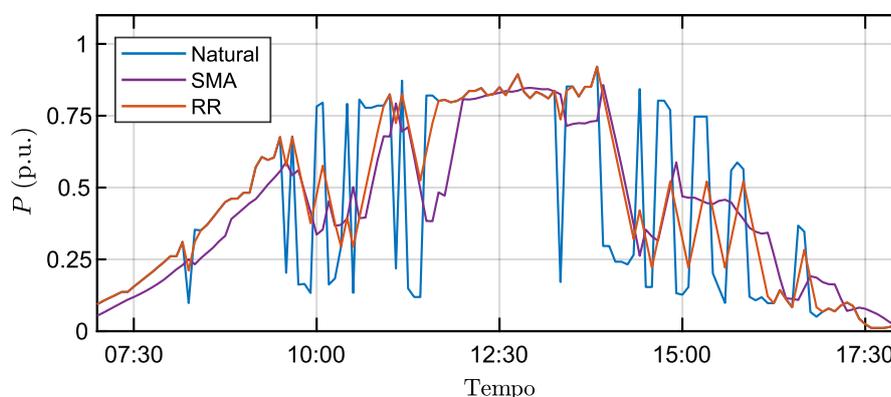
Fonte: Própria do Autor (2024)

2.4.3 Análise Visual

Apesar de não ser um método quantitativo, a análise visual é a métrica de avaliação mais amplamente empregada em artigos de suavização de potência. Essa técnica consiste na sobreposição dos gráficos dos métodos avaliados no gráfico do perfil de geração original. De forma semelhante à métrica $\Delta P_{\text{máx}}$, a análise usualmente leva em consideração um intervalo diário de geração. Alguns exemplos do seu uso podem ser encontrados em (KOOHI-KAMALI; RAHIM; MOKHLIS, 2014), (ATIF; KHALID, 2020) e (SILVA et al., 2023) ou na Figura 16.

É fundamental ressaltar que a análise visual da suavização de potência não proporciona nenhuma garantia de que os códigos de rede estejam sendo integralmente atendidos, uma vez que

Figura 16 – Exemplo de uso da análise visual para comparação do impacto dos algoritmos SMA e RR na suavização de potência. Avaliação feita para um perfil diário de geração fotovoltaica.



Fonte: Própria do Autor (2024).

não se trata de um método quantitativo. Embora a observação visual possa oferecer observações pertinentes sobre o comportamento geral do sistema e a eficácia das estratégias de suavização, ela só deve ser utilizada como ferramenta complementar em avaliações de suavização de potência.

2.4.4 Métricas Baseadas em Irradiância

Há, ainda, outras métricas voltadas à medição da variabilidade voltadas especificamente para geração fotovoltaica. Nesses casos, geralmente calcula-se a variabilidade com base no desvio da irradiância em relação à irradiância gerada pelo modelo de céu limpo. Um exemplo pode ser observado em (RAYGANI; SHARMA; SAHA, 2013). Contudo, esse tipo de métrica é fundamentalmente limitado por ser baseado em uma grandeza secundária (a irradiância), o que inviabiliza comparações com outras fontes de geração ou entre curvas de potência suavizadas. Por esse motivo, métricas dessa natureza não são contempladas neste trabalho.

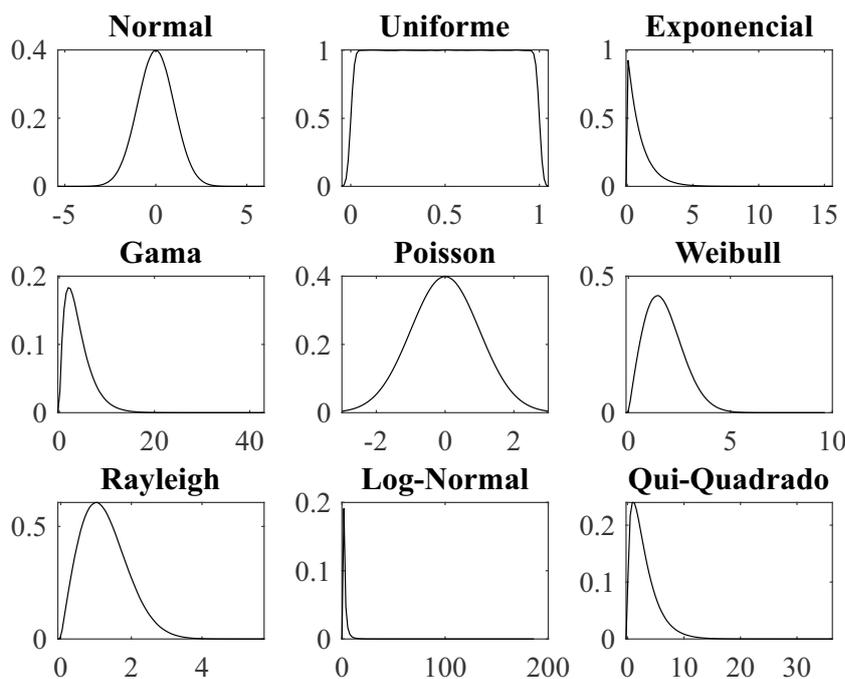
2.5 DISTRIBUIÇÕES DE PROBABILIDADE

No decorrer deste capítulo, utilizou-se, ao tratar de probabilidades de ocorrência de eventos, a distribuição Gaussiana como exemplo. Essa distribuição, apresentada na Figura 15, é um exemplo de distribuição de probabilidade (ou, mais formalmente, função densidade de probabilidade). As PDF são funções matemáticas que descrevem a probabilidade de uma variável aleatória assumir um valor específico, de modo que representam a distribuição de probabilidade contínua de uma variável aleatória. As PDFs permitem calcular probabilidades de eventos específicos, fazer previsões e inferências a partir de dados observados, além de servirem de base para muitas técnicas estatísticas e de análise de dados

Em uma PDF, a área sob a curva (considerando o intervalo de variação da variável aleatória de $\pm\infty$) corresponde à unidade, de forma equivalente a um histograma normalizado por

densidade de probabilidade. Como consequência, para encontrar a probabilidade de ocorrência de a variável aleatória assumir um determinado intervalo, basta calcular a área sob a curva para esse intervalo. Assim, as PDF são fundamentais na Estatística, uma vez que podem ser utilizadas em uma variedade de aplicações, como na caracterização de fenômenos físicos ou na análise de dados em ciência e engenharia. Na Figura 17, é possível visualizar alguns exemplos de PDFs.

Figura 17 – Exemplos de distribuições de probabilidade.

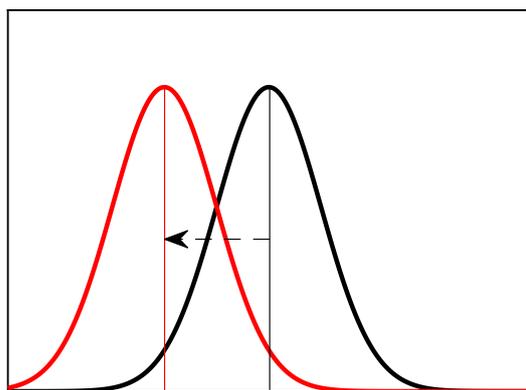


Fonte: Própria do Autor (2024).

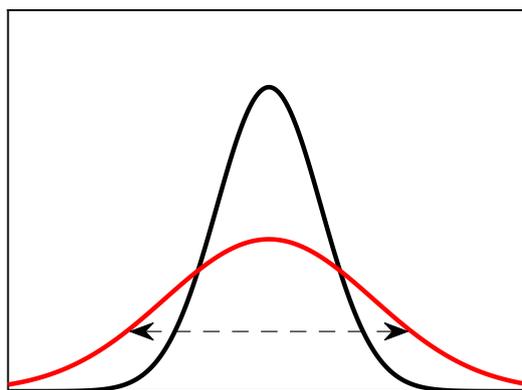
2.5.1 Parâmetros de uma Distribuição

As distribuições possuem parâmetros que ditam o seu formato. Uma distribuição Gaussiana, por exemplo, tem a sua posição no eixo das abscissas determinada pela sua média. Já em relação ao seu formato, é mais larga e mais baixa se possuir um maior desvio padrão e mais fina e mais alta se possuir um menor desvio padrão. Uma representação gráfica da variação desses parâmetros pode ser vista nas Figuras 18 e 19.

Observe que os parâmetros descritos (μ e σ , no caso da Gaussiana) afetam, respectivamente, a posição da distribuição e sua dispersão em relação ao centro. Por esse motivo, recebem os nomes de parâmetro de localização e parâmetro de escala. Algumas distribuições, diferentemente da Gaussiana, possuem um parâmetro adicional. Esse parâmetro recebe o nome de parâmetro de forma e a sua variação é capaz de alterar significativamente o formato do gráfico. Em capítulos posteriores, a influência desses parâmetros na caracterização de fenômenos físicos (e sua estimação) será discutida de forma mais aprofundada.

Figura 18 – Efeito da variação de μ .

Fonte: Própria do Autor (2024).

Figura 19 – Efeito da variação de σ .

Fonte: Própria do Autor (2024).

2.6 CONCLUSÕES PARCIAIS

Neste capítulo, foram abordadas as características gerais de sistemas de suavização, incluindo sua topologia, algoritmos de geração de referência e as métricas utilizadas em sua avaliação. Conforme apresentado, a suavização de potência é um fenômeno complexo e a sua avaliação perpassa pela análise da variabilidade de potência antes e depois da aplicação dos algoritmos de geração de referência. Verifica-se, no entanto, uma disparidade entre a literatura voltada puramente ao estudo da suavização e aquela voltada ao estudo da variabilidade. Nos trabalhos de suavização, observa-se uma predominância de indicadores não numéricos, uma vez que parte significativa dos artigos se limita a comparar os resultados obtidos de maneira visual. Além disso, há evidências que apontam para o uso de métricas estatísticas sem o devido cuidado necessário (ASENSIO et al., 2021).

Outro aspecto potencialmente problemático encontrado em diversos trabalhos é a prática de limitar a análise a pequenos intervalos, como o diário, o que pode levar a conclusões equivocadas, especialmente quando se utilizam indicadores fortemente sensíveis ao número de amostras. Nesse contexto, entende-se que é preciso avaliar os indicadores atualmente utilizados no campo da suavização de potência, especialmente no que diz respeito ao rigor estatístico da sua utilização. Mais especificamente, é preciso:

- Analisar as distribuições de probabilidade que caracterizam as variações de potência;
- Avaliar as métricas vigentes quanto à sua dependência em relação ao número de amostras;
- Propor, se necessário, novas métricas para esse campo de estudo.

3 ANÁLISE DE MÉTRICAS PARA AVALIAÇÃO DE ALGORITMOS DE GERAÇÃO DE REFERÊNCIA EM SUAVIZAÇÃO DE POTÊNCIA

Neste capítulo, algumas das principais métricas utilizadas para avaliação de algoritmos de suavização de potência são examinadas a partir de um conjunto de dados oriundos de medições experimentais. Pretende-se, dessa forma, expor as principais limitações das métricas já estabelecidas na literatura, bem como propor indicadores alternativos.

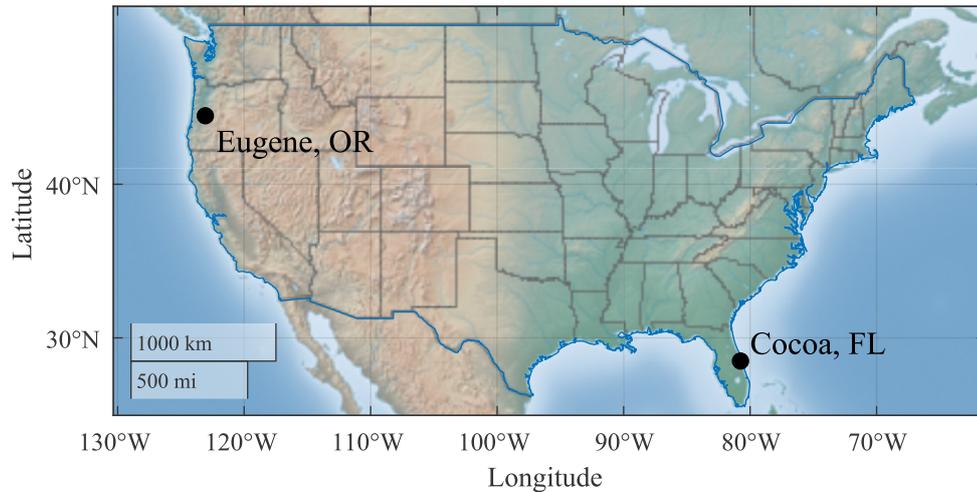
3.1 DESCRIÇÃO DO CONJUNTO DE DADOS EXPERIMENTAIS

Neste trabalho, dados de duas instalações distintas são utilizados para analisar os indicadores numéricos apresentados na Seção 2.4. O primeiro conjunto de dados é oriundo do Centro de Energia Solar da Flórida (FSEC – *Florida Solar Energy Center*), localizado em Cocoa (Flórida, EUA). Já o segundo conjunto de dados foi gerado pela Universidade de Oregon (UO – *University of Oregon*), localizada em Eugene (Óregon, EUA). Em ambos os casos, os dados foram gerados como parte do projeto "*Data for Validating Models for PV Module Performance*", coordenado pelo Laboratório Nacional de Energias Renováveis (NREL – *National Renewable Energy Laboratory*) dos Estados Unidos (MARION et al., 2021).

No estudo conduzido por Marion, Deceglie e Silverman (2014), foram contemplados módulos fotovoltaicos de diversas tecnologias, incluindo silício monocristalino e policristalino, telureto de cádmio, disseleneto de cobre índio e gálio, silício amorfo, além outras tecnologias disponíveis comercialmente em 2010. Dentre as tecnologias disponíveis, escolheu-se, neste trabalho, utilizar os dados referentes à tecnologia de silício monocristalino, em função de seu amplo uso comercial. A Figura 20 representa a localização das instalações utilizadas nesta pesquisa.

Com o objetivo de assegurar a validação da modelagem dos módulos, as medições foram realizadas em diferentes localidades, mantendo constantes tanto os módulos utilizados quanto os equipamentos de medição e a calibração. Cada uma das localidades foi submetida a pelo menos um ano de medições. Informações adicionais acerca das duas instalações estão disponíveis na Tabela 4. É relevante destacar que a seleção dos dados para inclusão no presente estudo considerou instalações inseridas em climas distintos (subtropical e marinho da Costa Oeste), além de contar com dados de acesso público. Assim, espera-se garantir uma diversidade climática, ainda que limitada, e a possibilidade de validação e replicação das observações realizadas a partir do referido conjunto de dados.

Figura 20 – Localização das instalações avaliadas neste trabalho.



Fonte: Própria do Autor (2024).

Tabela 4 – Detalhamento dos dados utilizados.

Nome da instalação	P_{nom} [W]	Localização aprox. em coordenadas	Período de medição	Intervalo entre as medições	Número de amostras	Tecnologia do módulo PV
Cocoa	46,1	28,39 N/ 80,75 O	21 de jan., 2011- 24 de fev., 2012	5 min	35.841	Silício monocristalino
Eugene	46,1	44,05 N/ 123,07 O	20 de dez., 2012- 19 de jan., 2014	5 min	43.174	Silício monocristalino

Obs.: Os dados utilizados neste trabalhos são de acesso público.

Fonte: Própria do Autor (2024).

3.1.1 Processamento de Dados

Os conjuntos de dados já foram submetidos a processamento para atender aos objetivos do projeto original coordenado pela NREL, conforme detalhado por Marion, Deceglie e Silverman (2014). Contudo, devido à natureza dos dados em relação à aplicação estudada, são necessárias etapas adicionais de processamento. Em (CAVALCANTE JÚNIOR, 2023), as curvas I-V foram tratadas para corrigir fatores multiplicativos associados ao sistema de medição para uma faixa de valores. Neste trabalho, no entanto, o foco está nas medições de potência, o que implica a necessidade da realização de etapas adicionais de validação.

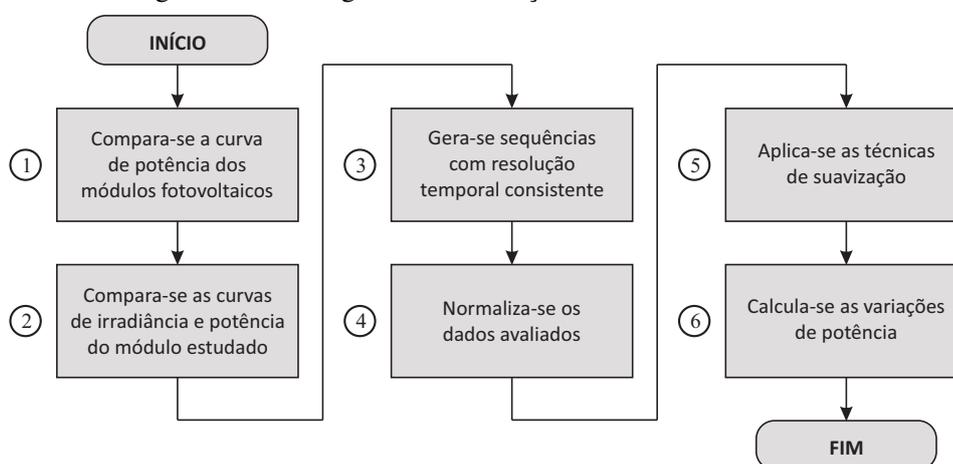
A Figura 21 ilustra o fluxograma completo do processo de validação e tratamento dos dados implementado neste trabalho. Para validação da curva de potência, dois métodos podem ser utilizados. Inicialmente, pode-se comparar as curvas de potência entre os módulos estudados (Etapa ① da Figura 21), os quais, apesar de possuírem valores nominais de potência e tecnologias diferentes, tendem a apresentar curva com características similares por estarem susceptíveis às mesmas condições de temperatura e irradiância. Posteriormente, pode-se analisar as curvas de potência referentes apenas ao módulo estudado (silício monocristalino), comparando-as com as curvas de irradiância da localidade (Etapa ② da Figura 21). Mantém-se, assim, apenas os dados

cujo desempenho foi satisfatório considerando as duas etapas de validação supracitadas.

Ainda é preciso lidar com a resolução temporal inconsistente. Os dados de série temporal são compostos por medições ininterruptas de 5 min, mas contém lacunas — decorrentes de falhas de equipamento, atividades de manutenção, além de outras razões —, o que resulta na existência de intervalos pré-removidos. Para adequar os dados aos objetivos deste trabalho, apenas as medições com diferença de tempo de 5 min foram mantidas no conjunto de dados, assegurando uma resolução temporal consistente (Etapa ③ da Figura 21). Vale ressaltar, também, que o conjunto de dados usado neste estudo não inclui falhas em tempo real na aquisição de dados, frequentemente encontradas em implementações reais. Portanto, deve-se reconhecer que os algoritmos avaliados não foram avaliados do ponto de vista de seu desempenho no tratamento frente às falhas em tempo real.

Após as etapas de validação e tratamento, o número de amostras de Cocoa e Eugene foi reduzido para, respectivamente, 29.372 e 39.357¹. Outra adequação necessária é a normalização dos dados a partir dos dados de potência nominal (Etapa ④ da Figura 21), disponíveis em Marion, Deceglie e Silverman (2014). Com isso, concluem-se as etapas de validação e tratamento dos dados. Em sequência, faz-se uso dos dados para a aplicação das técnicas de suavização estudadas, a partir das quais são geradas novas séries temporais (Etapa ⑤ da Figura 21). Finalmente, é possível calcular as variações de potência a partir das diferenças entre medições subsequentes (Etapa ⑥ da Figura 21).

Figura 21 – Fluxograma da validação e tratamento dos dados.



Fonte: Própria do Autor (2024).

3.1.2 Variabilidade Natural das Instalações Avaliadas

Utilizando os dados de Cocoa e Eugene, foram gerados dois histogramas representando as variações potência (em p.u.). Esses histogramas foram normalizados pela densidade de

¹ Note que mesmo os números originais (35.841 e 43.174) já estão aquém do esperado ao considerar medições de 12 horas espaçadas por 5 minutos. Isso ocorre pois, já no conjunto original, há períodos de indisponibilidade ou remoção completa em função de temporária baixa qualidade dos dados.

probabilidade², podendo ser utilizados como uma ferramenta para avaliar a probabilidade de ocorrência de variações de potência ativa em intervalos de magnitude predeterminados. Além disso, os histogramas obtidos permitem realizar comparações com distribuições de probabilidade conhecidas, como a distribuição Gaussiana. A variabilidade natural (antes do uso de técnicas de suavização) de Cocoa e Eugene pode ser vista, respectivamente, nas Figuras 22 e 23.

A análise das Figuras 22 e 23 permite constatar que, para o período observado, a localidade de Eugene apresenta menor variabilidade em comparação com Cocoa, o que se evidencia na maior concentração de probabilidade no centro do histograma. Os valores de σ_{Δ} para Cocoa e Eugene são, respectivamente, 0,1031 e 0,0750 p.u.. Já os valores de $\sigma_{\Delta,99.73\%}$ (o desvio em relação à média que contém 99.73% da probabilidade) são, respectivamente 0,777 e 0,736 p.u.. Apesar dos menores valores de desvio padrão, no entanto, observou-se que a maior variação de potência registrada no período analisado ocorreu em Eugene, alcançando o valor de 0,983 p.u., superando a variação máxima de 0,953 p.u. verificada em Cocoa.

3.1.3 Resultados Pós-Suavização

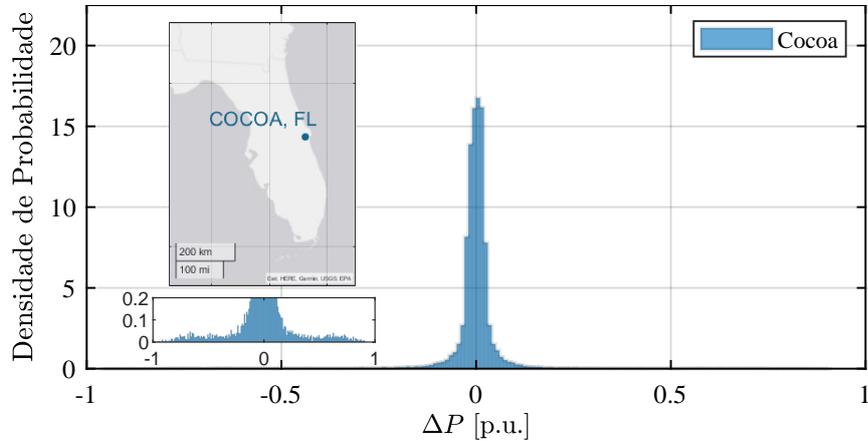
Para evidenciar o impacto das técnicas de suavização de potência, foram selecionados três dias com diferentes perfis de irradiância em cada localidade do conjunto de dados. Nas Figuras 24 e 25, os perfis de geração de Cocoa e Eugene são apresentados antes e depois da aplicação das técnicas de suavização SMA e RR. Para fins de visualização, os valores de medição ausentes foram substituídos pelo último valor registrado, com o objetivo de exibir a curva completa. Entretanto, para os indicadores numéricos, apenas sequências contínuas foram consideradas, conforme detalhado na Seção 3.1.1.

Os algoritmos foram parametrizados com o objetivo de manter aproximadamente 99% das variações abaixo de um limite arbitrário de 0,1 p.u., o que é equivalente a uma taxa de rampa de 0,02 p.u./min. No caso do algoritmo SMA, uma janela de 6 amostras (30 min) foi empregada para atingir esse objetivo para Cocoa, enquanto para Eugene foi utilizado um valor de 5 amostras (25 min). Nas Figuras 26 (Cocoa) e 27 (Eugene), podem ser observados novos histogramas, gerados após a suavização.

Os histogramas fornecem uma compreensão mais clara do desempenho dos métodos de suavização estudados. No caso da técnica SMA, todas as flutuações são suavizadas, fazendo com que os desvios de menor magnitude sejam mais prováveis do que antes da suavização, ainda que o perfil do histograma não seja alterado. Por outro lado, no caso da técnica RR, todos os desvios que excedem o limite adotado (0,1 p.u.) deixam de existir, fazendo com que toda a probabilidade que antes excedia o limite se concentre na borda de variações admitidas. Essa diferença de comportamento pode ser notada a partir da análise dos valores de σ_{Δ} e $\sigma_{\Delta,99.73\%}$.

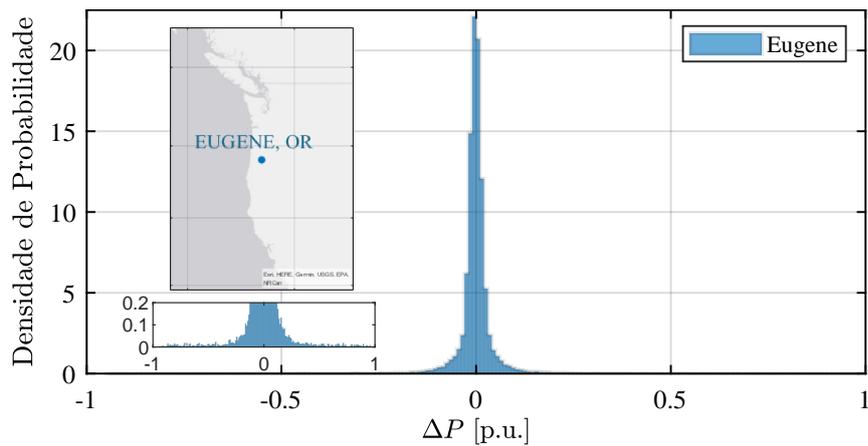
² **Observação:** A normalização é realizada de tal forma que $\int_{-\infty}^{\infty} \varphi(x) dx = 1$, em que $\varphi(x)$ é a função densidade de probabilidade (PDF — *Probability Density Function*).

Figura 22 – Histograma das variações de potência ativa em Cocoa (resultado sem aplicação de técnicas de suavização). Valores normalizados pela densidade de probabilidade.



Fonte: Própria do Autor (2024).

Figura 23 – Histograma das variações de potência ativa em Eugene (resultado sem aplicação de técnicas de suavização). Valores normalizados pela densidade de probabilidade.



Fonte: Própria do Autor (2024).

Após a suavização, os valores de σ_{Δ} de Cocoa passaram a ser de 0,0229 (SMA) e 0,0379 p.u. (RR). Em Eugene, os valores passaram a ser de 0,0216 (SMA) e 0,0340 p.u. (RR). No que diz respeito aos valores de $\sigma_{\Delta,99.73\%}$, Cocoa apresentou uma redução para 0,125 (SMA) e 0,100 p.u. (RR), enquanto Eugene teve seus valores reduzidos para 0,153 (SMA) e 0,100 p.u. (RR). Vale ressaltar, também, que os valores de $\Delta P_{\text{máx}}$ se comportaram de acordo com o esperado pelas Equações (8) e (9), apresentadas na Seção 2.3. Isto é:

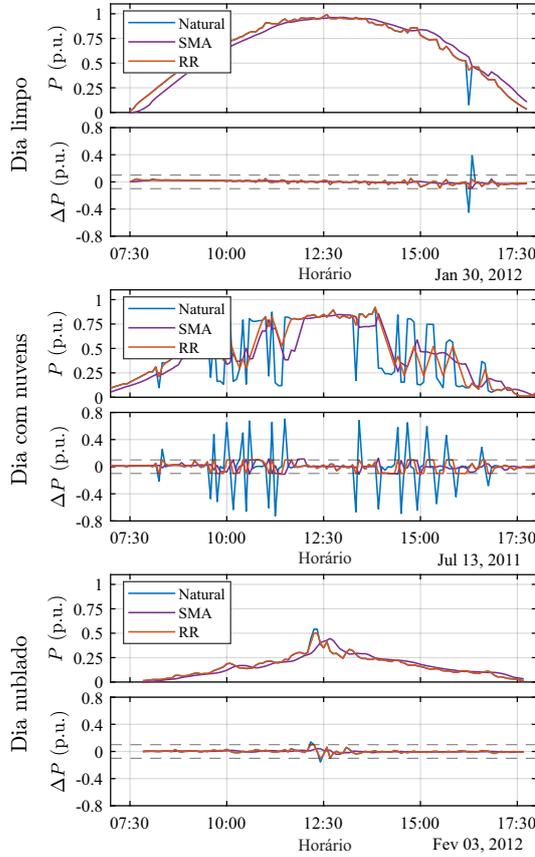
$$\Delta P_{\text{máx}}^{\text{pos}} = \frac{1}{n} P_{\text{máx}}^{\text{nat}}, \quad (8)$$

para a técnica SMA e

$$\Delta P_{\text{máx}}^{\text{pos}} = \lambda, \quad (9)$$

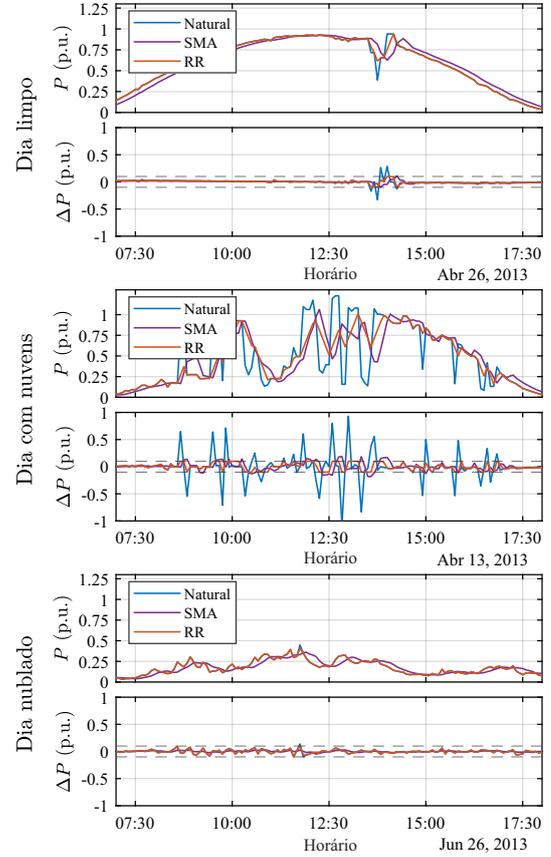
para a técnica RR. Uma síntese dos indicadores pode ser visualizada na Tabela 5.

Figura 24 – Perfil diário de geração para diferentes condições de irradiância antes e pós-suavização (Cocoa).



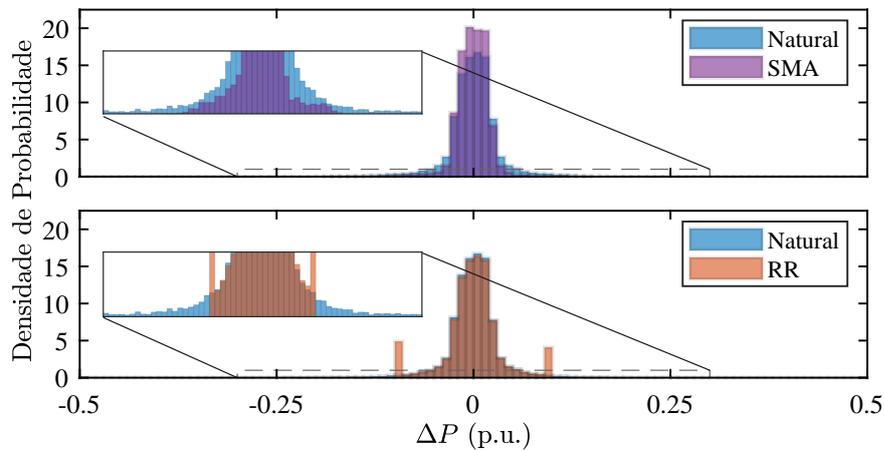
Fonte: Própria do Autor (2024).

Figura 25 – Perfil diário de geração para diferentes condições de irradiância antes e pós-suavização (Eugene).



Fonte: Própria do Autor (2024).

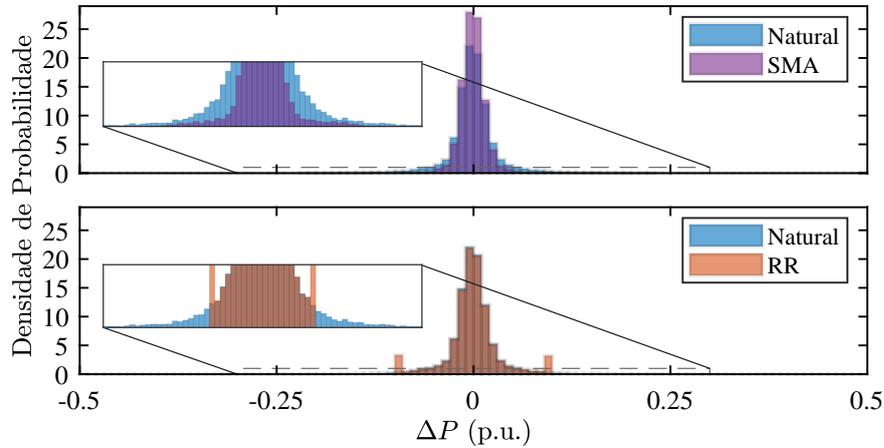
Figura 26 – Histograma das variações de potência ativa em Cocoa, antes e pós-suavização. Valores normalizados pela densidade de probabilidade.



Fonte: Própria do Autor (2024).

Outra característica que pode ser utilizada como ferramenta para a caracterização da variabilidade é a função distribuição acumulada (CDF – *Cumulative Distribution Function*). Essa

Figura 27 – Histograma das variações de potência ativa em Eugene, antes e pós-suavização. Valores normalizados pela densidade de probabilidade.



Fonte: Própria do Autor (2024).

Tabela 5 – Índices numéricos antes e depois da suavização de potência.

Local	Cenário	σ_{Δ} (p.u.)	$\Delta P_{\text{máx}}$ (p.u.)	$\sigma_{\Delta,99.73\%}$ (p.u.)
Cocoa	Natural	0,1031	0,953	0,777
	SMA	0,0229	0,148	0,125
	RR	0,0379	0,100	0,100
Eugene	Natural	0,0750	0,983	0,736
	SMA	0,0216	0,229	0,153
	RR	0,0340	0,100	0,100

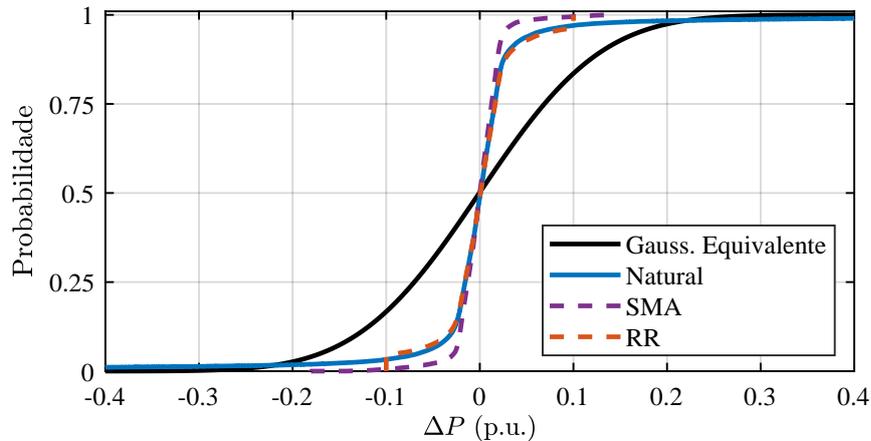
Fonte: Própria do Autor (2024).

função determina a probabilidade de uma variável aleatória (ΔP , nesse caso) assumir valores inferiores a um determinado x ; em termos matemáticos, $\mathbb{F}(x) = \mathbb{P}(\Delta P \leq x)$. A CDF gerada a partir dos dados de medição pode ser comparada às CDFs de distribuições conhecidas, como a Gaussiana. Nas Figuras 28 e 29, as CDFs de Cocoa e Eugene (pré e pós-suavização) são apresentadas em conjunto com distribuições Gaussianas de mesma média e desvio padrão para fins de comparação. A análise dessas figuras, além dos próprios histogramas, evidencia que as variações de potência de Cocoa e Eugene diferem significativamente de um comportamento gaussiano.

3.2 ANÁLISE DAS LIMITAÇÕES DAS MÉTRICAS COMUMENTE UTILIZADAS

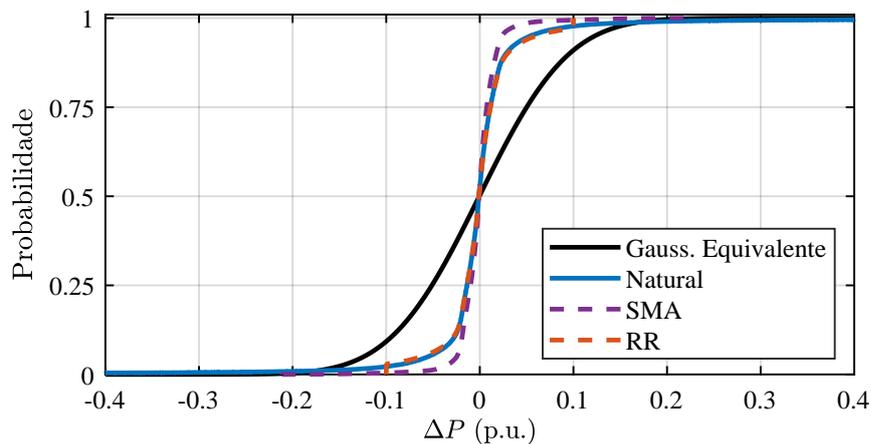
Finalmente, é possível avaliar as métricas apresentadas na Seção 2.4 quando aplicadas para analisar o desempenho das técnicas de suavização de potência. Nesse contexto, é fundamental considerar todo o período disponível nas amostras, garantindo uma abordagem abrangente

Figura 28 – CDF das variações de potência ativa em Cocoa (antes e pós-suavização) e Gaussiana de mesma média e desvio padrão para referência.



Fonte: Própria do Autor (2024).

Figura 29 – CDF das variações de potência ativa em Eugene (antes e pós-suavização) e Gaussiana de mesma média e desvio padrão para referência.



Fonte: Própria do Autor (2024).

na avaliação do impacto e eficácia das técnicas utilizadas. Assim, nas subseções a seguir são tratadas as limitações do desvio padrão, da variabilidade máxima de potência e da análise visual.

3.2.1 Limitações do Desvio Padrão

Uma análise comparativa da Tabela 5 leva a algumas constatações relevantes. Para os mesmos requisitos de projeto (detalhados na Seção 3.1.3), os valores de σ_{Δ} diferem significativamente entre os métodos de suavização. Isso ocorre ainda que se restrinja a análise de diversas maneiras, como exemplificado a seguir:

- **Ao restringir a análise para uma mesma localidade:** Os resultados da Tabela 5 indicam que, para Cocoa, o valor de σ_{Δ} usando o método SMA é de 0,0229 p.u., enquanto esse indicador, ao usar o método RR, é de 0,0379 p.u.. Para Eugene, observa-se que σ_{Δ} é igual a 0,0216 p.u. para o método SMA e 0,0340 p.u. para o método RR;
- **Ao restringir a análise para o mesmo método:** Conforme apresentado na Tabela 3,

para Cocoa, o valor de σ_{Δ} ao usar o método SMA é de 0,0229 p.u., enquanto, para o mesmo método, em Eugene, tem-se 0,0216 p.u.. Por outro lado, ao considerar o método RR, tem-se que o valor de σ_{Δ} é de 0,0379 p.u. para Cocoa e 0,0340 p.u. para Eugene.

Já do ponto de vista da redução, os valores de σ_{Δ} foram reduzidos em 77,8% (SMA) e 66,2% (RR) em Cocoa e em 71,2% (SMA) e 54,7% (RR) em Eugene. É evidente que, embora as reduções tenham sido observadas para ambas as localidades após a suavização, o valor de σ_{Δ} é uma função não apenas dos métodos aplicados, mas também da variabilidade natural da localidade. Isso evidencia as limitações de usar σ como uma métrica para comparar diretamente resultados entre diferentes usinas, além da sua incapacidade, enquanto indicador, de determinar o atendimento a um dado requisito de projeto.

Alternativamente, cabe ressaltar que o σ_{Δ} pode ser utilizado para avaliar, em uma mesma localidade, qual método demanda uma maior bateria ou menores reservas operativas. Para os exemplos estudados, o método RR foi capaz de atingir os mesmos requisitos de projeto com um σ_{Δ} maior que o do método SMA. A implicação disso é que o método RR demandará uma bateria de menor porte, mas, por outro lado, irá requerer maiores reservas operativas. Deve-se ressaltar, no entanto, que o indicador σ_{Δ} não permite estimar adequadamente a quantidade necessária de baterias ou reservas operativas, vide as limitações comentadas.

Adicionalmente, os valores de σ_{Δ} e $\sigma_{\Delta,99.73\%}$ demonstram que a distribuição das variações de potência não é adequadamente representada por uma distribuição gaussiana (para a qual $\sigma_{99.73\%} = 3 \cdot \sigma$), tanto antes quanto após a suavização, o que está de acordo com o que foi discutido em relação aos histogramas e CDFs apresentados. Essa constatação tem um impacto significativo na análise da probabilidade de ocorrência de eventos extremos, caracterizados por variações elevadas. Para um evento de $3\sigma_{\Delta}$, por exemplo, a probabilidade de ocorrência para Cocoa e Eugene é, respectivamente, 9,37 vezes e 5,78 vezes maior do que a do evento equivalente em uma distribuição Gaussiana.

Como as distribuições empíricas concentram relativamente mais probabilidade em suas caudas, quanto maior o desvio analisado, maior a discrepância, conforme pode ser verificado nas Tabelas 6 e 7³. Entende-se, assim, que devido à falta de conhecimento em relação a qual distribuição de probabilidade adequadamente representa o comportamento natural da localidade, é inadequado avaliar a probabilidade de um conjunto dado de valores de variação baseando-se apenas no valor de σ_{Δ} .

3.2.2 Limitações da Variabilidade Máxima

Conforme mencionado na Seção 2.4, o uso de $\Delta P_{\text{máx}}$ normalmente envolve a avaliação da maior variação de potência, considerando amostras consecutivas, dentro de um período de 1 dia. No entanto, é importante determinar o quanto os valores máximos são afetados pelo número

³ **Note:** A probabilidade é calculada considerando ambos os extremos da CDF, tal que $\mathbb{P}(|\Delta P| \geq x) = \mathbb{P}(\Delta P \leq -x) + \mathbb{P}(\Delta P \geq x)$, para $x > 0$.

Tabela 6 – Probabilidade de ocorrência de eventos extremos, $\mathbb{P}(|\Delta P| \geq x)$.

Evento	Gaussiana (%)	Cocoa (%)	Eugene (%)
$ \Delta P \geq 3\sigma$	0,27	2,53	1,56
$ \Delta P \geq 5\sigma$	$5,73 \times 10^{-5}$	1,53	0,93
$ \Delta P \geq 7\sigma$	$2,56 \times 10^{-10}$	0,51	0,61

Fonte: Própria do Autor (2024).

Tabela 7 – Razão entre probabilidade de ocorrência do evento na distribuição empírica e em uma Gaussiana equivalente.

Evento	Cocoa	Eugene
$ \Delta P \geq 3\sigma$	9,37	5,78
$ \Delta P \geq 5\sigma$	26.700	16.230
$ \Delta P \geq 7\sigma$	1.992.200.000	2.382.800.000

Fonte: Própria do Autor (2024).

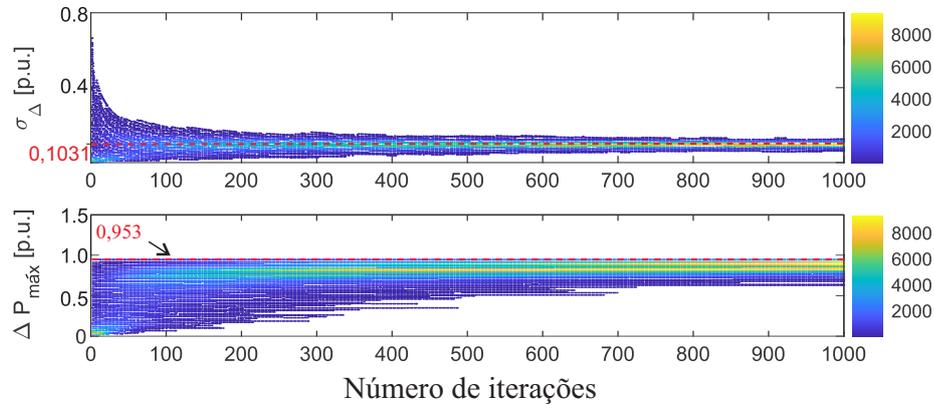
de amostras e se o intervalo de 1 dia, tipicamente utilizado, é estatisticamente significativo. Para investigar essa questão, pode-se conduzir um experimento de simulação utilizando amostras experimentais. A simulação consiste em selecionar, aleatoriamente e com reposição, um valor do conjunto de dados de variações de potência, registrando o valor mais alto a cada iteração.

Escolheu-se, como estimativa inicial, realizar 1.000 iterações. Esse processo foi repetido 5.000 vezes para gerar múltiplos gráficos de $\Delta P_{\text{máx}}$ em função do número de iterações. Os gráficos resultantes para Cocoa e Eugene podem ser visualizados, respectivamente, nas Figuras 30 e 31, com um mapa de calor que mostra a concentração de valores em cada iteração. As figuras também incluem o desvio padrão em cada iteração para comparação.

As Figuras 30 e 31 mostram que $\Delta P_{\text{máx}}$ tende a convergir mais lentamente para seu valor real (a variabilidade máxima encontrada em todo o conjunto de dados) em comparação com σ_{Δ} . Deve-se observar que um dia de medições, abrangendo 12 horas de geração com amostras espaçadas a intervalos de 5 min, compreende aproximadamente 144 amostras. Dado que cada iteração na figura corresponde a uma amostra, pode-se extrapolar o valor esperado de $\Delta P_{\text{máx}}$ após um determinado período de observação ao examinar o gráfico em uma contagem de iterações equivalente buscando o ponto mais quente do mapa de calor.

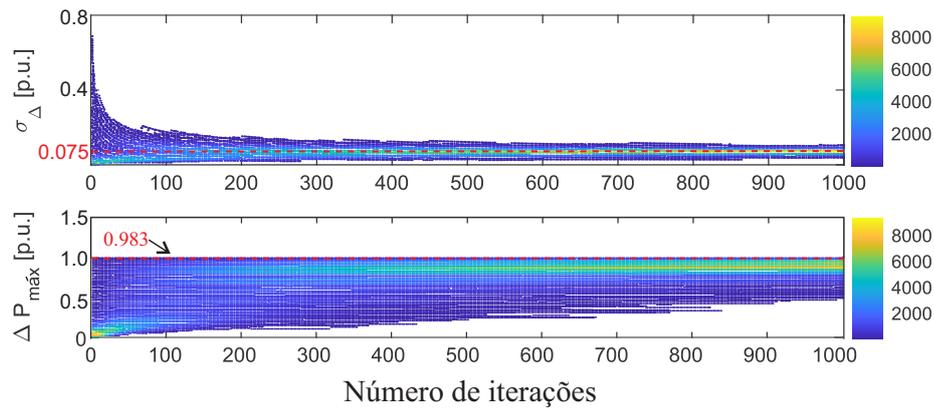
As figuras revelam que tanto σ_{Δ} quanto $\Delta P_{\text{máx}}$ exibem considerável variabilidade dentro de sequências medidas em um intervalo de um dia. Mais notavelmente, mesmo após 1.000 iterações, aproximadamente equivalente a uma semana de dados, os valores de $\Delta P_{\text{máx}}$ continuam a exibir variabilidade significativa. Essa observação suscita a dúvida de quantas amostras são necessárias para que os valores de $\Delta P_{\text{máx}}$ convirjam para um valor mais representativo da variação máxima dentro do conjunto de dados.

Figura 30 – Valor esperado de $\Delta P_{\text{máx}}$ a cada iteração considerando a variabilidade natural da planta fotovoltaica (Cocoa), em que um dia de medições compreende 144 amostras.



Fonte: Própria do Autor (2024).

Figura 31 – Valor esperado de $\Delta P_{\text{máx}}$ a cada iteração considerando a variabilidade natural da planta fotovoltaica (Eugene), em que um dia de medições compreende 144 amostras.



Fonte: Própria do Autor (2024).

A subestimação de $\Delta P_{\text{máx}}$ pode resultar em diferentes consequências, dependendo do algoritmo utilizado. No caso do SMA, a subestimação de $\Delta P_{\text{máx}}$ resulta na seleção de uma janela móvel menor do que o necessário. Isso, por sua vez, leva a ocorrências mais frequentes de variações maiores do que o estimado anteriormente. Por outro lado, no algoritmo RR, a intensidade das variações não afeta a parametrização do método. Consequentemente, as ramificações do valor subestimado de $\Delta P_{\text{máx}}$ se manifestam como uma subestimação das especificações da bateria necessária para que o algoritmo funcione conforme pretendido. Na Seção 3.3, o experimento realizado aqui é repetido de forma mais rigorosa, fazendo uso de Simulações Monte Carlo para determinar os valores prováveis de $\Delta P_{\text{máx}}$ a cada iteração.

3.2.3 Limitações da Análise Visual

Como mencionado anteriormente ao lidar com valores de $\Delta P_{\text{máx}}$, a análise visual geralmente envolve apenas um dia ou um conjunto de alguns dias. Apesar das limitações inerentes a este método, a análise visual fornece informações importantes sobre os métodos de suavização. Por exemplo, permite verificar o atraso inerente no método SMA, tornando a curva suavizada mais baixa ou mais alta do que a curva original a depender do momento, o que não ocorre com o método RR. No entanto, deve-se observar que a análise visual de apenas um dia, além de não fornecer necessariamente uma visão representativa de todo o conjunto de dias, está sujeita a julgamentos abstratos pelo observador.

Uma análise comparativa das Figuras 24 e 25 poderia levar o leitor a concluir que o método RR é superior ao método SMA, enquanto, para o caso estudado, ambos os métodos foram capazes de atender aos requisitos operacionais impostos. Pode-se, também, supor que o método SMA resulta em um valor mais alto de σ_{Δ} em comparação ao método RR. A realidade, no entanto, é o oposto disso, o que pode ser contraintuitivo à primeira vista.

3.3 SIMULAÇÃO DE MONTE CARLO PARA AVALIAÇÃO DE PARÂMETROS DE SUAVIZAÇÃO

A Simulação Monte Carlo (MCS – *Monte Carlo Simulation*), formalizada pela primeira vez por Metropolis e Ulam (1949) com base em observações anteriores realizadas por John von Neumann e Stanislaw Ulam, consiste na realização de sucessivos experimentos computacionais para estimar a probabilidade de um conjunto de eventos, dispensando a avaliação de cada estado possível do sistema. A simulação atinge esse objetivo a partir da repetida amostragem da distribuição experimental. Nesse contexto, a precisão das estimativas do método é baseada na distribuição de probabilidade inerente ao fenômeno, no método de amostragem e no número de amostragens realizadas (SILVA; CASTRO; GONZÁLEZ-FERNÁNDEZ, 2016).

A MCS se baseia na Lei dos Grandes Números (LLN – *Law of Large Numbers*), um teorema da Teoria das Probabilidades que afirma que a média dos resultados obtidos em um grande número de experimentos sucessivos idênticos se aproxima do valor esperado (também conhecido como esperança) à medida que o número de experimentos cresce.

Em (DEKKING C. KRAAIKAMP, 2005), a LLN é definida da seguinte forma:

Se \bar{X}_n é a média de n variáveis aleatórias independentes com esperança $\mathbb{E}(\bar{X}_n)$ e variância σ^2 , então para qualquer $\varepsilon > 0$:

$$\lim_{n \rightarrow \infty} \mathbb{P}(|\bar{X}_n - \mathbb{E}(\bar{X}_n)| > \varepsilon) = 0. \quad (10)$$

De forma generalista, os métodos de MCS podem ser classificados em sequenciais ou

não sequenciais. A MCS sequencial realiza a amostragem seguindo a ordem cronológica de ocorrência dos eventos. Já na MCS não sequencial, a amostragem se dá de modo aleatório, com base na distribuição experimental dos dados (SILVA; CASTRO; GONZÁLEZ-FERNÁNDEZ, 2016). O MCS não sequencial, de maior interesse para este trabalho, pode ser descrito tal qual demonstrado no Algoritmo 1. Do algoritmo, é pertinente destacar que, por motivos de economia de esforço computacional, a variância é calculada através da expressão:

$$\sigma^2 = \frac{\mathbb{E}(\bar{X}_n)^2 - \mathbb{E}(\bar{X}_n)}{n - 1}, \quad (11)$$

o que dispensa a o armazenamento de todo o conjunto de amostras sorteadas. Outro aspecto importante é o critério de convergência do algoritmo, determinado pelo coeficiente de variação (β), cujo valor de tolerância é escolhido de acordo com as circunstâncias da aplicação almejada. A seguir, na Seção 3.3.1, o algoritmo do Estimador de Monte Carlo é adaptado para os objetivos deste trabalho.

Algoritmo 1: Estimador de Monte Carlo básico.

Dados: Conjunto de dados experimentais

Resultado: Valor esperado para a variável aleatória de interesse

Entrada: *dados*

Saída: *média*

```

1 início
2   enquanto  $\beta > \text{tolerância}$  faça
3      $n \leftarrow n + 1$  // Conta o número de amostras
4      $\text{amostra} \leftarrow \text{amostragem}(\text{dados})$  // Extrai uma amostra aleatória
5      $\text{soma} \leftarrow \text{soma} + \text{amostra}$  // Soma das amostras
6      $\text{quad\_soma} \leftarrow \text{amostra}^2$  // Soma do quadrado das amostras
7      $\text{média} \leftarrow \text{soma}/n$  // Média ou valor esperado
8      $\text{média\_quad} \leftarrow \text{quad\_soma}/n$  // Média dos quadrados
9      $\text{variância} \leftarrow (\text{média\_quad} - \text{média}^2)/(n - 1)$ 
10    // Calcula a variância
11     $\beta \leftarrow \sqrt{\text{variância}}/\text{média}$  // Calcula o coefic. de variação
12 fim
13 retorna média
14 fim
```

Fonte: Própria do Autor (2024).

3.3.1 Aplicação de MCS para o Caso Estudado

Conforme comentado na Seção 3.2, o indicador $\Delta P_{\text{máx}}$, tal qual utilizado na literatura para avaliação do desempenho de métodos de suavização de potência, é fortemente susceptível às variações oriundas do número de amostras. Esse comportamento, quando não considerado cuidadosamente, pode levar a conclusões equivocadas acerca do desempenho dos métodos estudados. Diante desse contexto, faz-se relevante elaborar um método para a determinação do

número mínimo de amostras necessário para a obtenção de um valor de $\Delta P_{\text{máx}}$ estatisticamente significativo.

O Estimador de Monte Carlo Básico (vide Algoritmo 1) não é adequado para a estimação de $\Delta P_{\text{máx}}$, uma vez que visa estimar a média de uma determinada distribuição. No contexto deste trabalho, no entanto, deseja-se estimar o valor máximo de variação observado dentro de um período de observações. Para isso, algumas adequações no Algoritmo 1 se fazem necessárias, gerando o Estimador de Monte Carlo não sequencial adaptado (representado pelo Algoritmo 2). Uma das adequações necessárias é a inclusão de uma variável para armazenar o maior valor encontrado até a iteração vigente (linha 6 do Algoritmo 2). Outro ponto é que, pela natureza dessa nova variável, o valor pode ficar estático por múltiplas iterações, o que faria o algoritmo convergir rapidamente, mantendo-se em um valor pouco representativo. Para isso, inclui-se uma variável auxiliar (linha 9 do Algoritmo 2), a partir da qual são calculadas a média, a variância e as demais variáveis do algoritmo. Por fim, o algoritmo ajustado retorna o número de amostras, em oposição ao tradicional, que retorna a própria média.

Algoritmo 2: Estimador de Monte Carlo não sequencial adaptado.

Dados: Conjunto das variações de potência
Resultado: Número de amostras para garantir relevância estatística
Entrada: *dados*
Saída: *n*

```

1 início
2   enquanto  $\beta > \text{tolerância}$  faça
3      $n \leftarrow n + 1$  // Conta o número de amostras
4      $\text{amostra} \leftarrow \text{amostragem}(\text{dados})$  // Extrai uma amostra aleatória
5     se  $\text{amostra} > \text{máxima}$  então
6        $\text{máxima} \leftarrow \text{amostra}$  // Armazena maior variação
7       // já encontrada
8     fim
9      $\text{aux\_máxima} \leftarrow (\text{máxima} + \text{amostra})/2$ 
10    // Cria variável auxiliar para
11    // garantir variação entre
12    // iterações
13     $\text{soma} \leftarrow \text{soma} + \text{aux\_máxima}$  // Soma das amostras
14     $\text{quad\_soma} \leftarrow \text{aux\_máxima}^2$  // Soma do quadrado das amostras
15     $\text{média} \leftarrow \text{soma}/n$  // Média ou valor esperado
16     $\text{média\_quad} \leftarrow \text{quad\_soma}/n$  // Média dos quadrados
17     $\text{variância} \leftarrow (\text{média\_quad} - \text{média}^2)/(n - 1)$ 
18    // Calcula a variância
19     $\beta \leftarrow \sqrt{\text{variância}}/\text{média}$  // Calcula o coefic. de variação
20  fim
21  retorna n
22 fim
```

Uma vez implementado o algoritmo, resta determinar a tolerância para a qual o algoritmo funciona de acordo com o almejado. Considera-se que o algoritmo funciona adequadamente quando, ao término da execução, a variável *máxima* (linha 6 do Algoritmo 2) corresponde à máxima variação encontrada em todo o conjunto de dados na maioria das execuções. Assim, o número de amostras n retornado corresponde àquele para o qual a variável $\Delta P_{\text{máx}}$ possui a significância estatística desejada. Para investigar essa questão, diferentes valores de tolerância foram testados para Cocoa e Eugene e podem ser visualizados, respectivamente, nas Tabelas 8 e 9.

Analisando as tabelas, percebe-se que, dentre os valores avaliados, uma tolerância de 0,05 % parece ser a mais adequada. Adicionalmente, para as execuções do algoritmo observadas, o número de iterações necessárias para um $\Delta P_{\text{máx}}$ representativo é de aproximadamente 40.000. No entanto, as tabelas representam apenas um subgrupo de todas as possíveis execuções. Para visualizar o comportamento médio do algoritmo, pode-se gerar um gráfico com a média de 1.000 execuções, conforme demonstrado nas Figuras 32 e 33. Nessas figuras, torna-se evidente que o valor de tolerância escolhido é satisfatório para atingir os objetivos de estimação do máximo valor presente em todo o conjunto de dados. As figuras também reforçam a hipótese de que as 40.000 amostras são uma boa aproximação para garantir uma estimação adequada.

Tabela 8 – Resultados do Algoritmo 2 para diferentes valores de tolerância - Cocoa.

Execução	Tolerância = 1%		Tolerância = 0,1%		Tolerância = 0,05%	
	nº de iterações	valor final	nº de iterações	valor final	nº de iterações	valor final
1	653	0,919	17.020	0,953	44.700	0,953
2	826	0,902	13.556	0,953	45.231	0,953
3	759	0,770	13.471	0,947	49.442	0,953
4	605	0,953	14.048	0,908	49.774	0,953
5	527	0,902	13.267	0,953	47.816	0,953
6	310	0,624	15.005	0,912	47.465	0,953
7	814	0,789	12.581	0,912	50.386	0,953
9	288	0,773	17.731	0,953	46.461	0,953
9	503	0,892	14.278	0,947	49.267	0,953
10	626	0,849	13.071	0,912	40.829	0,953

Obs.: Em negrito os valores que correspondem à máxima variação do conjunto de dados.

Fonte: Própria do Autor (2024).

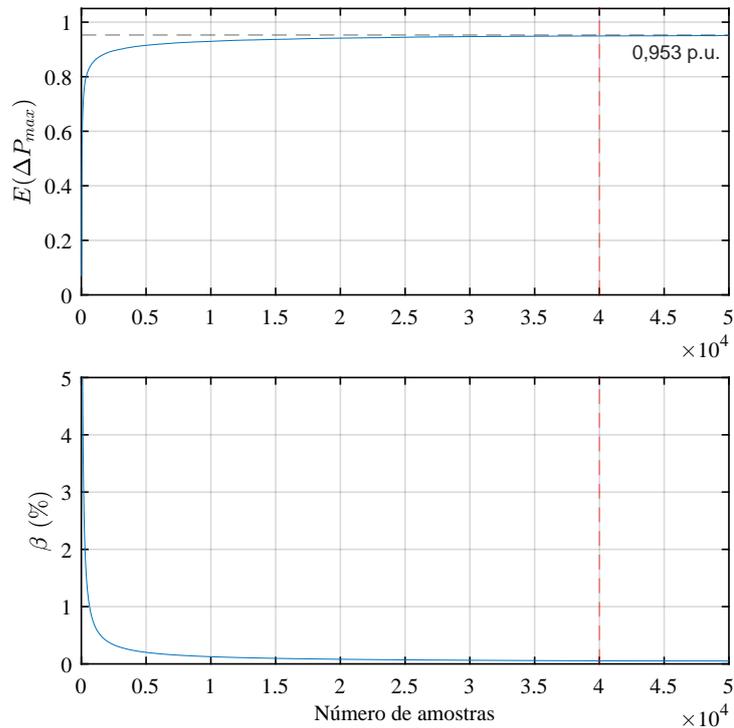
Tabela 9 – Resultados do Algoritmo 2 para diferentes valores de tolerância - Eugene.

Execução	Tolerância = 1%		Tolerância = 0,1%		Tolerância = 0,05%	
	nº de iterações	valor final	nº de iterações	valor final	nº de iterações	valor final
1	1.641	0,938	18.466	0,970	31.781	0,983
2	1.087	0,954	9.662	0,952	39.216	0,970
3	1.470	0,913	15.466	0,954	36.753	0,983
4	530	0,876	10.117	0,970	27.927	0,983
5	1.089	0,850	13.602	0,983	38.171	0,983
6	539	0,924	10.210	0,983	28.262	0,983
7	1.228	0,952	10.847	0,938	42.730	0,970
9	925	0,835	14.758	0,983	48.998	0,983
9	1.090	0,898	7.177	0,924	34.320	0,983
10	893	0,865	11.955	0,914	50.405	0,983

Obs.: Em negrito os valores que correspondem à máxima variação do conjunto de dados.

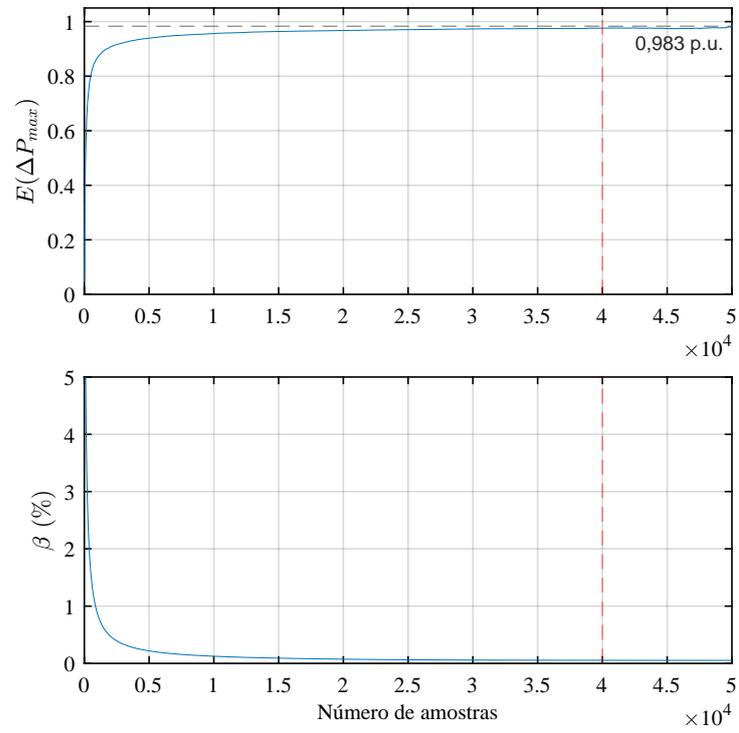
Fonte: Própria do Autor (2024).

Figura 32 – Valor esperado de ΔP_{\max} e coeficiente de variação a cada iteração (Cocoa). Em vermelho, é indicada a quantidade de amostras sugerida pelo Algoritmo 2 para garantir um valor estatisticamente significativo.



Fonte: Própria do Autor (2024).

Figura 33 – Valor esperado de $\Delta P_{\text{máx}}$ e coeficiente de variação a cada iteração (Eugene). Em vermelho, é indicada a quantidade de amostras sugerida pelo Algoritmo 2 para garantir um valor estatisticamente significativo.



Fonte: Própria do Autor (2024).

3.4 PROPOSTAS DE MÉTRICAS ALTERNATIVAS

Diante das considerações apresentadas a respeito da métrica $\Delta P_{\text{máx}}$, em especial sua elevada sensibilidade ao número de amostras, entende-se como necessária a proposição de novas métricas associadas à medição da variabilidade máxima. Nesse contexto, é essencial reconhecer que uma métrica robusta deve possuir as seguintes características:

- A capacidade de encapsular efetivamente as características pertinentes dos fenômenos observados em relação à sua intensidade e/ou frequência;
- Ser aplicável à sistemas com fontes de geração diversas ou sistemas com múltiplas fontes de geração;
- A capacidade de permitir a comparação de resultados provenientes de localidades diferentes e de dimensões diferentes; e
- Menor sensibilidade a variações associadas ao número de amostras.

Diante dessas circunstâncias, surgem duas alternativas a serem consideradas: (i) enfatizar a determinação do tempo necessário para obter um $\Delta P_{\text{máx}}$ estatisticamente significativo; ou (ii) tentar antecipar, temporalmente, a obtenção de um $\Delta P_{\text{máx}}$ estatisticamente significativo, baseando-se em apenas uma fração dos dados. A seguir, nas Subseções 3.4.1 e 3.4.2, essas duas abordagens são apresentadas em maiores detalhes.

3.4.1 Variabilidade Máxima Estatisticamente Significativa

A Variabilidade Máxima Estatisticamente Significativa, $\Delta P_{\text{máx}}^{\text{ES}}$, consiste na variabilidade máxima obtida num intervalo de tempo de análise suficientemente grande para que o seu valor seja estatisticamente significativo. Conforme mencionado anteriormente, o valor de $\Delta P_{\text{máx}}$ é tipicamente obtido através da observação de intervalos reduzidos, como um único dia. Devido a essa prática, os valores obtidos podem não representar adequadamente a variabilidade natural da instalação analisada. Conseqüentemente, o $\Delta P_{\text{máx}}$ obtido através de métodos de suavização cujo valor é proporcional à variabilidade natural da planta, como no caso do método SMA, pode ser influenciado negativamente por essa abordagem.

Uma solução para esse problema reside no aumento do intervalo de observação. No entanto, determinar a quantidade de tempo adicional necessária para a produção de um indicador estatisticamente significativo não é uma tarefa trivial. Neste trabalho, buscou-se desenvolver um algoritmo baseado em uma MCS adaptada para a resolução desse problema, resultando na elaboração do Algoritmo 2. Dessa forma, $\Delta P_{\text{máx}}^{\text{ES}}$ pode ser entendida, de forma sintética, como o valor de variabilidade máxima obtido após a observação do número necessário de amostras determinado pelo Algoritmo 2.

Apesar dos avanços proporcionados por essa métrica, cabe ressaltar, também, suas limitações. Sua utilização demanda observações durante períodos longos de tempo. Para os casos estudados das instalações em Eugene e Cocoa, seriam necessárias aproximadamente 40.000

amostras, equivalente a cerca de nove meses, o que pode tornar inviável a aplicação em aplicações reais. Outra limitação a ser considerada é que o valor de 40.000 amostras foi calculado com base nos dados completos de Cocoa e Eugene, cujos resultados – até que seja realizado um estudo mais abrangente – não podem ser generalizados para instalações com características diversas de potência instalada, de dispersão espacial e de clima. Por fim, uma limitação adicional decorre da natureza do Algoritmo 2, que visa alcançar a variabilidade máxima em todo o conjunto de dados. Essa característica torna o indicador $\Delta P_{\text{máx}}^{\text{ES}}$ incapaz de estimar máximas históricas futuras, não contempladas no histórico de variações.

Diante do exposto, compreende-se como necessário desenvolver uma métrica capaz de superar, ao menos em parte, essas limitações. Nesse contexto, a subseção seguinte apresenta uma nova métrica que tem a capacidade de antecipar temporalmente a estimativa de uma Variabilidade Máxima Estatisticamente Significativa, além de extrapolar variações para além das existentes no conjunto de dados original.

3.4.2 Variabilidade Máxima com Horizonte Antecipado

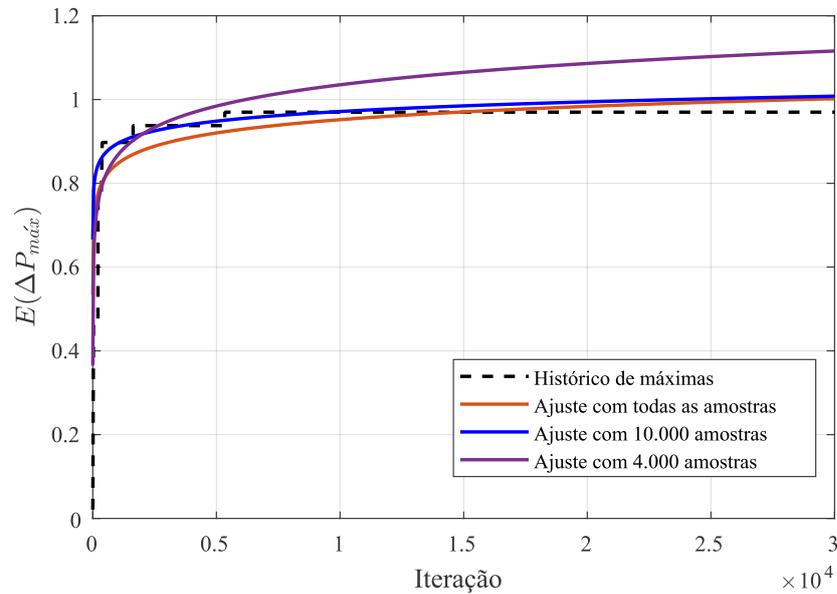
A ideia por trás da Variabilidade Máxima com Horizonte Antecipado, $\Delta P_{\text{máx}}^{\text{HA}}$, surge da constatação de que, em média, o valor esperado para $\Delta P_{\text{máx}}$ pode ser modelado pela seguinte equação:

$$\mathbb{E}(\Delta P_{\text{máx}}) = a(t) x^{b(t)} + c(t), \quad (12)$$

em que a , b e c são parâmetros variáveis obtidos a partir do ajuste aos dados experimentais disponíveis até o momento da análise, enquanto x representa o horizonte de antecipação (expresso em número de amostras) a contar da primeira amostra. Para validar essa afirmação, basta verificar o comportamento dos gráficos nas Figuras 32 e 33. Uma análise mais específica pode ser feita ao examinar o exemplo apresentado na Figura 34, onde é apresentado um histórico (baseado em amostragem aleatória) da maior variação encontrada. Essa figura ilustra claramente o processo dinâmico de ajuste com base na Equação (12), evidenciando que tal ajuste pode ser realizado a qualquer momento, gerando resultados distintos dependendo da quantidade de dados disponíveis até o momento da análise.

Observe que, à medida que o número de amostras cresce, o valor final (VF) se aproxima da variação máxima registrada. Em outras palavras, quando há indisponibilidade de informações acerca da real variação máxima (gerada pelo menor número de amostras), o VF tende a superestimar a máxima variabilidade real. Mesmo ao dispor do total das informações do histórico, o método tende a superestimar, embora em menor grau, a máxima variabilidade real. Dessa forma, o método é capaz de apresentar avanços em duas características quando comparado ao $\Delta P_{\text{máx}}^{\text{ES}}$: (i) é capaz de estimar $\Delta P_{\text{máx}}$ com diferentes graus de confiabilidade associados ao número de amostras considerado; (ii) é capaz de extrapolar valores de $\Delta P_{\text{máx}}$ para além daqueles dispostos no histórico, tornando-se capaz de antecipar máximas históricas futuras.

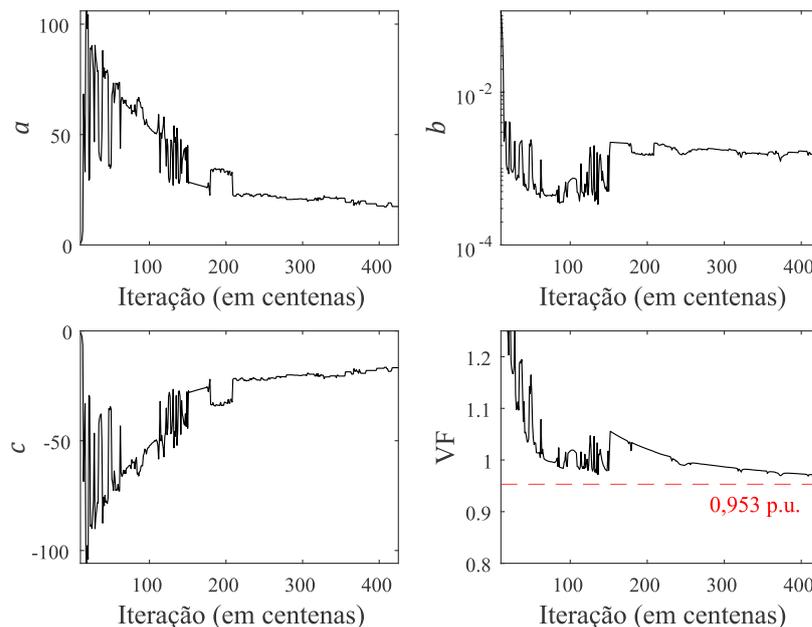
Figura 34 – Exemplo de ajuste dinâmico da Equação (12) para diferentes quantidades de amostras.



Fonte: Própria do Autor (2024).

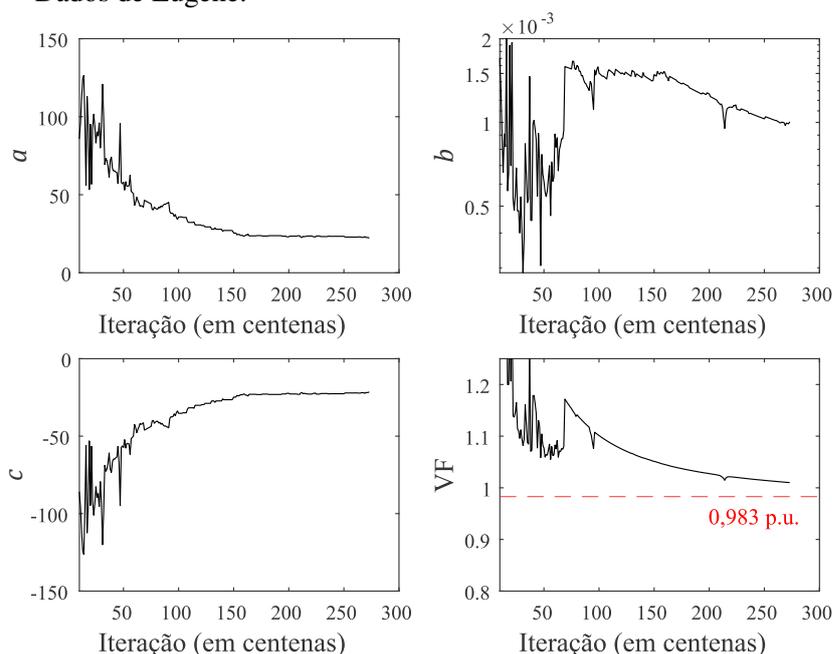
Conforme explicado, o método de estimação proposto pode ser utilizado para qualquer número de amostras. Contudo, é pertinente determinar a partir de que momento a estimação já pode ser considerada suficientemente boa. Para isso, foram realizadas simulações com os dados de Cocoa e Eugene. Na simulação, os ajustes, realizados através da Equação (12), foram calculados a cada 100 iterações. Nas Figuras 35 e 36, pode-se visualizar como os parâmetros variam no decorrer das simulações. Nessa imagens, estão representados também os valores de VF, os quais consistem em avaliar, a cada iteração, o valor da Equação (12) para $x = 40.000$.

Figura 35 – Ajuste dinâmico dos parâmetros da curva de variabilidade máxima experimental. Dados de Cocoa.



Fonte: Própria do Autor (2024).

Figura 36 – Ajuste dinâmico dos parâmetros da curva de variabilidade máxima experimental. Dados de Eugene.



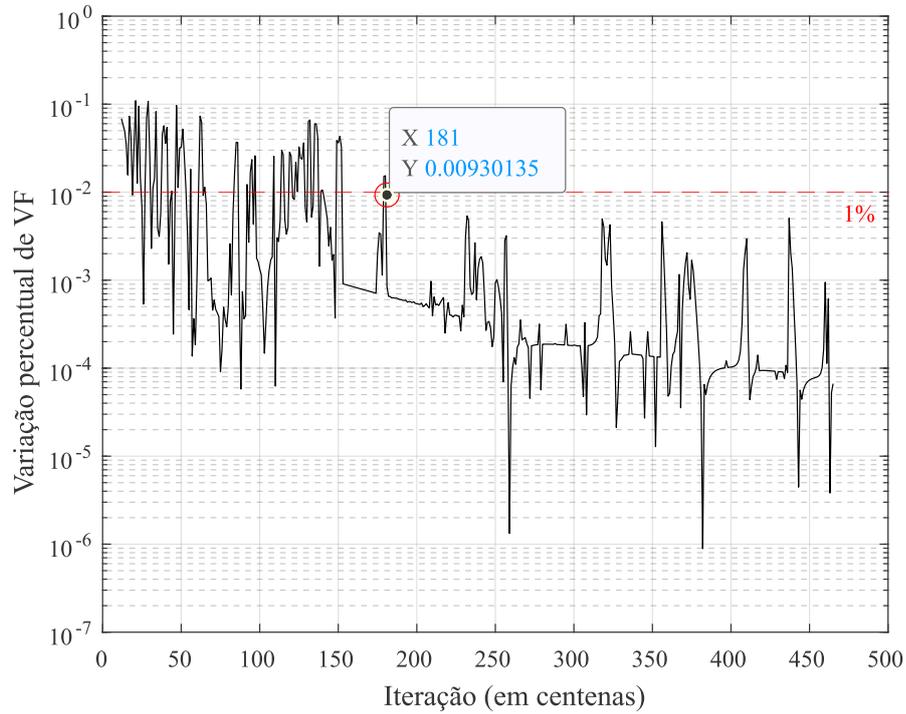
Fonte: Própria do Autor (2024).

Adicionalmente, foram avaliadas as variações percentuais de VF entre as iterações, conforme apresentado nas Figuras 37 e 38. Com base nesses resultados, pode-se determinar a partir de que iteração as variações ficam abaixo de um valor predeterminado. Neste trabalho, optou-se pela utilização de um critério de parada de 1%. Assim, considera-se satisfatória a estimação de $\Delta P_{\text{máx}}$ quando a variação percentual entre iterações subsequentes de VF fica abaixo de 1% e não torna a superar esse valor. Nessas condições, pode-se definir esse último valor de VF como a métrica $\Delta P_{\text{máx}}^{\text{HA}}$. Para Cocoa, esse valor foi alcançado em 18.100 iterações, o que corresponde a aproximadamente quatro meses de observações. Já para Eugene, foram necessárias 9.700 iterações, o que corresponde a cerca dois meses.

Há de se destacar, porém, que há margem para evolução na metodologia descrita, o que se evidencia ao analisar as Figuras 37 e 38. Nessas figuras, é possível constatar que as variações abruptas nos parâmetros entre iterações subsequentes — desnecessárias uma vez que não alteram a tendência central — acabam por exigir mais iterações para alcançar o critério de parada. Nesse contexto, soluções que limitam as taxas de variações dos parâmetros (ou fixam parte dos parâmetros), constituem alternativas para a evolução do método descrito.

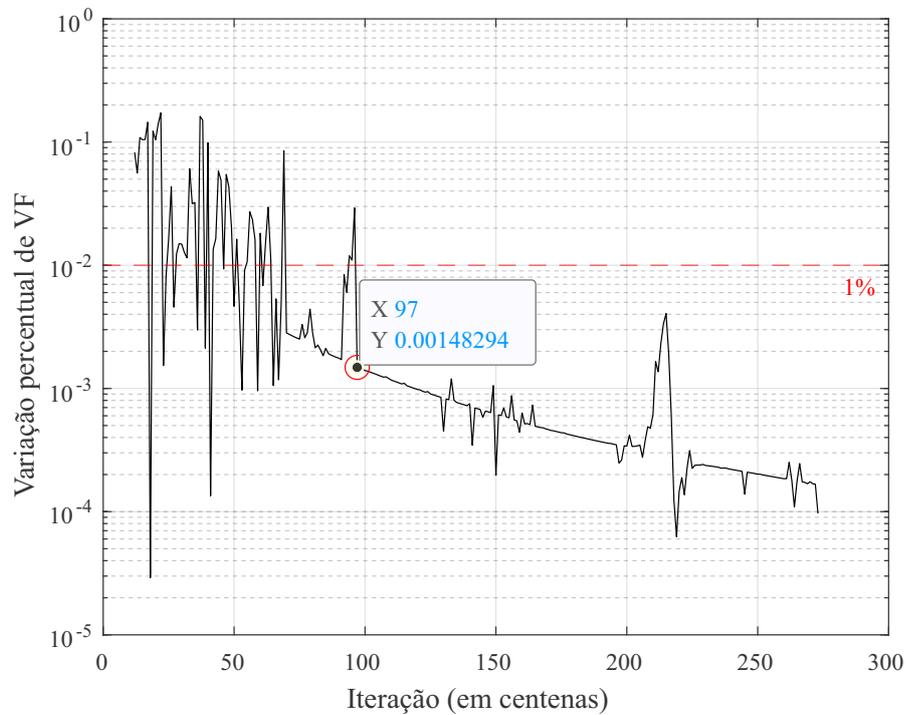
O método proposto pode ser implementado seguindo o fluxograma apresentado na Figura 39. Este fluxograma oferece uma visão clara e sequencial dos passos necessários para a estimação da Variabilidade Máxima com Horizonte Antecipado ($\Delta P_{\text{máx}}^{\text{HA}}$). Deve-se ressaltar o valor de 40.000 foi utilizado com base no Algoritmo 2 e pode mudar, com base no mesmo algoritmo, a depender das características da aplicação.

Figura 37 – Variação do valor de VF entre iterações (dados de Cocoa). Em vermelho, está destacada a primeira iteração na qual o critério de parada é satisfeito.



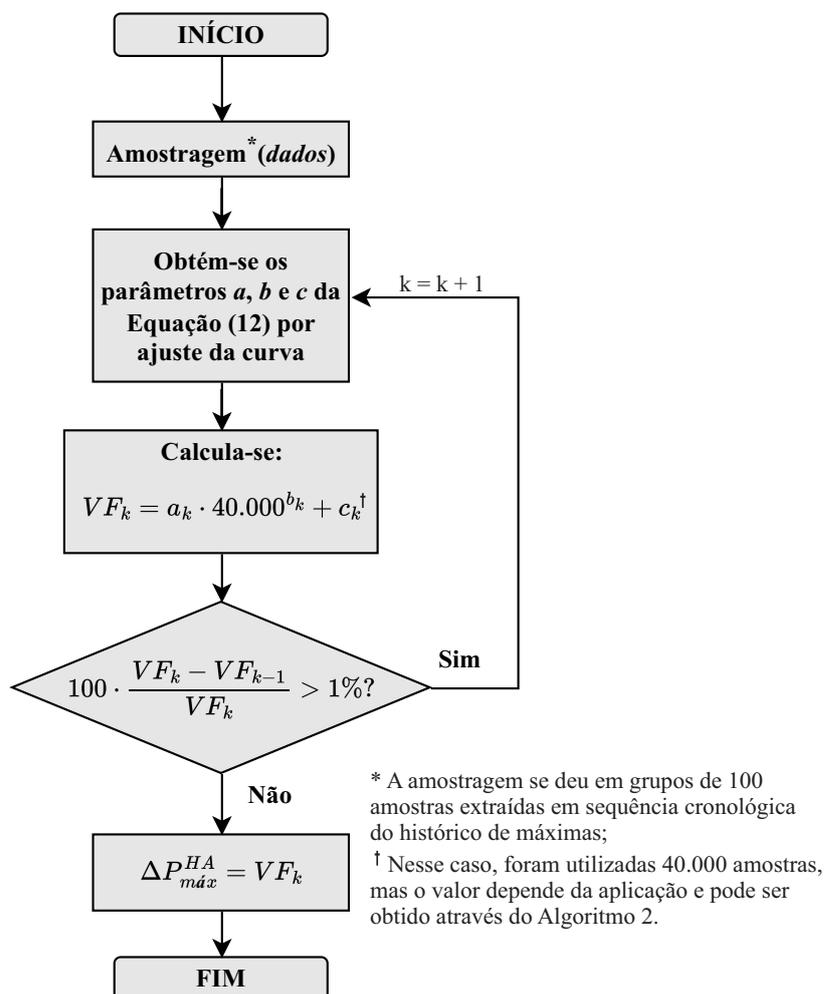
Fonte: Própria do Autor (2024).

Figura 38 – Variação do valor de VF entre iterações (dados de Eugene). Em vermelho, está destacada a primeira iteração na qual o critério de parada é satisfeito.



Fonte: Própria do Autor (2024).

Figura 39 – Fluxograma do algoritmo para a determinação da Variabilidade Máxima com Horizonte Antecipado ($\Delta P_{máx}^{HA}$).



Fonte: Própria do Autor (2024).

3.4.3 Comparação Qualitativa entre as Métricas

As métricas utilizadas neste capítulo pode ser avaliadas quanto à sua capacidade de atendimento aos itens apresentados a seguir. Os resultados da comparação qualitativa podem ser conferidos nas Tabelas 10 e 11.

- [I] Capacidade de hierarquizar métodos de suavização quanto ao seu impacto na necessidade de reservas operativas, mas sem fornecer informações pertinentes ao seu dimensionamento.
- [II] Capacidade de hierarquizar métodos de suavização quanto ao seu impacto na necessidade de reservas operativas, fornecendo também informações pertinentes ao seu dimensionamento.
- [III] Possibilidade de utilizar a métrica na comparação de resultados provenientes de localidades diferentes e de dimensões diferentes.
- [IV] Grau de sensibilidade às variações associadas ao número de amostras.

Tabela 10 – Comparação qualitativa das métricas voltadas à análise da probabilidade das variações de potência.

Métricas \ Critérios	Critérios			
	[I]	[II]	[III]	[IV]
σ_{Δ}	✓	✗	✗	baixo
$\sigma_{\Delta,99.73\%}$	✓	✗	✗	baixo
Análise da PDF, CDF e percentis	✓	✓	✓	baixo

Fonte: Própria do Autor (2024).

Tabela 11 – Comparação qualitativa das métricas voltadas à análise da intensidade das variações de potência.

Métricas \ Critérios	Critérios			
	[I]	[II]	[III]	[IV]
$\Delta P_{\text{máx}}$	✗	✗	✓	alto
$\Delta P_{\text{máx}}^{\text{ES}}$	✓	✗	✓	muito baixo
$\Delta P_{\text{máx}}^{\text{HA}}$	✓	✓	✓	baixo

Fonte: Própria do Autor (2024).

3.5 CONCLUSÕES PARCIAIS

Neste capítulo, um subgrupo de algoritmos — representativo das principais famílias de métodos utilizados para geração de referência em suavização de potência — foi aplicado a um conjunto de dados oriundos de medições experimentais. Com base nos resultados obtidos, algumas métricas comumente utilizadas para avaliar a suavização de potência foram avaliadas. Além disso, avaliou-se também o fenômeno da variabilidade de potência do ponto de vista da sua distribuição de probabilidade e as consequências disso sobre as ocorrências de variação de potência.

Uma das métricas analisadas foi o desvio padrão, acerca do qual algumas constatações pertinentes podem ser realizadas. Ao analisar o σ_{Δ} em Cocoa e Eugene, verificou-se que, embora Eugene possua um menor σ_{Δ} , essa localidade registrou uma máxima variação de potência maior do que Cocoa dentro do período analisado. Constata-se, assim, que não há uma relação direta entre σ_{Δ} e $\Delta P_{\text{máx}}$, sendo esta última especialmente relevante devido ao seu uso na parametrização dos métodos e no dimensionamento do sistema de armazenamento de energia associado.

Outra constatação pertinente associada ao desvio padrão é que os valores de σ_{Δ} diferem de modo significativo entre os métodos, mesmo ao se considerar os mesmos requisitos de projeto e a mesma localidade. Essa discrepância também é verificada ao analisar o mesmo método em

duas localidades diferentes. Com base nisso, pode-se afirmar que o σ_{Δ} é uma métrica limitada no que diz respeito ao seu uso para validar o atendimento a requisitos de projeto, além de não ser adequada para comparar resultados entre diferentes localidades.

Os resultados obtidos também possibilitaram a análise da sensibilidade de $\Delta P_{\text{máx}}$ em relação ao número de amostras. Conforme discutido neste capítulo, a subestimação desse valor pode levar à escolha de uma janela móvel insatisfatória, no caso do método SMA, ou ao incorreto dimensionamento da bateria, no caso do método RR. Com base nos resultados obtidos, pôde-se confirmar a hipótese de que valor de $\Delta P_{\text{máx}}$ é altamente susceptível ao número de amostras. Utilizando um algoritmo Estimador de Monte Carlo adaptado, foi possível estimar o número de amostras necessárias para garantir um $\Delta P_{\text{máx}}$ estatisticamente significativo, representado por $\Delta P_{\text{máx}}^{\text{ES}}$. O valor encontrado para as localidades e a resolução temporal avaliada, 40.000 amostras, equivale a cerca de nove meses de medição.

Apesar de representar uma evolução frente às alternativas, a Variabilidade Máxima Estatisticamente Significativa ($\Delta P_{\text{máx}}^{\text{ES}}$) ainda apresenta limitações significativas associadas, principalmente, à necessidade de um longo período de observação. Por esse motivo, desenvolveu-se uma métrica adicional denominada Variabilidade Máxima com Horizonte Antecipado ($\Delta P_{\text{máx}}^{\text{HA}}$). Essa métrica, baseada no ajuste dinâmico de parâmetros, foi capaz de superar as principais limitações presentes no $\Delta P_{\text{máx}}^{\text{ES}}$, o que é evidenciado pelo cumprimento aos requisitos descritos nas Tabelas 10 e 11.

Adicionalmente, buscou-se avaliar as variações de potência a partir da sua distribuição de probabilidade. Diversos resultados obtidos apontam para o fato de que as variações de potência não podem ser adequadamente caracterizadas por uma distribuição Gaussiana, o que está de acordo com a literatura correlata. Reforçam essa afirmação as CDFs obtidas, os dados da Tabelas 6 e 7 e os valores de $\sigma_{99.73\%}$. Esse comportamento não gaussiano possui grande impacto na probabilidade de ocorrência de eventos extremos, fazendo com que eles ocorram com maior frequência. Outra consequência dessa característica é a impossibilidade de avaliar a probabilidade de um conjunto de valores com base no valor de σ_{Δ} , o que torna impraticável o uso desse indicador para estimar reservas operativas.

Nesse contexto, observa-se a necessidade de uma caracterização mais aprofundada das variações de potência em termos de sua distribuição de probabilidade. Para isso, planeja-se investigar a literatura no campo de caracterização da variabilidade de potência, o que é feito no Capítulo 4.

4 ESTIMAÇÃO DE DISTRIBUIÇÃO DE PROBABILIDADE PARA VARIABILIDADE DE POTÊNCIA

Neste capítulo, o foco do trabalho se recai sobre a caracterização das variações de potência, também conhecidas como desvios, flutuações ou incrementos. Para isso, alguns métodos de caracterização da literatura são aplicados em um conjunto de dados conhecido, e os resultados obtidos são utilizados para avaliar as limitações dessas abordagens.

À medida que a geração distribuída cresce em capacidade instalada, ampliam-se em relevância as problemáticas associadas à sua inserção do ponto de vista da operação do sistema. Uma das características de impacto para a operação das fontes de geração eólica e fotovoltaica é o seu caráter fundamentalmente intermitente. Essa intermitência, difícil de antecipar graças ao seu caráter estocástico, torna especialmente relevante caracterizar as flutuações de potência associadas adequadamente. Conforme detalhado no Capítulo 2, as variações de potência são definidas a partir das diferenças entre medições subsequentes separadas por uma diferença temporal fixa Δt , tal que

$$\Delta P(t) = P(t) - P(t - \Delta t). \quad (13)$$

A depender da direção das variações, ΔP pode assumir valores positivos ou negativos. O conjunto de dados das variações de potência pode ser utilizado para gerar histogramas normalizados por densidade de probabilidade. Esses histogramas, oriundos de dados experimentais, podem ser caracterizados por Funções de Densidade de Probabilidade (PDF – *Probability Density Function*).

Pode-se argumentar, partindo de uma perspectiva intuitiva, que o caráter estocástico e intermitente das variações de potência em usinas fotovoltaicas e eólicas é minimizado ao analisar o agregado de vários parques ou regiões geográficas inteiras. No entanto, a literatura existente na área indica que, embora a variabilidade seja reduzida à medida que a escala de análise cresce, o comportamento não gaussiano dessas fontes de geração persiste (ANVARI et al., 2016). Isto é, o comportamento não gaussiano não está presente apenas em pequena escala (conforme visto nas localidades do Capítulo 3), mas também no agregado de regiões inteiras. À primeira vista, essa constatação parece incorreta, já que o Teorema do Limite Central (CLT — *Central Limit Theorem*) aponta que quando a quantidade de amostras aumenta, a distribuição amostral da sua média aproxima-se cada vez mais de uma distribuição Gaussiana.

Mais formalmente, o CLT é definido como (BILLINGSLEY, 1968 apud TALEB, 2022):

Suponha uma sequência de variáveis aleatórias independentes e identicamente distribuídas, tal que $\mathbb{E}(X_i) = \mu$ e $\mathbb{V}(X_i) = \sigma^2 < +\infty$ e \bar{X}_n a média para n amostras. À medida que n se aproxima do infinito, a soma das variáveis aleatórias $\sqrt{n}(\bar{X}_n - \mu)$ converge para uma distribuição Gaussiana:

$$\sqrt{n}(\bar{X}_n - \mu) \xrightarrow{d} N(0, \sigma^2). \quad (14)$$

Vale ressaltar que, conforme destacado em seu enunciado, o CLT pressupõe que as variáveis aleatórias devem ser independentes e identicamente distribuídas. No entanto, evidências da literatura correlata indicam que essas considerações não são válidas para o caso de usinas eólicas e fotovoltaicas. Verifica-se, nesses casos, a existência de correlações na velocidade do vento e na distribuição geográfica das nuvens, mesmo ao considerar grandes áreas, o que está de acordo com a persistência do caráter não gaussiano das variações de potência dessas fontes de geração (WOOD; FIELD, 2011) (BAÏLE; MUZY, 2010).

Conforme detalhado no Capítulo 3 (e reforçado pelos dados das Tabelas 6 e 7), a definição da PDF que adequadamente representa o fenômeno físico das variações de potência não é mera formalidade. Ao considerar esses eventos como possuidores de um caráter gaussiano, tende-se a subestimar, em ordem de grandeza significativa, a probabilidade de ocorrência de eventos extremos. Essa subestimação, por sua vez, resulta em análises equivocadas no que diz respeito à necessidade de reservas operativas ou, tratando mais especificamente no campo de suavização de potência, no dimensionamento inadequado do sistema de armazenamento. A seguir, é apresentada a Estimativa por Máxima Verossimilhança, relevante para as discussões apresentadas neste capítulo, e, em seguida, é realizada uma síntese da literatura correlata associada à estimação de PDF para variações de potência.

4.1 ESTIMATIVA POR MÁXIMA VEROSSIMILHANÇA

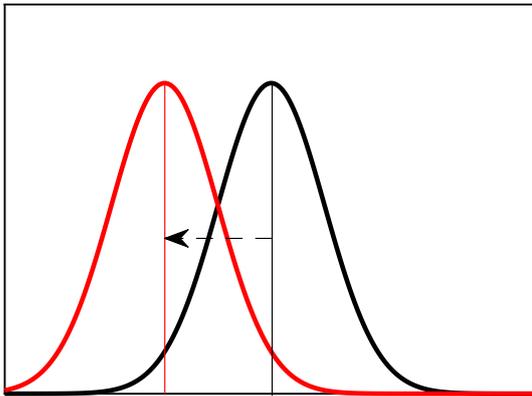
Conforme mencionado anteriormente, distribuições experimentais podem ser caracterizadas, de forma paramétrica, por PDFs. No entanto, são muitas as possibilidades de PDFs candidatas a melhor representação do fenômeno estudado, o que suscita a seguinte pergunta: como saber o quão bem a curva estimada (PDF) representa os pontos experimentais? A resposta para esse questionamento pode ser obtida a partir do uso do conceito de verossimilhança, capaz de quantificar essa relação. Nesta seção, a distribuição Gaussiana, já introduzida em seções anteriores, é utilizada como ferramenta auxiliar para o entendimento do conceito de Estimativa por Máxima Verossimilhança (MLE - *Maximum Likelihood Estimation*) e seu uso no contexto deste trabalho.

A PDF da distribuição Gaussiana é definida a partir de dois parâmetros, sendo eles a média (μ) e o desvio padrão (σ), conforme a Equação (15). O parâmetro μ modifica a média da distribuição e, por consequência, a desloca horizontalmente (Figura 40). Por outro lado, o

segundo parâmetro, σ , controla a dispersão da distribuição, sendo que valores maiores de σ resultam em uma distribuição mais ampla, reduzindo seu pico central (Figura 41).

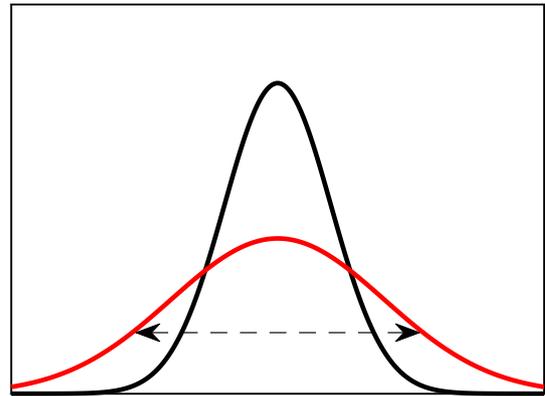
$$\varphi(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \quad (15)$$

Figura 40 – Efeito da variação de μ .



Fonte: Própria do Autor (2024).

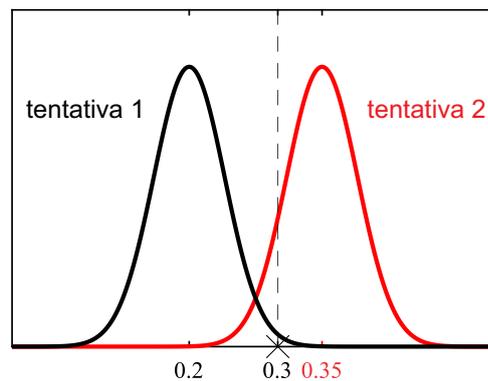
Figura 41 – Efeito da variação de σ .



Fonte: Própria do Autor (2024).

Com base no conhecimento acerca dos efeitos da variação dos parâmetros da distribuição, é possível encontrar os valores de μ e σ que melhor representam os dados experimentais. Como exemplo, pode-se considerar o caso mais simples, em que se dispõe de apenas uma medição experimental (considere, arbitrariamente, o valor de $\Delta P = 0,3$ p.u.). Nesse caso, assumindo uma distribuição Gaussiana, pode-se tentar aproximar a distribuição aos dados experimentais a partir da variação dos valores de μ e σ . Nesse exemplo, considere os valores $\mu = 0,2$ p.u. (tentativa 1) e $\mu = 0,35$ p.u. (tentativa 2), ambos com um σ também arbitrário de $0,1$ p.u. (Figura 42).

Figura 42 – Tentativas de estimaco da distribuo experimental.



Fonte: Própria do Autor (2024).

Aplicando os valores de $\mu = 0,2$ p.u. e $\mu = 0,35$ p.u na Equao (15), tem-se que, para um σ de $0,1$ p.u.,

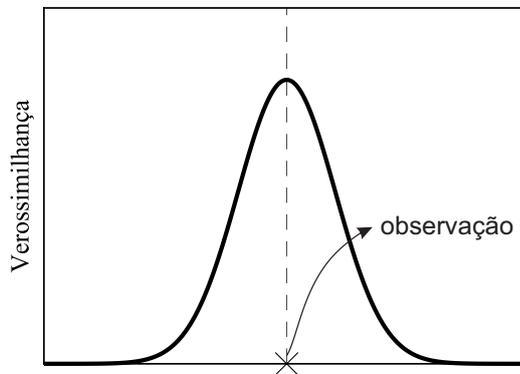
$$\mathbb{L}(\mu = 0,2, \sigma = 0,1 \mid x_1 = 0,3) = \frac{1}{0,1\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{0,3-0,2}{0,1}\right)^2} = 2,4197 \quad (16)$$

e

$$\mathbb{L}(\mu = 0,35, \sigma = 0,1 \mid x_1 = 0,3) = \frac{1}{0,1\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{0,3-0,35}{0,1}\right)^2} = 3,5207. \quad (17)$$

Ao analisar os dois valores obtidos, percebe-se que, à medida que o valor de μ se aproxima da média real experimental, o valor da verossimilhança cresce, pois a distribuição escolhida representa mais adequadamente a observação experimental. Se o processo for repetido para todos os valores possíveis de μ , obtém-se um gráfico da verossimilhança em função de μ . Nesse gráfico, o ponto mais alto da distribuição (sua média, no caso de uma Gaussiana), coincide com o valor da observação da qual se dispõe. Assim, para o caso com apenas uma observação, é fácil perceber que $\mathbb{L}(x) \propto \mathbb{P}(x)$, como demonstrado na Figura 43 ¹.

Figura 43 – Verossimilhança máxima.



Fonte: Própria do Autor (2024).

Mais formalmente, pode-se dizer que:

A verossimilhança de que qualquer parâmetro (ou conjunto de parâmetros) deva ter algum valor atribuído (ou conjunto de valores) é proporcional à probabilidade de que, se isso fosse verdade, a totalidade das observações fosse a observada (FISHER; RUSSELL, 1922).

Note que a afirmação acima é válida para um conjunto de amostras, não se restringindo ao exemplo com uma única observação (como o mostrado acima). Matematicamente, a afirmação generalizada acima pode ser representada por:

$$\mathbb{L}(\mu, \sigma) \propto \mathbb{P}(x_1, x_2, \dots, x_N \mid \mu, \sigma), \quad (18)$$

em que

$$\mathbb{L}(\mu, \sigma \mid x_1, x_2, \dots, x_N) = \mathbb{L}(\mu, \sigma \mid x_1) \times \mathbb{L}(\mu, \sigma \mid x_2) \times \dots \times \mathbb{L}(\mu, \sigma \mid x_N), \quad (19)$$

desde que as observações sejam independentes. Para simplificar os cálculos, pode-se aplicar o logaritmo natural em ambos os lados da equação. Assim:

$$\ln [\mathbb{L}(\mu, \sigma \mid x_1, x_2, \dots, x_N)] = \ln \left[\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x_1-\mu}{\sigma}\right)^2} \right] + \dots + \ln \left[\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x_N-\mu}{\sigma}\right)^2} \right]. \quad (20)$$

¹ **Observação:** Uma constatação análoga pode ser realizada ao analisar a variação do valor de σ , mas, nesse caso, a demonstração requer mais de uma observação.

Expandindo a Equação (20), constata-se que:

$$\begin{aligned}
& -\ln(\sigma\sqrt{2\pi}) - \frac{1}{2}\left(\frac{x_1 - \mu}{\sigma}\right)^2 + \dots - \ln(\sigma\sqrt{2\pi}) - \frac{1}{2}\left(\frac{x_N - \mu}{\sigma}\right)^2, \\
& -\ln \sigma - \frac{1}{2} \ln 2\pi - \frac{1}{2}\left(\frac{x_1 - \mu}{\sigma}\right)^2 + \dots - \ln \sigma - \frac{1}{2} \ln 2\pi - \frac{1}{2}\left(\frac{x_N - \mu}{\sigma}\right)^2, \\
\therefore \mathbb{L}(\mu, \sigma \mid x_1, x_2, \dots, x_N) &= -N \ln \sigma - \frac{N}{2} \ln 2\pi - \frac{1}{2}\left(\frac{x_1 - \mu}{\sigma}\right)^2 - \dots - \frac{1}{2}\left(\frac{x_N - \mu}{\sigma}\right)^2. \quad (21)
\end{aligned}$$

Para encontrar os valores que maximizam a verossimilhança, pode-se derivar a Equação (21) em relação aos seus parâmetros μ e σ . Igualando as expressões resultantes a zero, encontra-se o máximo da função e, conseqüentemente, os valores dos parâmetros que correspondem à melhor aproximação do conjunto de dados experimentais. Isso significa que, ao considerar N amostras, para μ faz-se:

$$\begin{aligned}
\frac{\partial \mathbb{L}}{\partial \mu} &= \left(\frac{x_1 - \mu}{\sigma^2}\right) + \dots + \left(\frac{x_N - \mu}{\sigma^2}\right), \\
\therefore \frac{\partial \mathbb{L}}{\partial \mu} &= \frac{1}{\sigma^2}[(x_1 + \dots + x_N) - N\mu], \quad (22)
\end{aligned}$$

que, ao ser igualado a zero, resulta em:

$$\begin{aligned}
\frac{1}{\sigma^2}[(x_1 + \dots + x_N) - N\mu] &= 0, \\
N\mu &= (x_1 + \dots + x_N), \\
\therefore \mu &= \frac{(x_1 + \dots + x_N)}{N}. \quad (23)
\end{aligned}$$

Analogamente, para σ faz-se:

$$\frac{\partial \mathbb{L}}{\partial \sigma} = -\frac{N}{\sigma} + \frac{(x_1 - \mu)^2}{\sigma^3} + \dots + \frac{(x_N - \mu)^2}{\sigma^3}, \quad (24)$$

que, ao ser igualado a zero, resulta em:

$$\begin{aligned}
-\frac{N}{\sigma} + \frac{(x_1 - \mu)^2}{\sigma^3} + \dots + \frac{(x_N - \mu)^2}{\sigma^3} &= 0, \\
-N\sigma^2 + (x_1 - \mu)^2 + \dots + (x_N - \mu)^2 &= 0, \\
\therefore \sigma &= \sqrt{\frac{(x_1 - \mu)^2 + \dots + (x_N - \mu)^2}{N}}. \quad (25)
\end{aligned}$$

Assim, demonstra-se que os parâmetros μ e σ para os quais a verossimilhança é máxima são justamente aqueles correspondentes à média e ao desvio padrão da própria distribuição experimental. No entanto, essa constatação, intuitiva para o caso da distribuição Gaussiana, não pode ser generalizada para outras distribuições. Portanto, é pertinente analisar cuidadosamente a MLE própria da distribuição de interesse, sendo necessária a obtenção analítica dos parâmetros da MLE. Na Seção 4.2, uma revisão da literatura aponta as distribuições mais utilizadas para a caracterização da variabilidade de potência de fontes renováveis intermitentes. Nesses casos, sempre que viável, a MLE é utilizada para a estimação dos parâmetros da distribuição.

4.2 MÉTODOS DE ESTIMAÇÃO ORIUNDOS DA LITERATURA

Tomando como referência de partida o ano de 2010, buscou-se na literatura alternativas para a caracterização da variabilidade de potência baseadas em distribuições de probabilidade. Os trabalhos encontrados estão listados na Tabela 12 e são apresentados nas subseções a seguir.

Tabela 12 – Distribuições de probabilidade utilizadas para caracterização das variações de potência na literatura.

Referência (AUTORES, ANO)	PDF	Natureza do conjunto de dados †
(ANVARI et al., 2016)	q-Exponencial	PV, WP
(MAZUMDAR; SAQUIB; DAS, 2014)	Sigmoide*	PV
(LOUIE, 2010)	Laplace, GEV e Gaussiana	WP
(KEERATIMAHAT; BRUCE; MACGILL, 2019)	Laplace	PV
(LEE; BALDICK, 2012)	Laplace	WP
(RAOOFAT et al., 2018)	Laplace	WP
(RAYGANI; SHARMA; SAHA, 2013)	Gaussiana	PV

* Ainda que não seja uma PDF, é utilizada de forma análoga. † PV = Geração Fotovoltaica; WP = Geração Eólica.

Fonte: Própria do Autor (2024).

4.2.1 Caracterização Proposta por Anvari et al. (2016)

Em (ANVARI et al., 2016), os autores apresentam uma caracterização baseada na distribuição q-Exponencial, cuja PDF é dada por:

$$\varphi(x) = A [1 - \beta(1 - q)x]^{1/1-q}, \quad (26)$$

com parâmetros β e q e uma constante de normalização dada por

$$A = \frac{1}{2(2 - q)\beta}. \quad (27)$$

Na Equação (26), x representa todos os valores possíveis de variação de potência normalizados pelo seu desvio padrão. O parâmetro q é calculado a partir da planicidade (*flatness*, no original)², f , tal que:

$$f = 6 \cdot \frac{(2q - 3)(3q - 4)}{(4q - 5)(5q - 6)}. \quad (28)$$

Para valores de $f \geq 2,4$, q pode ser obtido a partir da seguinte expressão:

$$q = -\frac{\sqrt{f^2 + 84f + 36} - 49f + 102}{40f - 72}. \quad (29)$$

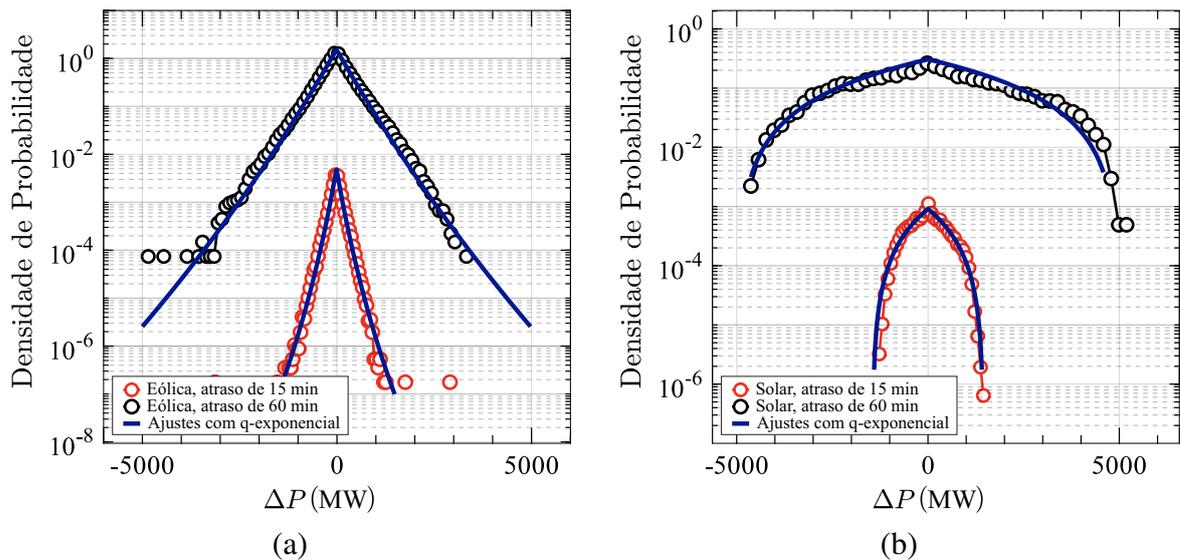
² **Observação:** Escolheu-se, aqui, pela manutenção da nomenclatura do conteúdo original. No entanto, cabe ressaltar que, nesse contexto, planicidade é um termo alternativo para se referir à curtose.

Já o parâmetro remanescente, β , pode ser calculado a partir do valor de q e da variância da distribuição:

$$\beta = \sqrt{\frac{2(q-2)}{\sigma^2(3q-4)(2q^2-7q+6)}}. \quad (30)$$

De modo a validar o modelo proposto em (ANVARI et al., 2016), os autores fazem uso de dados coletados em alta frequência (0,001 - 1 Hz) em oito localidades, das quais três são parques eólicos, quatro são medições de irradiância e uma corresponde a uma usina fotovoltaica. Geograficamente, as localidades contemplam climas suficientemente diversos. Os intervalos de medição variam entre oito meses e 10 anos, a depender da localidade. Uma amostra dos resultados obtidos pode ser visualizada nas Figuras 44a e 44b. Também constam, no material original, gráficos da variação dos valores de q , β e f para diferentes localidades e intervalos de flutuação.

Figura 44 – Resultado do uso da distribuição q-Exponencial para caracterizar flutuações de potência em (a) uma usina eólica e (b) uma usina fotovoltaica. Foram consideradas flutuações de intervalos de 15 e 60 min.



Fonte: Adaptado de (ANVARI et al., 2016).

A partir dos resultados da caracterização, os autores concluem que as variações de potência em usinas eólicas e fotovoltaicas podem ser adequadamente modeladas através de uma distribuição q-Exponencial. Além disso, os autores consideram que essa modelagem permanece válida para uma ampla gama de valores de flutuações normalizadas (considerando frequências de amostragens diversas), desde que os valores de q e β sejam ajustados para cada caso, de acordo com a metodologia descrita.

Conforme mencionado na Seção 4.1, os parâmetros que melhor aproximam a distribuição experimental podem ser obtidos a partir da MLE. Em alguns casos, no entanto, a obtenção analítica desses parâmetros não é possível ou não é trivial, como é o caso da distribuição q-Exponencial. Em (ANVARI et al., 2016), os autores optam por um ajuste baseado na planicidade

da distribuição experimental. Todavia, devido a essa simplificação, não se pode afirmar que esse é o melhor ajuste possível³. Assim, os autores também concluem que é necessário analisar essa questão com maior profundidade e alertam para a possível necessidade de utilização de outros métodos de determinação dos parâmetros da distribuição, especialmente em relação às suas caudas (ANVARI et al., 2016).

4.2.2 Caracterização Proposta por Mazumdar, Saquib e Das (2014)

Em (MAZUMDAR; SAQUIB; DAS, 2014), os autores propõem uma caracterização das variações de potência a partir da modelagem da função de distribuição acumulada (CDF) experimental por meio de uma função sigmoide. A seguir, apresenta-se uma síntese da obtenção analítica, detalhada no texto original, de uma expressão para a CDF das flutuações de potência. Considere o seguinte conjunto das amostras de variações inferiores a um limite arbitrário λ , normalizadas pela soma dos valores:

$$\prod(\lambda, \Delta t) = \{P(t) \mid P(t + \Delta t) - P(t) < \lambda\}. \quad (31)$$

Nesse cenário, as probabilidades dos desvios serem menores que λ ou maiores que ou iguais a λ são dadas, respectivamente, por:

$$\mathbb{P}([P(t + \Delta t) - P(t) < \lambda]) = \mathbb{F}(\lambda) \quad (32)$$

e

$$\mathbb{P}([P(t + \Delta t) - P(t) \geq \lambda]) = 1 - \mathbb{F}(\lambda), \quad (33)$$

em que \mathbb{F} representa a função distribuição acumulada.

Considere, agora, um pequeno incremento h no valor de λ . Analogamente, para o conjunto

$$\prod(\lambda + h, \Delta t) = \{P(t) \mid P(t + \Delta t) - P(t) < \lambda + h\}, \quad (34)$$

tem-se que:

$$\mathbb{P}([P(t + \Delta t) - P(t) < \lambda + h]) = \mathbb{F}(\lambda + h). \quad (35)$$

Segundo Mazumdar, Saquib e Das (2014), devido à natureza estocástica das fontes intermitentes, a probabilidade dos eventos $\{P(t) \in \prod(\sigma, \Delta t)\}$ e $\{P(t) \in \prod(\sigma + h, \Delta t)\}$ podem ser consideradas mutuamente independentes. Naturalmente, o mesmo pode ser dito em relação às probabilidades $\{P(t) \notin \prod(\sigma, \Delta t)\}$ e $\{P(t) \in \prod(\sigma + h, \Delta t)\}$. Assim, para um pequeno incremento h , a probabilidade de uma flutuação ser igual a λ é dada por:

$$\mathbb{P}([P(t + \Delta t) - P(t) = \lambda]) \simeq \mathbb{P}([\lambda \leq P(t + \Delta t) - P(t) \leq \lambda + h]), \quad (36)$$

³ **Observação:** Consulte (SHALIZI, 2007) para uma introdução ao problema da estimação dos parâmetros para ajustes em distribuições q-Exponenciais.

$$= \mathbb{P} \left(\left\{ P(t) \notin \prod(\lambda, \Delta t) \right\} \cap \left\{ P(t) \in \prod(\sigma + h, \Delta t) \right\} \right), \quad (37)$$

$$= \mathbb{P} \left(\left\{ P(t) \notin \prod(\lambda, \Delta t) \right\} \right) \times \mathbb{P} \left(\left\{ P(t) \in \prod(\lambda + h, \Delta t) \right\} \right). \quad (38)$$

Em decorrência das Equações (31) e (32), tem-se:

$$\mathbb{P} \left(\left\{ P(t) \notin \prod(\lambda, \Delta t) \right\} \right) \propto 1 - \mathbb{F}(\lambda). \quad (39)$$

Essa constatação, em conjunto à Equação (38), permite concluir que:

$$\mathbb{P} (P(t + \Delta t) - P(t) = \lambda) \propto \mathbb{F}(\lambda + h)[1 - \mathbb{F}(\lambda)]. \quad (40)$$

Ao considerar o Teorema Fundamental do Cálculo, a Equação (32) pode ser escrita como:

$$\mathbb{P} ([P(t + \Delta t) - P(t) = \lambda]) = \frac{d\mathbb{F}(\lambda)}{d\lambda}. \quad (41)$$

Portanto, tomando como referência essa expressão e a Equação (40), tem-se:

$$\frac{d\mathbb{F}(\lambda)}{d\lambda} = \kappa \mathbb{F}(\lambda)[1 - \mathbb{F}(\lambda)], \quad (42)$$

onde κ é uma constante representativa do caráter proporcional previamente indicado. Resolvendo essa equação diferencial, é possível obter a seguinte expressão para \mathbb{F} em função de λ :

$$\mathbb{F}(\sigma) = \frac{e^{\beta\lambda}}{C_1 + e^{\beta\lambda}}, \quad (43)$$

em que C_1 é uma constante genérica. Por fim, rearranjando os termos e substituindo as constantes, obtém-se o modelo proposto por Mazumdar, Saquib e Das (2014):

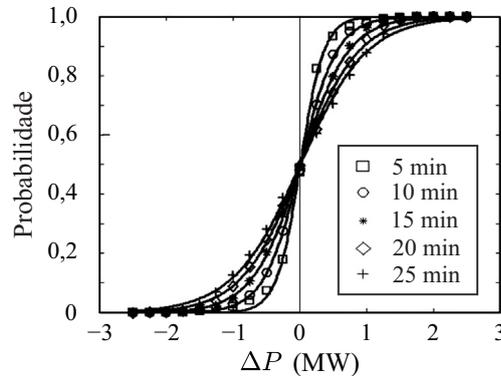
$$\mathbb{F}(\lambda) = \frac{1}{1 + \alpha e^{-\beta\lambda}}. \quad (44)$$

De modo a validar o modelo proposto, Mazumdar, Saquib e Das (2014) utilizam medições de potência oriundas de um parque fotovoltaico no distrito de Karnataka, na Índia. A instalação possui uma capacidade instalada de 3 MW (pico) e as medições foram obtidas com um intervalo de 5 min entre as amostras, realizadas durante o período de um ano. Um subgrupo dos resultados pode ser visualizado na Figura 45.

Em (MAZUMDAR; SAQUIB; DAS, 2014), os autores também discutem como os valores de α e β , presentes na Equação (44), dos ajustes são afetados pela variação de Δt e pelas estações do ano. Os autores observam que o valor de α decai linearmente com o aumento de Δt , enquanto o valor de β decai exponencialmente. Os valores de ambos os parâmetros também parecem estar sujeitos a sazonalidades, já que α e β variam em margens de, respectivamente, 5 e 50% no ano.

A partir dos resultados da caracterização e da comparação dos percentis de probabilidade das CDFs experimental e ajustada, Mazumdar, Saquib e Das (2014) concluem que a modelagem é satisfatória para a aplicação almejada (estimação de taxas de rampa). No entanto, observa que, dada a elevada flutuação dos parâmetros ao decorrer o ano, as caracterizações devem ser segregadas temporalmente e realizadas sobre um conjunto menor de dados.

Figura 45 – Resultado do uso da função sigmoide para caracterizar flutuações de potência em uma usina fotovoltaica. Foram consideradas flutuações de intervalos de 5, 10, 15, 20 e 25 min.



Fonte: Adaptado de (MAZUMDAR; SAQUIB; DAS, 2014).

4.2.3 Caracterização Proposta por Louie (2010)

Em (LOUIE, 2010), três distribuições de probabilidade são consideradas para caracterizar as variações de potência, são elas: a distribuição de Laplace; a distribuição generalizada de valor extremo (GEV – *Generalized Extreme Value*); e a distribuição Gaussiana. Louie (2010) enfatiza que as distribuições supracitadas foram consideradas graças ao seu caráter simétrico (opcional, no caso da GEV) e por permitirem uma centralização em torno de zero. A PDF da Gaussiana é dada por:

$$\varphi(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}, \quad (45)$$

em que σ e μ são, respectivamente, a média e o desvio padrão. Um outro exemplo do uso da distribuição Gaussiana para caracterização das variações de potência pode ser visto em (RAYGANI; SHARMA; SAHA, 2013). Já a distribuição de Laplace é dada por:

$$\varphi(x) = \frac{1}{2b} \exp\left(-\frac{|x-\mu|}{b}\right), \quad (46)$$

em que b é o parâmetro de escala. Por fim, a GEV é dada por:

$$\varphi(x) = \frac{1}{\sigma} t(x)^{\xi+1} e^{-t(x)}, \quad (47)$$

em que

$$t(x) \equiv \begin{cases} [1 + \xi \left(\frac{x-\mu}{\sigma}\right)]^{-\frac{1}{\xi}} & \text{se } \xi \neq 0, \\ \exp\left(-\frac{x-\mu}{\sigma}\right) & \text{se } \xi = 0. \end{cases} \quad (48)$$

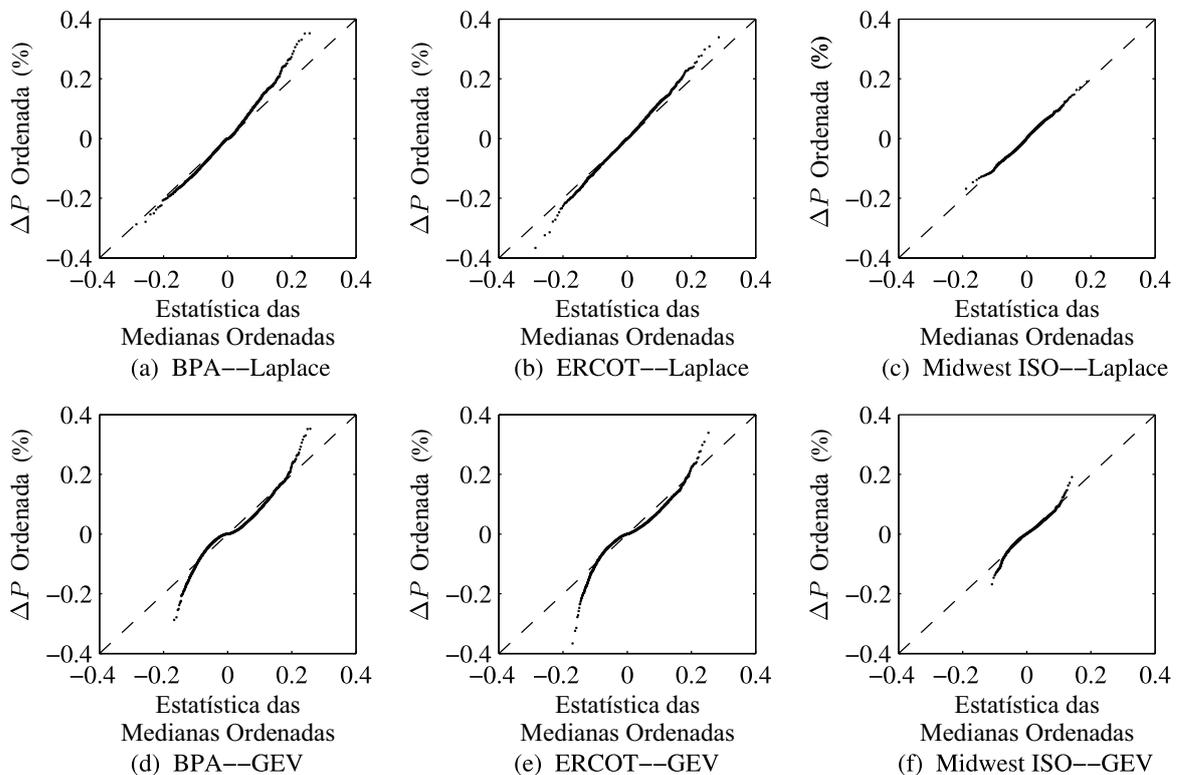
e ξ é o parâmetro de forma da distribuição GEV.

A validação da caracterização a partir das distribuições apresentadas nesta subseção foi realizada com o auxílio de três conjuntos de dados de medição em usinas eólicas com capacidade instalada entre 1.000 e 5.000 MW. Esses dados são oriundos das seguintes instituições: *Bonneville Power Administration (BPA)*, *Electric Reliability Council of Texas (ERCOT)* e

Midwest Independent System Operator (Midwest ISO). Os dados, amostrados de hora em hora, contemplam um ano de medição, nos casos BPA e ERCOT, e seis meses, no caso *Midwest ISO*.

Para a obtenção dos parâmetros de ajuste, os autores utilizaram a MLE. Os resultados obtidos foram comparados através da análise de seus percentis, com base em gráficos q-q (Figura 46). Adicionalmente, o autor utiliza a métrica χ^2 , descrita por Papoulis e Pillai (2002), para rejeitar ou não a hipótese do ajuste realizado. Em síntese, os resultados obtidos indicam que, dentre as distribuições avaliadas, a distribuição de Laplace é a que melhor modela as variações de potência empíricas. Os autores afirmam, no entanto, que essa caracterização deve ser utilizada de forma cautelosa, pois as caracterizações realizadas não foram capazes de passar pelo teste do χ^2 em parte significativa dos subconjuntos avaliados.

Figura 46 – Comparação entre os percentis de probabilidade para as distribuições de Laplace e GEV. Os resultados da distribuição Gaussiana foram omitidos no artigo por limitação de espaço.



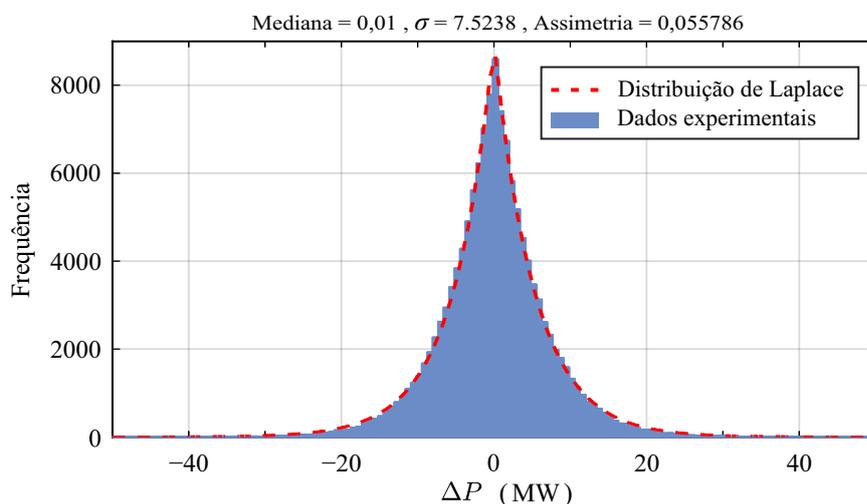
Fonte: Adaptado de (LOUIE, 2010).

4.2.4 Caracterizações Propostas por Lee e Baldick (2012), Raoufat et al. (2018) e Keeratimahat, Bruce e MacGill (2019)

Os trabalhos desenvolvidos por Lee e Baldick (2012), Raoufat et al. (2018) e Keeratimahat, Bruce e MacGill (2019) constituem exemplos adicionais do uso da distribuição de Laplace para caracterização das variações de potência em fontes intermitentes. Em (LEE; BALDICK, 2012), o foco do trabalho está no dimensionamento e na operação de uma bateria para fins de redução das flutuações de potência em parques eólicos. Para isso, o autor modela as variações

através de uma distribuição de Laplace e utiliza os dados agregados de todas as usinas eólicas da ERCOT, amostrados a cada 20 segundos, durante o mês de maio de 2008. A caracterização realizada em (LEE; BALDICK, 2012) pode ser visualizada na Figura 47.

Figura 47 – Resultado do uso da distribuição de Laplace para caracterizar flutuações de potência num agregado de geração eólica.



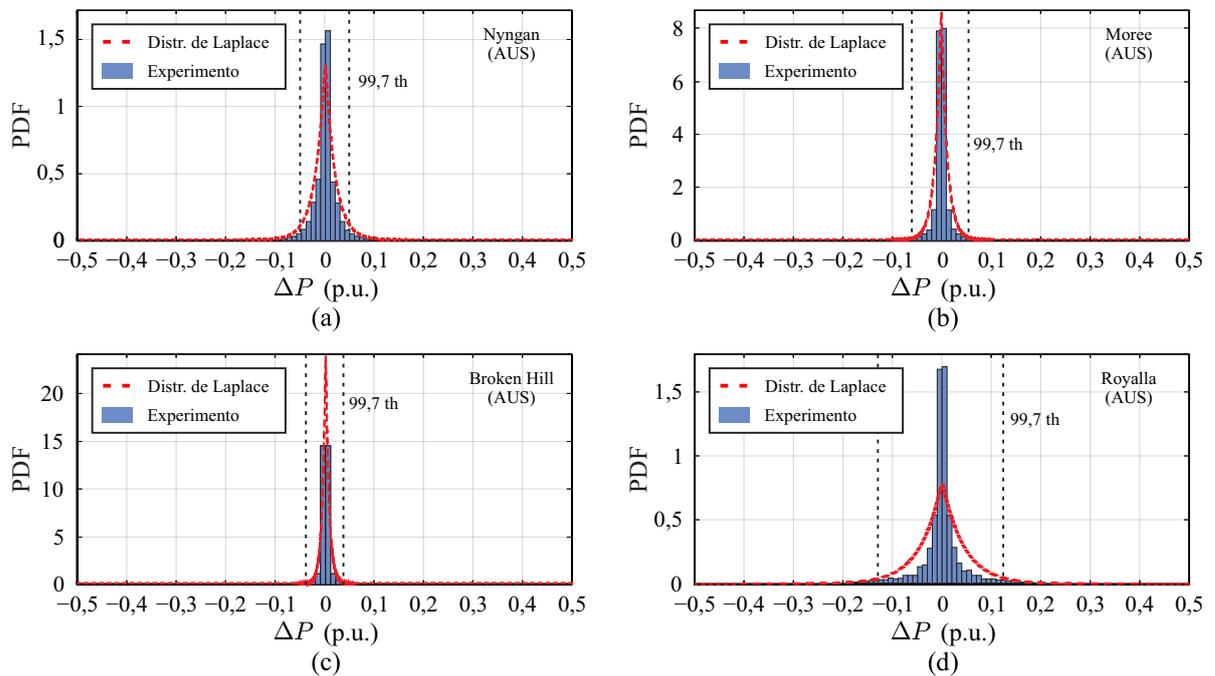
Fonte: Adaptado de (LEE; BALDICK, 2012).

Inspirado no trabalho desenvolvido por Lee e Baldick (2012), os autores de (RAOOFAT et al., 2018) estudam uma microrrede com inserção de geração eólica, modelando as rampas oriundas dessa fonte de geração através da distribuição de Laplace. No artigo, um esquema de controle para suavização utilizando resposta à demanda por parte de veículos elétricos é proposto. Outro exemplo do uso da distribuição de Laplace pode ser encontrado em (KEERATIMAHAT; BRUCE; MACGILL, 2019). Nesse estudo, os autores investigam os efeitos da razão entre a capacidade do inversor e a capacidade instalada de geração (razão CA/CC) sobre a variabilidade de potência. Para isso, são utilizados dados de quatro instalações fotovoltaicas, coletados entre 2016 e 2017 com amostragem a cada 20 segundos, oriundos Operador do Mercado de Energia da Austrália (AEMO – *Australian Energy Market Operator*). Os ajustes realizados para as quatro instalações podem ser visualizados na Figura 48.

4.2.5 Outras Abordagens Possíveis

Uma revisão da literatura mais extensa, não realizada neste trabalho devido a limitações de tempo, poderia contemplar fenômenos físicos cuja natureza estocástica é similar às variações de potência em fontes renováveis. A análise da literatura associada à caracterização desses fenômenos poderia avançar o estado-da-arte do campo da suavização de potência. Nesse contexto, um dos campos de estudo com potencial é o do estudo das flutuações de frequência. Alguns exemplos são os trabalhos desenvolvidos por Haehne et al. (2018) e Schäfer et al. (2018). Outras oportunidades também residem na análise de distribuições ainda não exploradas na literatura, como as distribuições Logística, t de Student e de Cauchy.

Figura 48 – Resultado do uso da distribuição de Laplace para caracterizar flutuações de potência nos parques fotovoltaicos da Austrália: (a) Nyngan, (b) Moree, (c) Broken Hill e (d) Royalla.

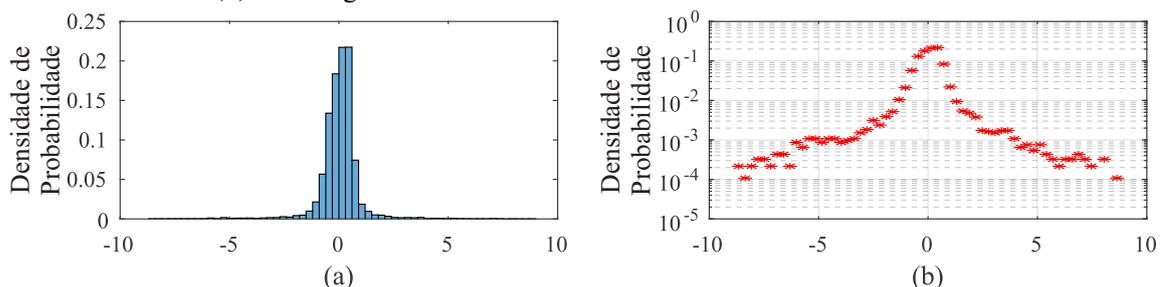


Fonte: Adaptado de (KEERATIMAHAT; BRUCE; MACGILL, 2019).

4.3 APLICAÇÃO DOS MÉTODOS DE CARACTERIZAÇÃO SOBRE O CONJUNTO DE DADOS ESTUDADOS

Uma vez apresentadas as PDFs utilizadas na literatura para a caracterização das variações de potência, pode-se aplicá-las aos conjuntos de dados utilizados neste trabalho. Assim, visando avaliar essas alternativas, fez-se uso dos dados de Cocoa e Eugene para implementar as metodologias dos trabalhos descritos na Seção 4.2. É pertinente destacar também que nas seções a seguir, em oposição ao padrão adotado nas demais partes do trabalho, os histogramas de densidade de probabilidade são apresentados em gráfico semi-log, o que permite a melhor visualização das caudas das distribuições de probabilidade. Adicionalmente, opta-se por representar as barras do histogramas por pontos, de modo a facilitar a visualização do ajuste. As duas formas de representação estão exemplificadas na Figura 49, considerando o mesmo conjunto de dados.

Figura 49 – Histograma para um mesmo conjunto de dados representado em escala (a) linear e (b) semi-log.

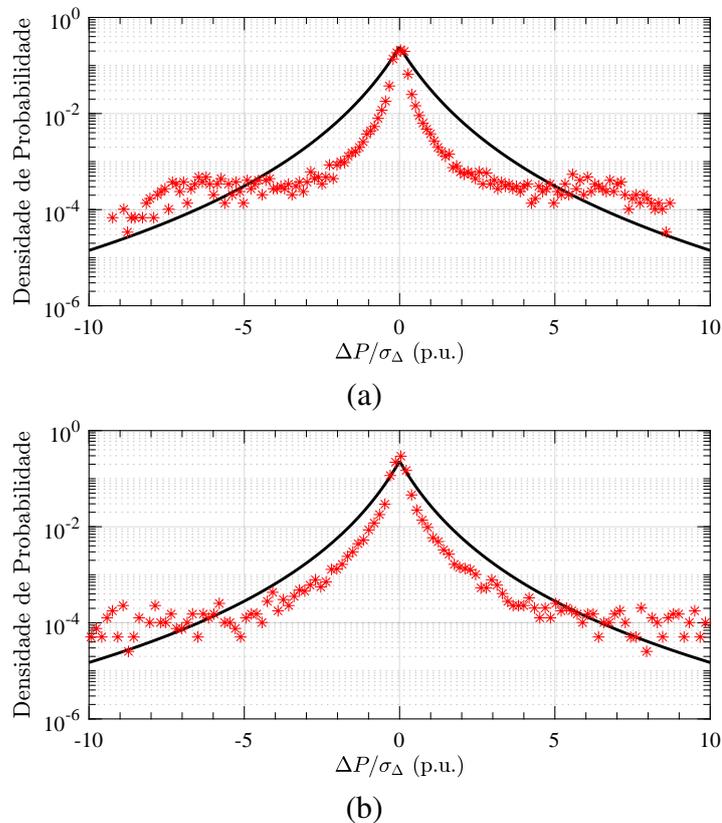


Fonte: Própria do Autor (2024).

4.3.1 Avaliação da Distribuição q-Exponencial

Os resultados da caracterização para os dados de Cocoa e Eugene ao utilizar a distribuição q-Exponencial podem ser visualizados na Figura 50. Conforme demonstrado na figura referida, a distribuição experimental, quando exibida em gráfico semi-log, possui um formato de "chave", distinguindo-se significativamente do formato da distribuição q-Exponencial. Apesar da divergência de formato, a distribuição q-Exponencial é capaz de acompanhar a ordem de grandeza da distribuição experimental em boa parte dos intervalos. Para conferência, os parâmetros associados aos ajustes podem ser visualizados na Tabela 13.

Figura 50 – Resultado do uso da distribuição q-Exponencial para caracterizar flutuações de potência em (a) Cocoa e (b) Eugene.



Fonte: Própria do Autor (2024).

Tabela 13 – Parâmetros da distribuição q-Exponencial para a caracterização das flutuações de potência em Cocoa e Eugene.

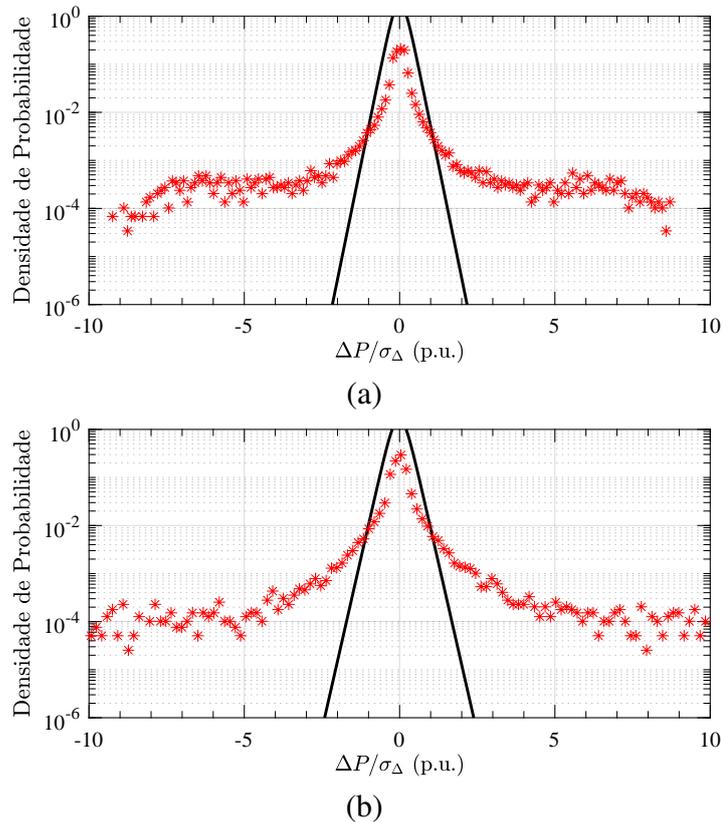
Localidade \ Parâmetro	q	β
Cocoa	1,166	2,446
Eugene	1,181	2,622

Fonte: Própria do Autor (2024).

4.3.2 Avaliação da Distribuição Sigmoide

A análise comparativa entre a distribuição experimental e a sigmoide, ilustrada na Figura 51 e obtida numericamente a partir da CDF, evidencia a incapacidade do ajuste em representar adequadamente o fenômeno da variabilidade de potência, especialmente para os desvios de maior intensidade. Esse resultado, aparentemente divergente em relação ao apresentado por (MAZUMDAR; SAQUIB; DAS, 2014), é melhor explorado na Seção 4.4. Contudo, uma análise cuidadosa da comparação, apresentada no artigo, entre a probabilidade de ocorrência do desvio *versus* a sua probabilidade empírica, evidencia que o autor incluiu apenas os valores referentes a desvios de pequena intensidade. Essa escolha reforça a compatibilidade dos resultados obtidos em (MAZUMDAR; SAQUIB; DAS, 2014) e os obtidos neste trabalho. Por fim, os parâmetros resultantes do ajuste para a função sigmoide podem ser visualizados na Tabela 14.

Figura 51 – Resultado do uso da função sigmoide para caracterizar flutuações de potência em (a) Cocoa e (b) Eugene.



Fonte: Própria do Autor (2024).

Tabela 14 – Parâmetros da função sigmoide para a caracterização das flutuações de potência em Cocoa e Eugene.

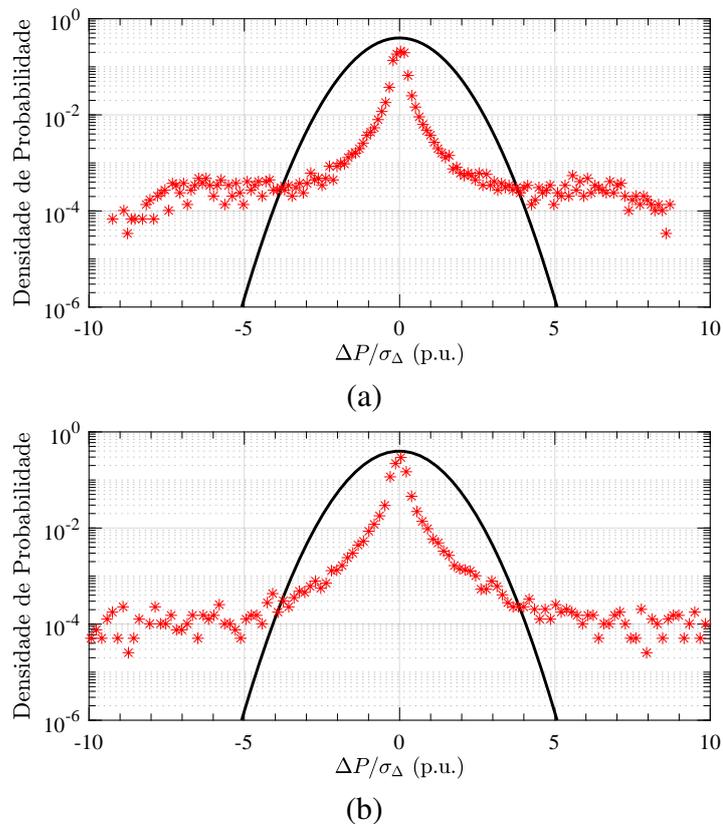
Localidade	Parâmetro	
	α	β
Cocoa	1,031	7,287
Eugene	0,914	6,538

Fonte: Própria do Autor (2024).

4.3.3 Avaliação da Distribuição Gaussiana

A distribuição Gaussiana – e as suas limitações para estimação da probabilidade de ocorrência de variações de potência – já foi discutida de forma extensa no Capítulo 3. Na Figura 52, essa limitação é novamente destacada, uma vez que é possível constatar visualmente a incapacidade do modelo baseado na distribuição Gaussiana de capturar os efeitos da variabilidade presente, especialmente, para desvios de maior amplitude. Os parâmetros da caracterização utilizando a distribuição Gaussiana podem ser vistos na Tabela 15.

Figura 52 – Resultado do uso da distribuição gaussiana para caracterizar flutuações de potência em (a) Cocoa e (b) Eugene.



Fonte: Própria do Autor (2024).

Tabela 15 – Parâmetros da distribuição Gaussiana para a caracterização das flutuações de potência em Cocoa e Eugene.

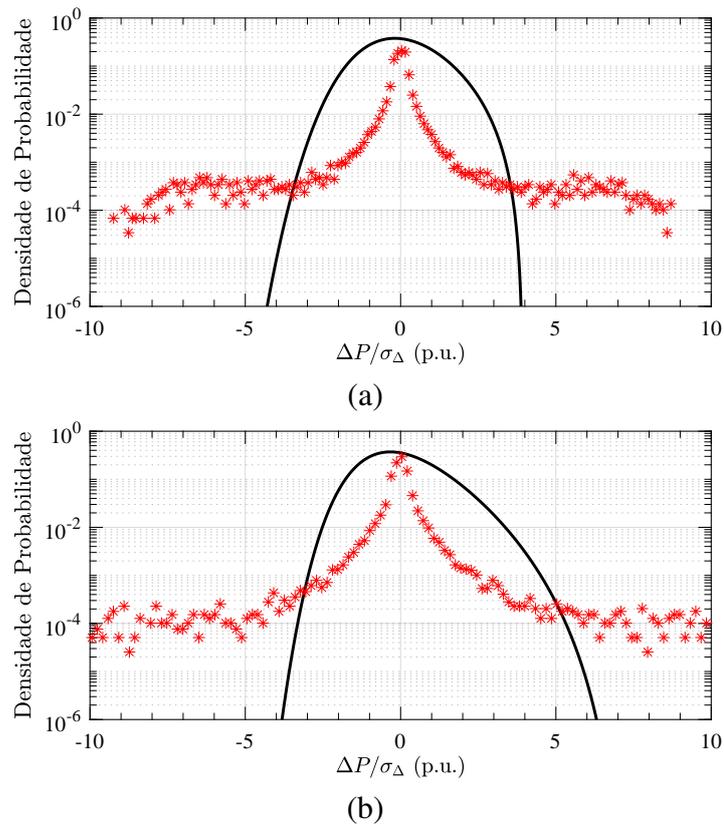
Localidade \ Parâmetro	Localização	Escala
Cocoa	$-5,131 \cdot 10^{-3}$	1,000
Eugene	$-7,500 \cdot 10^{-3}$	1,000

Fonte: Própria do Autor (2024).

4.3.4 Avaliação da Distribuição GEV

A distribuição GEV difere-se das demais apresentadas por ser capaz de exibir um formato assimétrico, como pode ser visualizado na Figura 53. Essa característica torna esse método de caracterização suscetível a resíduos presentes nos dados, cuja média, embora próxima, não é exatamente zero. Na Figura 16, é possível verificar os parâmetros resultantes do ajuste para a distribuição GEV.

Figura 53 – Resultado do uso da distribuição GEV para caracterizar flutuações de potência em (a) Cocoa e (b) Eugene.



Fonte: Própria do Autor (2024).

Tabela 16 – Parâmetros da distribuição GEV para a caracterização das flutuações de potência em Cocoa e Eugene.

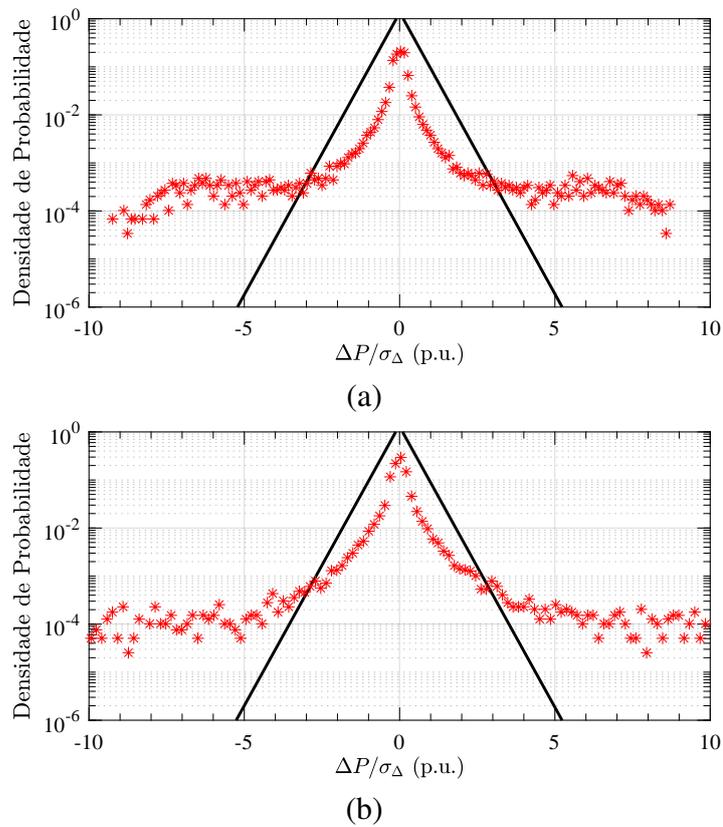
Localidade \ Parâmetro	Localização	Escala	Forma
Cocoa	0,228	-0,436	2,099
Eugene	0,128	-0,466	1,744

Fonte: Própria do Autor (2024).

4.3.5 Avaliação da Distribuição de Laplace

Conforme discutido na revisão da literatura, a distribuição de Laplace é a alternativa mais utilizada para a caracterização de flutuações de potência. No entanto, os resultados obtidos (vide Figura 54) indicam que essa distribuição não foi capaz de reproduzir adequadamente o formato e a ordem de grandeza da distribuição experimental, ao menos para o método de estimação de parâmetros utilizado neste trabalho. Os parâmetros, calculados através da MLE, estão disponíveis para consulta na Tabela 17.

Figura 54 – Resultado do uso da distribuição de Laplace para caracterizar flutuações de potência em (a) Cocoa e (b) Eugene.



Fonte: Própria do Autor (2024).

Tabela 17 – Parâmetros da distribuição de Laplace para a caracterização das flutuações de potência em Cocoa e Eugene.

Localidade \ Parâmetro	Localização	Escala
Cocoa	$6,876 \cdot 10^{-3}$	0,370
Eugene	$-14,198 \cdot 10^{-3}$	0,372

Fonte: Própria do Autor (2024).

4.3.6 Análise Comparativa dos Resultados Obtidos

Uma vez apresentadas as opções de caracterização disponíveis na literatura e os resultados obtidos ao aplicá-las aos dados deste trabalho, considera-se pertinente compará-las. É importante ressaltar que, dentre os sete artigos detalhados nas seções anteriores, apenas em (LOUIE, 2010) é possível verificar algum tipo de comparação entre diferentes propostas de caracterização. Também é importante destacar que as buscas na literatura não encontraram artigos dedicados à listagem ou comparação de propostas distintas, o que representa uma lacuna nessa área de estudo, em parte remediada pelo conteúdo deste capítulo.

Neste trabalho, optou-se por comparar os resultados obtidos a partir da probabilidade de ocorrência dos desvios, conforme apresentado nas Tabelas 18 e 19. Essa abordagem foi escolhida porque o foco deste trabalho é a análise no contexto de suavização de potência, e a correta estimação da probabilidade dos desvios é o principal objetivo da caracterização das variações de potência. Nesse contexto, foram avaliados três intervalos de intensidade de variação: $\mathbb{P}(\Delta P \leq -x \text{ ou } \Delta P \geq x)$, em que x assume os valores de 3σ , 5σ e 7σ .

Tabela 18 – Comparação entre probabilidade de ocorrência dos eventos para as distribuições avaliadas (dados de Cocoa).

PDF	Probabilidade de ocorrência do evento (%)		
	$\mathbb{P}(\Delta P \geq 3\sigma)$	$\mathbb{P}(\Delta P \geq 5\sigma)$	$\mathbb{P}(\Delta P \geq 7\sigma)$
Experimental	2,53	1,53	0,51
Gaussiana	0,27	$5,73 \cdot 10^{-5}$	$2,56 \cdot 10^{-10}$
q-Exponencial	1,83	0,38	0,12
Sigmoide	$6,41 \cdot 10^{-8}$	$3,33 \cdot 10^{-14}$	≈ 0
Laplace	0,03	$1,37 \cdot 10^{-4}$	$6,16 \cdot 10^{-7}$
GEV	17,41	2,27	0,08

Fonte: Própria do Autor (2024).

Tabela 19 – Comparação entre probabilidade de ocorrência dos eventos para as distribuições avaliadas (dados de Eugene).

PDF	Probabilidade de ocorrência do evento (%)		
	$\mathbb{P}(\Delta P \geq 3\sigma)$	$\mathbb{P}(\Delta P \geq 5\sigma)$	$\mathbb{P}(\Delta P \geq 7\sigma)$
Experimental	1,56	0,93	0,61
Gaussiana	0,27	$5,73 \cdot 10^{-5}$	$2,56 \cdot 10^{-10}$
q-Exponencial	1,82	0,41	0,13
Sigmoide	$6,10 \cdot 10^{-7}$	$1,28 \cdot 10^{-12}$	≈ 0
Laplace	0,03	$1,44 \cdot 10^{-4}$	$6,64 \cdot 10^{-7}$
GEV	11,84	1,80	0,20

Fonte: Própria do Autor (2024).

A análise dos dados das Tabelas 18 e 19 pode ser realizada sob três perspectivas distintas. Essas três perspectivas são brevemente discutidas a seguir:

- A primeira alternativa consiste em apontar a distribuição com menor erro na estimação da probabilidade para cada valor de variação de potência. Nesse contexto, a distribuição q-Exponencial é a que melhor modela a distribuição experimental para desvios de 3σ , 5σ e 7σ , no caso de Cocoa. Já em Eugene, a GEV é mais adequada para modelar as variações de 5σ , enquanto os demais valores seguem sendo mais adequadamente modelados pela distribuição q-Exponencial;
- A segunda alternativa de análise consiste em avaliar os dados sob a perspectiva da confiabilidade, atribuindo um desempenho superior aos métodos cuja probabilidade de ocorrência da variação é superior à observada na distribuição experimental (respeitando a sua ordem de grandeza). Isso garante que não haja subdimensionamento nas decisões baseadas nesse valor. Nessa ótica, a melhor alternativa – considerando os dados de Cocoa – para os desvios de 3σ e 5σ é a distribuição GEV, enquanto a distribuição q-Exponencial constitui uma melhor opção para desvios de 7σ , apesar de ainda subestimar a probabilidade real. Já em se tratando dos dados de Eugene, a distribuição GEV constitui a melhor alternativa para desvios de 5σ e 7σ , enquanto a distribuição q-Exponencial é mais adequada para desvios de 3σ ;
- Por fim, as distribuições também podem ser avaliadas quanto à semelhança do seu formato quando comparado à distribuição experimental, o que possibilita uma melhor estimação das probabilidades para um grupo maior de valores de variações de potência. Nesse aspecto, destaca-se a distribuição q-Exponencial como a melhor alternativa.

4.4 PROBLEMAS POTENCIAIS IDENTIFICADOS

Durante o desenvolvimento deste trabalho, foram identificados problemas endêmicos na literatura que têm o potencial de impactar a avaliação dos métodos de suavização. A seguir, algumas dessas limitações são brevemente comentadas com base nos dados obtidos neste trabalho.

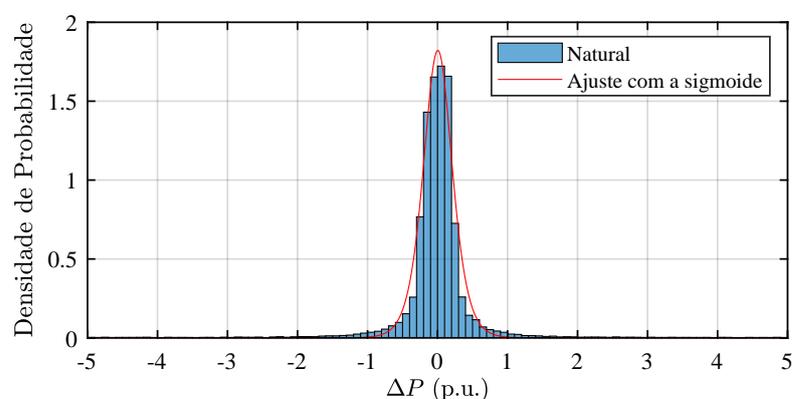
4.4.1 Limitações da Análise do Histograma

Na introdução da Seção 4.3, foi destacada a mudança no padrão de representação utilizado para os histogramas. Conforme mencionado no trecho indicado, o uso do gráfico em formato semi-log permite uma melhor avaliação das caudas da distribuição de probabilidade, contudo, há razões adicionais para essa mudança de representação. Uma das razões pode ser compreendida ao observar a Figura 55. Nessa figura, estão representadas a variabilidade natural em Cocoa (normalizada pela densidade de probabilidade) e o ajuste realizado a partir da função sigmoide. Uma análise preliminar desse resultado poderia levar o leitor a concluir que o método é capaz de fornecer uma boa caracterização. No entanto, ao analisar as Tabelas 18 e 19 e a Figura 51, torna-

se evidente que a função sigmoide possui o pior desempenho entre os métodos de caracterização estudados.

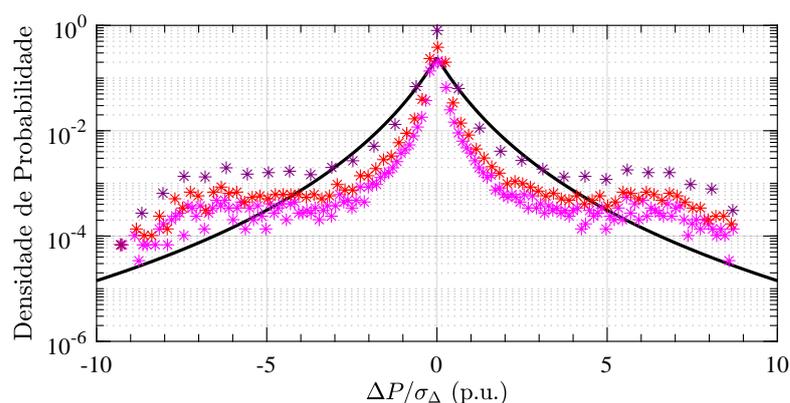
Uma outra limitação da análise do histograma é a sua sensibilidade à variação do número de barras utilizadas na sua construção. O impacto dessa variação em um histograma normalizado pela densidade de probabilidade pode ser visualizada na Figura 56. Conforme apresentado na figura, a variação do número de barras pode fazer com que a estimativa possa parecer melhor ou pior do que na realidade. Para remediar esse efeito, faz-se necessário realizar uma avaliação das probabilidades dos desvios (ou análise dos percentis), como realizada nas Tabelas 18 e 19.

Figura 55 – Histograma das variações de potência em Cocoa normalizado pela densidade de probabilidade. Sobre o histograma, pode-se visualizar a PDF obtida a partir da caracterização com função sigmoide.



Fonte: Própria do Autor (2024).

Figura 56 – Histogramas com diferentes números de barras considerando o mesmo conjunto de dados. Em roxo, vermelho e rosa, histogramas com, respectivamente, 30, 80 e 150 barras.



Fonte: Própria do Autor (2024).

4.4.2 Limitação por Ausência de Informações Futuras

Outra limitação a ser considerada é a decorrente de ausência de informações futuras. Naturalmente, todo ajuste, seja nesse contexto ou em qualquer outro, é um ajuste para um

conjunto de dados que refletem um histórico. Isto é, o observador, especialmente quando não há uma modelagem analítica para a natureza física do fenômeno, dispõe apenas de um conjunto de observações que, por si só, não correspondem a uma distribuição de probabilidade, mas sim a ocorrências limitadas de uma distribuição desconhecida (TALEB, 2022).

Nesse contexto, realizar um ajuste corresponde a tentar modelar o conjunto de dados dos quais se dispõe até o momento, o que não deve ser confundido com a caracterização da distribuição em si, inerente ao fenômeno. Um exemplo da limitação dos ajustes pode ser observado na Figura 57, em que ajustes com a distribuição q-Exponencial foram realizados para diferentes volumes de dados de Cocoa e Eugene. Na figura, a análise da caudas das distribuições revela que as diferenças entre os ajustes podem gerar probabilidades de ocorrências significativamente distintas. Esse problema é especialmente relevante ao se tratar de distribuições que concentram relativamente mais probabilidade em suas caudas, uma vez que os seus parâmetros tendem a convergir de forma mais lenta, exigindo um número elevado (em alguns casos, inviável) de observações para a convergência (TALEB, 2022).

Essas considerações levam à constatação de que a caracterização das variações de potência através de distribuições de probabilidade, como realizada neste capítulo, deve se realizada de forma cuidadosa, levando em conta a quantidade limitada de observações disponíveis. Também é importante buscar incorporar, por meio da estimação, as variações não contempladas no histórico.

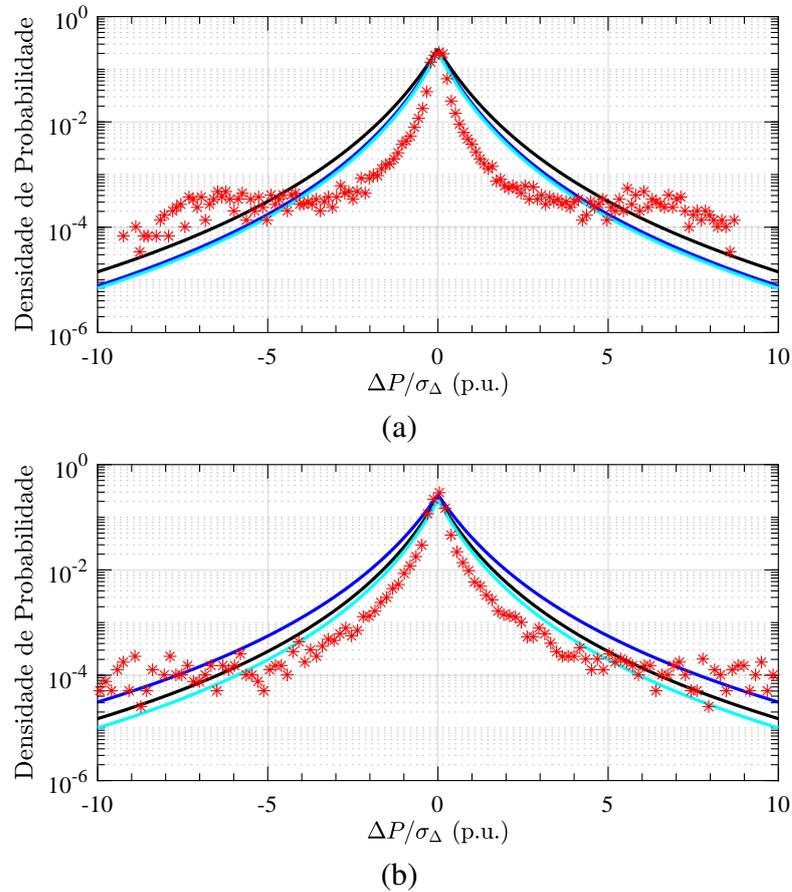
4.5 CONCLUSÕES PARCIAIS

Neste capítulo, buscou-se realizar uma investigação da literatura associada à caracterização das flutuações de potência. Os trabalhos encontrados foram descritos e as suas metodologias foram aplicadas aos dados utilizados neste trabalho, a fim de tentar replicar os resultados originais. Os resultados obtidos foram usados como subsídio para a análise dos métodos, comparando-os no que diz respeito a sua capacidade de adequadamente modelar as probabilidades de ocorrência das variações de potência. Avaliou-se, também, possíveis lacunas nos critérios e análises tipicamente utilizados na literatura correlata, identificando possíveis caminhos para a evolução do campo.

A revisão da literatura identificou uma variedade significativa de métodos, contemplando PDFs como a q-Exponencial, a de Laplace, a Gaussiana e a GEV, além de funções como a sigmoide. Foi possível verificar, nos artigos selecionados, que os métodos foram utilizados de forma indiscriminada para modelar tanto variações de potências oriundas de geração eólica, quanto oriundas de fonte fotovoltaica. Entende-se, portanto, que não há diferenças significativas na modelagem de ambas as formas de variação através de distribuições de probabilidade e essas constituem um único campo de pesquisa.

Os resultados gerados foram comparados com a distribuição experimental tomando como referência a probabilidade de ocorrência de desvios com intensidade preestabelecida. Com base nos dados, pode-se afirmar que, para o conjunto de dados analisado, a distribuição q-Exponencial é a que melhor estima as probabilidades dentro dos intervalos avaliados, além de ser a distribuição

Figura 57 – Resultado do uso da distribuição q-Exponencial para caracterizar flutuações de potência em (a) Cocoa e (b) Eugene. Em ciano, azul e preto com, respectivamente, disponibilidades de 10%, 50% e 100% dos dados.



Fonte: Própria do Autor (2024).

cuja forma mais se aproxima da distribuição experimental. Já sob a ótica de evitar a subestimação da probabilidade de ocorrência de eventos, a distribuição GEV se mostrou superior, ao menos para os intervalos avaliados.

Os dados resultantes das análises realizadas também foram pertinentes na crítica a algumas das práticas comuns ao campo de estudo. Foram criticadas, em especial, as práticas da análise de histogramas de forma acrítica, bem como a análise desprovida de rigor dos resultados da caracterização das variações de potência. Esta última, com o auxílio de ferramentas estatísticas mais complexas, pode vir a resultar no avanço do estado-da-arte do campo no futuro. Por fim, entende-se que também há possibilidade de evolução nos próprios métodos de caracterização. Conforme mencionado, a estimação dos parâmetros de (ANVARI et al., 2016) pode incorporar elementos de MLE, como mencionado em (SHALIZI, 2007). Além disso, outras distribuições, ainda não exploradas, podem ser utilizadas, como as distribuições Logística, t de Student e de Cauchy.

5 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

Neste trabalho foram apresentadas as características gerais de sistemas de suavização, o que inclui: a sua topologia, algoritmos de geração de referência e métricas utilizadas em sua avaliação. Escolheu-se um subgrupo de algoritmos, representativo das principais famílias de métodos utilizados para geração de referência em suavização de potência, para aplicação nos dados experimentais. Com base nos resultados obtidos, algumas métricas comumente utilizadas para avaliar a suavização de potência foram avaliadas. Avaliou-se, também, o fenômeno da variabilidade de potência do ponto de vista da sua distribuição de probabilidade e as consequências disso sobre as ocorrências de variação de potência.

Verifica-se, tanto no subtópico de suavização de potência quanto no de caracterização das variações de potência, uma disparidade entre a literatura voltada puramente aos referidos temas e a literatura especializada da Estatística. Nos trabalhos de suavização observa-se uma predominância dos indicadores não numéricos, já que parte significativa dos artigos se limita a comparar os resultados obtidos visualmente. Para além disso, há evidências que apontam para o uso de métricas estatísticas sem o devido cuidado necessário.

Outro fator potencialmente problemático é a prática de limitar a análise a pequenos intervalos, como o diário, o que pode levar a conclusões equivocadas, especialmente ao se utilizar indicadores fortemente afetados pelo número de amostras. A partir dos resultados obtidos, pode-se afirmar que o σ_{Δ} é uma métrica limitada no que diz respeito ao seu uso para validação de atendimento a requisitos de projeto, além de não ser adequada para comparar resultados entre diferentes localidades. Adicionalmente, pôde-se confirmar a hipótese de que valor de $\Delta P_{\text{máx}}$ é altamente susceptível ao número de amostras.

Com base em um algoritmo Estimador de Monte Carlo adaptado, pôde-se estimar o número de amostras necessários para garantir um $\Delta P_{\text{máx}}$ estatisticamente significativo, o que resultou na criação do indicador $\Delta P_{\text{máx}}^{\text{ES}}$. O valor encontrado para as localidades e a resolução temporal avaliada, 40.000 amostras, equivale a cerca de nove meses de medição. Frente ao elevado número de amostras necessárias para a obtenção de um valor estatisticamente significativo, propôs-se uma métrica chamada Variabilidade Máxima com Horizonte Antecipado ($\Delta P_{\text{máx}}^{\text{HA}}$), o que permite a estimação de $\Delta P_{\text{máx}}$ com um número significativamente inferior de amostras, tornando-a mais factível para fins práticos.

Por fim, ao comparar os métodos de caracterização das variações de potência disponíveis na literatura a partir de 2010, verificou-se que nenhuma das alternativas é capaz de modelar precisamente o comportamento da distribuição de probabilidade experimental, principalmente em se tratando de suas caudas. Dentre, as PDFs analisadas, a q-Exponencial, proposta em (ANVARI et al., 2016), foi a que apresentou melhor desempenho de forma geral, ainda que a GEV tenha desempenhado melhor em alguns contextos. A revisão bibliográfica, em conjunto

com os resultados obtidos, também permitiu verificar que há possibilidades de evolução para o método descrito em (ANVARI et al., 2016), a partir de uma mudança no método de estimação dos parâmetros da distribuição, e no estado-da-arte como um todo, a partir do uso de distribuições de probabilidade ainda não exploradas.

Por fim, os métodos também foram analisados quanto à queda de desempenho quando considerados subconjuntos do total de dados disponíveis, visando avaliar a convergência dos parâmetros da distribuição em função do número de amostras. Os resultados obtidos apontam que a subestimação das probabilidades para eventos extremos pode ser ainda maior do que a verificada. Assim, destaca-se a necessidade de encontrar meios de incorporar a ausência de informações em relação a desvio futuros na modelagem das variações de potência.

5.1 CONTRIBUIÇÕES DO AUTOR

As principais contribuições obtidas a partir deste trabalho são:

- O tratamento dos conjuntos de dados de Cocoa e Eugene visando disponibilização pública futura;
- A análise comparativa das principais métricas utilizadas no contexto da avaliação de algoritmos de suavização de potência;
- A análise dos resultados obtidos a partir da aplicação dos algoritmos SMA e RR com o devido rigor estatístico, tipicamente não encontrado em trabalhos da área;
- A proposta de um estimador de Monte Carlo adaptado para estimação do número de amostras necessário para um valor de variabilidade máxima estatisticamente significativo;
- A proposta de duas novas métricas (Variabilidade Máxima Estatisticamente Significativa e Variabilidade Máxima com Horizonte Antecipado) voltadas à análise da variabilidade de potência no contexto de suavização de potência;
- A análise comparativa dos principais métodos de caracterização das flutuações de potência disponíveis na literatura;
- A identificação de falhas na análise dos resultados obtidos a partir de histogramas no contexto do campo de estudo da caracterização das flutuações de potência.

5.2 TRABALHOS FUTUROS

A partir das análises realizadas neste trabalho:

- Sugere-se a evolução da análise das métricas realizada no Capítulo 2 para incluir também os algoritmos de geração de referência baseados em filtros, contemplando assim todas as famílias de algoritmos;
- Sugere-se a aplicação das novas métricas propostas em um terceiro conjunto de dados, para validação;

- Sugere-se realizar um estudo acerca da caracterização dos desvios de potência, tal qual realizado no Capítulo 4, incorporando dados de desvios com escalas distintas de amostragem e potência instalada;
- Sugere-se aplicar o procedimento descrito em (SHALIZI, 2007) para a estimação dos parâmetros da PDF q-Exponencial descrita em (ANVARI et al., 2016);
- Sugere-se avaliar distribuições de probabilidade ainda não exploradas para a caracterização das variações de potência como as distribuições Logística, t de Student e de Cauchy.

5.3 PUBLICAÇÕES RESULTANTES DO MESTRADO

A seguir, ordenados em ordem decrescente de relação com o mestrado, estão enumerados os trabalhos publicados em anais de congressos durante o mestrado.

1. **DE SOUZA, RICARDO M.**; FERREIRA, F. J. P.; NETO, A. S.; NETO, R. C.; NEVES, F. A. S.; CASTRO, J. F. C.. *"A Comparative Analysis of Power Smoothing Metrics: Unveiling Limitations Through Observational Data."* Proc. of 8th IEEE Southern Power Electronics Conference (SPEC) / 17th Brazilian Power Electronics Conference (COBEP), Florianópolis, 2023.
2. **DE SOUZA, RICARDO M.**; BANDEIRA, C. M.; LIMA, G. H. M.; NETO, R. C.; BRADASCHIA, F.; AZEVEDO, G. M. S.; CASTRO, J. F. C.. *"Avaliação de Alternativas para Adequação da SE Bongí Considerando Sistema de Armazenamento Por Baterias."* Proc. of XXVII Seminário Nacional de Produção e Transmissão de Energia Elétrica (SNPTEE), Brasília, 2023.

É pertinente destacar que o Artigo (1), intitulado *"A Comparative Analysis of Power Smoothing Metrics: Unveiling Limitations Through Observational Data"*, foi selecionado dentre os melhores artigos do evento para integrar, condicionada à adição de conteúdo adicional, uma versão especial da Revista *Open Journal of Power Electronics* (antiga *Brazilian Journal of Power Electronics*) e se encontra atualmente em processo de submissão.

Além disso, o autor colaborou com a execução de um artigo aceito para publicação em anais de congressos:

3. CAVALCANTE, VALDEMAR M.; CALDEIRA, CAROLINA A.; **DE SOUZA, RICARDO M.**; FURTADO, ARTUR M. S.; BRADASCHIA, FABRÍCIO; CAVALCANTI, MARCELO C.. *"I-V Curve Tracer Development for the Performance Analysis of a Photovoltaic Module."* Proc. of 2023 Workshop on Communication Networks and Power Systems (WCNPS), Brasília, 2023.

REFERÊNCIAS

- ABBEY, C.; JOOS, G. Supercapacitor energy storage for wind energy applications. *IEEE Transactions on Industry Applications*, v. 43, n. 3, p. 769–776, 2007. Citado na página 31.
- ABDALLA, A. A. et al. A novel adaptive power smoothing approach for pv power plant with hybrid energy storage system. *IEEE Transactions on Sustainable Energy*, v. 14, n. 3, p. 1457–1473, 2023. Citado na página 32.
- ACKERMANN, T. et al. *Smart modeling of optimal integration of high penetration of PV - SMOOTH PV*. [S.l.], 2013. Citado na página 26.
- ALI, M. H.; WU, B.; DOUGAL, R. A. An overview of smes applications in power and energy systems. *IEEE Transactions on Sustainable Energy*, v. 1, n. 1, p. 38–47, 2010. Citado na página 31.
- AMMAR, M.; JOÓS, G. A short-term energy storage system for voltage quality improvement in distributed wind power. *IEEE Transactions on Energy Conversion*, v. 29, n. 4, p. 997–1007, 2014. Citado na página 31.
- ANVARI, M. et al. Short term fluctuations of wind and solar power systems. *New Journal of Physics*, IOP Publishing, v. 18, n. 6, p. 063027, jun 2016. Citado 9 vezes nas páginas 18, 74, 79, 80, 81, 96, 97, 98 e 99.
- ASENSIO, A. P. et al. Numerical analysis of renewable generation variability for energy storage smoothing applications. In: *2021 22nd IEEE International Conference on Industrial Technology (ICIT)*. [S.l.: s.n.], 2021. v. 1, p. 446–451. Citado 7 vezes nas páginas 21, 22, 40, 43, 44, 45 e 48.
- ATIF, A.; KHALID, M. Savitzky–golay filtering for solar power smoothing and ramp rate reduction based on controlled battery energy storage. *IEEE Access*, v. 8, p. 33806–33817, 2020. Citado 2 vezes nas páginas 32 e 45.
- BAÏLE, R.; MUZY, J.-F. m. c. Spatial intermittency of surface layer wind fluctuations at mesoscale range. *Phys. Rev. Lett.*, American Physical Society, v. 105, p. 254501, Dec 2010. Citado na página 75.
- BARRA, P. et al. A review on wind power smoothing using high-power energy storage systems. *Renewable and Sustainable Energy Reviews*, v. 137, p. 110455, 2021. ISSN 1364-0321. Citado 5 vezes nas páginas 21, 22, 30, 32 e 33.
- BERRUETA, A. et al. Supercapacitors: Electrical characteristics, modeling, applications, and future trends. *IEEE Access*, v. 7, p. 50869–50896, 2019. Citado na página 31.
- BILLINGSLEY, P. *Convergence of Probability Measures*. Wiley, 1968. (Wiley Series in Probability and Mathematical Statistics). ISBN 9780471072423. Disponível em: <<https://books.google.com.br/books?id=O9oQAQAIAAJ>>. Citado na página 75.
- CAVALCANTE JÚNIOR, V. M. *Análise comparativa de modelos globais não-lineares para módulos fotovoltaicos*. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Federal de Pernambuco, Recife, 2023. Citado na página 50.

- CHEN, H. et al. Progress in electrical energy storage system: A critical review. *Progress in Natural Science*, v. 19, n. 3, p. 291–312, 2009. ISSN 1002-0071. Citado na página 29.
- CHONG, L. W. et al. Hybrid energy storage systems and control strategies for stand-alone renewable energy power systems. *Renewable and Sustainable Energy Reviews*, v. 66, p. 174–189, 2016. ISSN 1364-0321. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1364032116303872>>. Citado na página 32.
- CRACIUN, B.-I. et al. Overview of recent grid codes for pv power integration. In: *2012 13th International Conference on Optimization of Electrical and Electronic Equipment (OPTIM)*. [S.l.: s.n.], 2012. p. 959–965. Citado 3 vezes nas páginas 21, 26 e 27.
- DEKKING C. KRAAIKAMP, H. L. L. M. F. *A Modern Introduction to Probability and Statistics: Understanding Why and How*. 1. ed. [S.l.]: Springer, 2005. (Springer Texts in Statistics). ISBN 1852338962; 9781852338961. Citado na página 60.
- DÍAZ-GONZÁLEZ, F. et al. Control of a flywheel energy storage system for power smoothing in wind power plants. *IEEE Transactions on Energy Conversion*, v. 29, n. 1, p. 204–214, 2014. Citado na página 31.
- DIAZ, V. N. S. *Avaliação de Desempenho das Estratégias de Controle Para Suavização de Potência Ativa de Sistemas Fotovoltáicos com Armazenamento de Energia*. Tese (Dissertação de Mestrado) — Universidade Estadual do Oeste do Paraná, Foz do Iguaçu, 2019. Citado 3 vezes nas páginas 21, 26 e 27.
- D'AMICO, G.; PETRONI, F.; VERGINE, S. Ramp rate limitation of wind power: An overview. *Energies*, v. 15, n. 16, 2022. ISSN 1996-1073. Citado 2 vezes nas páginas 41 e 42.
- EPE. *Plano Decenal de Expansão de Energia (PDE) 2026 – 9. Eficiência Energética e Geração Distribuída*. 2017. <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-40/topico-75/Cap9_Texto.pdf>. Acesso em: 22 dez. 2023. Citado na página 20.
- EPE. *Plano Decenal de Expansão de Energia (PDE) 2031 – MMGD Baterias*. 2017. <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-607/topico-591/Caderno_MMGD_Baterias_rev2022.pdf>. Acesso em: 22 dez. 2023. Citado na página 20.
- ESKANDARI, M. et al. Battery energy storage systems (besss) and the economy-dynamics of microgrids: Review, analysis, and classification for standardization of besss applications. *Journal of Energy Storage*, v. 55, p. 105627, 2022. Citado na página 34.
- FISHER, R. A.; RUSSELL, E. J. On the mathematical foundations of theoretical statistics. *Philosophical Transactions of the Royal Society of London. Series A, Containing Papers of a Mathematical or Physical Character*, v. 222, n. 594-604, p. 309–368, 1922. Citado na página 77.
- HAEHNE, H. et al. The footprint of atmospheric turbulence in power grid frequency measurements. *Europhysics Letters*, EDP Sciences, IOP Publishing and Società Italiana di Fisica, v. 121, n. 3, p. 30001, mar 2018. Citado na página 85.
- HEMMATI, R.; SABOORI, H. Emergence of hybrid energy storage systems in renewable energy and transport applications – a review. *Renewable and Sustainable Energy Reviews*, v. 65, p. 11–23, 2016. ISSN 1364-0321. Citado na página 32.

HOFF, T. E.; PEREZ, R. Quantifying pv power output variability. *Solar Energy*, v. 84, n. 10, p. 1782–1793, 2010. ISSN 0038-092X. Citado na página 45.

IKEGAMI, T. et al. Numerical definitions of wind power output fluctuations for power system operations. *Renewable Energy*, v. 115, p. 6–15, 2018. ISSN 0960-1481. Citado 2 vezes nas páginas 43 e 44.

IPCC. *IPCC, 2023: Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, H. Lee and J. Romero (eds.)]. IPCC, Geneva, Switzerland.* [s.n.], 2023. Disponível em: <<http://dx.doi.org/10.59327/IPCC/AR6-9789291691647>>. Citado na página 20.

KEERATIMAHAT, K.; BRUCE, A.; MACGILL, I. The impact of dc/ac ratio on short-term variability of utility-scale pv plants. In: *2019 IEEE Power Energy Society General Meeting (PESGM)*. [S.l.: s.n.], 2019. p. 1–5. Citado 5 vezes nas páginas 18, 79, 84, 85 e 86.

KINI, R. et al. Mitigation of pv variability using adaptive moving average control. *IEEE Transactions on Sustainable Energy*, v. 11, n. 4, p. 2252–2262, 2020. Citado na página 44.

KOOHI-FAYEGH, S.; ROSEN, M. A review of energy storage types, applications and recent developments. *Journal of Energy Storage*, v. 27, p. 101047, 2020. ISSN 2352-152X. Citado 2 vezes nas páginas 31 e 32.

KOOHI-KAMALI, S.; RAHIM, N.; MOKHLIS, H. Smart power management algorithm in microgrid consisting of photovoltaic, diesel, and battery storage plants considering variations in sunlight, temperature, and load. *Energy Conversion and Management*, v. 84, p. 562–582, 2014. ISSN 0196-8904. Citado na página 45.

LAMSAL, D. et al. Output power smoothing control approaches for wind and photovoltaic generation systems: A review. *Renewable and Sustainable Energy Reviews*, v. 113, p. 109245, 2019. ISSN 1364-0321. Citado 2 vezes nas páginas 28 e 30.

LANDERA, Y. G. et al. A review of grid connection requirements for photovoltaic power plants. *Energies*, v. 16, n. 5, 2023. Citado na página 26.

LEE, D.; BALDICK, R. Limiting ramp rate of wind power output using a battery based on the variance gamma process. *Renewable Energy and Power Quality Journal*, p. 1591–1596, 04 2012. Citado 4 vezes nas páginas 18, 79, 84 e 85.

LI, X.; HUI, D.; LAI, X. Battery energy storage station (bess)-based smoothing control of photovoltaic (pv) and wind power generation fluctuations. *IEEE Transactions on Sustainable Energy*, v. 4, n. 2, p. 464–473, 2013. Citado na página 32.

LI, X.; PALAZZOLO, A. A review of flywheel energy storage systems: state of the art and opportunities. *Journal of Energy Storage*, v. 46, p. 103576, 2022. ISSN 2352-152X. Citado na página 31.

LOUIE, H. Evaluation of probabilistic models of wind plant power output characteristics. In: *2010 IEEE 11th International Conference on Probabilistic Methods Applied to Power Systems*. [S.l.: s.n.], 2010. p. 442–447. Citado 5 vezes nas páginas 18, 79, 83, 84 e 92.

MARION, B. et al. Data for validating models for pv module performance. 8 2021. Citado na página 49.

- MARION, B.; DECEGLIE, M. G.; SILVERMAN, T. J. Analysis of measured photovoltaic module performance for florida, oregon, and colorado locations. *Solar Energy*, v. 110, p. 736–744, 2014. ISSN 0038-092X. Citado 3 vezes nas páginas 49, 50 e 51.
- MAZUMDAR, B. M.; SAQUIB, M.; DAS, A. K. An empirical model for ramp analysis of utility-scale solar pv power. *Solar Energy*, v. 107, p. 44–49, 2014. ISSN 0038-092X. Citado 6 vezes nas páginas 18, 79, 81, 82, 83 e 88.
- METROPOLIS, N.; ULAM, S. The monte carlo method. *Journal of the American Statistical Association*, [American Statistical Association, Taylor Francis, Ltd.], v. 44, n. 247, p. 335–341, 1949. ISSN 1949. Citado na página 60.
- MILLS, A. D.; WISER, R. H. Implications of geographic diversity for short-term variability and predictability of solar power. In: *2011 IEEE Power and Energy Society General Meeting*. [S.l.: s.n.], 2011. p. 1–9. Citado na página 45.
- MITCHELL, M. et al. Power variability analysis of megawatt-scale solar photovoltaic installations. In: *2016 IEEE Electrical Power and Energy Conference (EPEC)*. [S.l.: s.n.], 2016. p. 1–4. Citado na página 44.
- MOAVENI, H. et al. Quantifying solar power variability for a large central pv plant and small distributed pv plant. In: *2013 IEEE 39th Photovoltaic Specialists Conference (PVSC)*. [S.l.: s.n.], 2013. p. 0969–0972. Citado na página 45.
- MUYEEN, S.; TAMURA, J.; MURATA, T. Integration of an energy storage system into wind farm. In: _____. *Stability Augmentation of a Grid-connected Wind Farm*. London: Springer London, 2009. p. 137–162. ISBN 978-1-84800-316-3. Citado na página 37.
- ONS. *EVOLUÇÃO DA CAPACIDADE INSTALADA DE GERAÇÃO EÓLICA E FOTOVOLTAICA*. 2024. <https://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/evolucao-capacidade_instalada.aspx>. Acesso em: 15 jan. 2024. Citado na página 21.
- PAPOULIS, A.; PILLAI, S. *Probability, Random Variables, and Stochastic Processes*. [S.l.]: McGraw-Hill, 2002. (McGraw-Hill series in electrical and computer engineering). ISBN 9780071226615. Citado na página 84.
- PINHEIRO, A. L. et al. A review and comparison of smoothing methods for solar photovoltaic power fluctuation using battery energy storage systems. In: *2021 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America)*. [S.l.: s.n.], 2021. p. 1–5. Citado na página 44.
- POLAT, H. et al. A review of dc fast chargers with bess for electric vehicles: Topology, battery, reliability oriented control and cooling perspectives. *Batteries*, v. 9, n. 2, 2023. Citado na página 34.
- PURI, A. Optimally smoothing output of pv farms. In: *2014 IEEE PES General Meeting | Conference Exposition*. [S.l.: s.n.], 2014. p. 1–5. Citado 2 vezes nas páginas 38 e 45.
- RAN, L.; BUMBY, J.; TAVNER, P. Use of turbine inertia for power smoothing of wind turbines with a dfig. In: *2004 11th International Conference on Harmonics and Quality of Power (IEEE Cat. No.04EX951)*. [S.l.: s.n.], 2004. p. 106–111. Citado na página 28.
- RANGARAJAN, S. S. et al. A survey on global pv interconnection standards. In: *2017 IEEE Power and Energy Conference at Illinois (PECI)*. [S.l.: s.n.], 2017. p. 1–8. Citado na página 26.

- RAOOFAT, M. et al. Wind power smoothing using demand response of electric vehicles. *International Journal of Electrical Power Energy Systems*, v. 99, p. 164–174, 2018. ISSN 0142-0615. Citado 4 vezes nas páginas 18, 79, 84 e 85.
- RAYGANI, S. V.; SHARMA, R.; SAHA, T. K. Variability and performance analysis of the pv plant at the university of queensland. In: *2013 Australasian Universities Power Engineering Conference (AUPEC)*. [S.l.: s.n.], 2013. p. 1–6. Citado 3 vezes nas páginas 46, 79 e 83.
- SAID, S. M. et al. Smes-based fuzzy logic approach for enhancing the reliability of microgrids equipped with pv generators. *IEEE Access*, v. 7, p. 92059–92069, 2019. Citado na página 31.
- SCHÄFER, B. et al. Non-gaussian power grid frequency fluctuations characterized by lévy-stable laws and superstatistics. *Nature Energy*, v. 3, n. 2, p. 119–126, Feb 2018. ISSN 2058-7546. Citado na página 85.
- SENJYU, T. et al. Output power leveling of wind turbine generator for all operating regions by pitch angle control. *IEEE Transactions on Energy Conversion*, v. 21, n. 2, p. 467–475, 2006. Citado na página 28.
- SHALIZI, C. R. *Maximum Likelihood Estimation for q-Exponential (Tsallis) Distributions*. 2007. Citado 3 vezes nas páginas 81, 96 e 99.
- SILVA, A. M. Leite da; CASTRO, J. F. C.; GONZÁLEZ-FERNÁNDEZ, R. A. Spinning reserve assessment under transmission constraints based on cross-entropy method. *IEEE Transactions on Power Systems*, v. 31, n. 2, p. 1624–1632, 2016. Citado 2 vezes nas páginas 60 e 61.
- SILVA, P. L. Tabosa da et al. Power smoothing strategy for wind generation based on fuzzy control strategy with battery energy storage system. *Energies*, v. 16, n. 16, 2023. ISSN 1996-1073. Citado na página 45.
- SUCH, M. C.; MASADA, G. Y. Bess control on an microgrid with significant wind generation. In: *2017 IEEE Power Energy Society General Meeting*. [S.l.: s.n.], 2017. p. 1–5. Citado na página 34.
- SUKUMAR, S. et al. Ramp-rate control smoothing methods to control output power fluctuations from solar photovoltaic (pv) sources—a review. *Journal of Energy Storage*, v. 20, p. 218–229, 2018. ISSN 2352-152X. Citado 3 vezes nas páginas 22, 36 e 37.
- SUN, Y. et al. Power compensation of network losses in a microgrid with bess by distributed consensus algorithm. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, v. 51, n. 4, p. 2091–2100, 2021. Citado na página 34.
- TALEB, N. N. *Statistical Consequences of Fat Tails: Real World Preasymptotics, Epistemology, and Applications*. 2022. Citado 2 vezes nas páginas 75 e 95.
- UEHARA, A. et al. A coordinated control method to smooth wind power fluctuations of a pmsg-based wecs. *IEEE Transactions on Energy Conversion*, v. 26, n. 2, p. 550–558, 2011. Citado na página 28.
- VULUSALA, G. V. S.; MADICHETTY, S. *Application of superconducting magnetic energy storage in electrical power and energy systems: a review*. [S.l.]: Hindawi Limited, 2017. 358–368 p. Citado na página 31.

WAN, C. et al. Probabilistic forecasting based sizing and control of hybrid energy storage for wind power smoothing. *IEEE Transactions on Sustainable Energy*, v. 12, n. 4, p. 1841–1852, 2021. Citado na página 32.

WOOD, R.; FIELD, P. R. The distribution of cloud horizontal sizes. *Journal of Climate*, American Meteorological Society, Boston MA, USA, v. 24, n. 18, p. 4800 – 4816, 2011. Citado na página 75.

XUE, X.; CHENG, K.; SUTANTO, D. Power system applications of superconducting magnetic energy storage systems. In: *Fourtieth IAS Annual Meeting. Conference Record of the 2005 Industry Applications Conference, 2005*. [S.l.: s.n.], 2005. v. 2, p. 1524–1529. Citado na página 30.

ZHENG, Y. et al. An active power smoothing control for photovoltaic-flywheel system using fuzzy control. In: *2012 IEEE Fifth International Conference on Advanced Computational Intelligence (ICACI)*. [S.l.: s.n.], 2012. p. 1113–1118. Citado na página 31.

ZUBI, G. et al. The lithium-ion battery: State of the art and future perspectives. *Renewable and Sustainable Energy Reviews*, v. 89, p. 292–308, 2018. ISSN 1364-0321. Citado na página 32.