



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENERGIA NUCLEAR
PROGRAMA DE PÓS-GRADUAÇÃO EM TECNOLOGIAS ENERGÉTICAS E NUCLEARES

IGOR CAVALCANTE TORRES

**ESTRATÉGIA DE MITIGAÇÃO PARA SOBRETENSÃO DE CURTO PRAZO
DIANTE DA VARIABILIDADE DA GERAÇÃO FOTOVOLTAICA EM REDES DE
DISTRIBUIÇÃO SECUNDÁRIA**

Recife

2021

IGOR CAVALCANTE TORRES

**ESTRATÉGIA DE MITIGAÇÃO PARA SOBRETENSÃO DE CURTO PRAZO
DIANTE DA VARIABILIDADE DA GERAÇÃO FOTOVOLTAICA EM REDES DE
DISTRIBUIÇÃO SECUNDÁRIA**

Tese apresentada ao Programa de Pós-Graduação em Tecnologias Energéticas e Nucleares da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de Doutor em Tecnologias Energéticas e Nucleares.

Área de Concentração: Fontes Renováveis de Energia.

Orientador: Prof. Dr. Chigueru Tiba

Recife

2021

T693e Torres, Igor Cavalcante.
Estratégia de mitigação para sobretensão de curto prazo diante da variabilidade da geração fotovoltaica em redes de distribuição secundária / Igor Cavalcante Torres - 2021.
136 folhas, il., gráfs., tabs.

Orientador: Prof. Dr. Chigueru Tiba.

Tese (Doutorado) – Universidade Federal de Pernambuco. CTG.
Programa de Pós-Graduação em Tecnologias Energéticas e Nucleares, 2021.

Inclui Referências e Apêndice.

1. Energia Nuclear. 2. Previsão da irradiação solar. 3. Armazenamento. 4. Sistemas fotovoltaicos. 5. Fluxo de potência. 6. Modelagem de redes de distribuição. I. Tiba, Chigueru (Orientador). II. Título.

UFPE

612.01448 CDD (22. ed.)

BCTG/2021-204

IGOR CAVALCANTE TORRES

**ESTRATÉGIA DE MITIGAÇÃO PARA SOBRETENSÃO DE CURTO PRAZO
DIANTE DA VARIABILIDADE DA GERAÇÃO FOTOVOLTAICA EM REDES DE
DISTRIBUIÇÃO SECUNDÁRIA**

Tese apresentada ao Programa de Pós-Graduação em Tecnologias Energéticas e Nucleares da Universidade Federal de Pernambuco, Centro Acadêmico CTG, como requisito para obtenção do título de Doutor em Tecnologias Energéticas e Nucleares. Área de Concentração: Fontes Renováveis de Energia (FRE).

Aprovado em: 10/09/2021.

BANCA EXAMINADORA

Prof^o. Dr^o. Chiguera Tiba (Orientador)
Universidade Federal de Pernambuco - UFPE

Prof^o. Dr. Carlos Alberto Brayner de Oliveira Lira (Examinador Interno)
Universidade Federal de Pernambuco - UFPE

Prof^o. Dr. José Bione de Melo Filho (Examinador Externo)
Companhia Hidro Elétrica do São Francisco

Prof^o. Dr. Ronaldo Ribeiro Barbosa de Aquino (Examinador Externo)
Universidade Federal de Pernambuco - UFPE

Prof^o. Dr. André Luiz Lins de Aquino (Examinador Externo)
Universidade Federal de Alagoas - UFAL

AGRADECIMENTOS

Gostaria de agradecer a Deus, pelo dom da vida e por todas as oportunidades concedidas ao longo de toda minha caminhada pessoal e profissional.

Ao meu pai e minha mãe (*in memoriam*), que nunca mediram esforços, priorizando o caminho da educação.

Ao meu orientador professor Chigueru Tiba, pela confiança e por sempre acreditar no meu potencial.

Aos amigos e colegas de trabalho Leonardo Faustino, Ricardo Araújo, Amanda Peiter, Jhonathan Gomes, Juciela e Ayrton Martim, pelas conversas e incentivos diários, sempre mantendo a motivação da pesquisa.

Ao professor André Aquino e Daniel Melo, pela valiosa parceria, disponibilizando o Laboratório de Computação Científica e Análise Numérica (LaCCAN) da Universidade Federal de Alagoas (UFAL), como apoio à minha pesquisa, além das contribuições fundamentais na produção científica.

Ao aluno Cledson Calaça e o engenheiro Raphael Guedes, pelas incontáveis reuniões durante os projetos de pesquisas, e manter a disposição no desenvolvimento do nosso grupo de pesquisa.

A UFAL, ao Campus de Engenharia e Ciências Agrárias (UFAL), sob comando do professor Gaus Silvestre, bem como a coordenação do curso de Engenharia de Energias, na gestão do professor Márcio Cavalcante, por todo o apoio fornecido para que eu conduzisse o doutoramento com a máxima exclusividade.

A minha companheira Janinne Melo, por me apoiar em todas as circunstâncias da minha vida, principalmente nos momentos mais conturbados.

RESUMO

Um dos grandes desafios é a maximização da hospedagem de geradores fotovoltaicos no sistema elétrico de distribuição sem comprometer a qualidade de energia disponível aos consumidores. Este trabalho apresentou um método para mitigação das sobretensões que surgem diante da alta injeção de potência elétrica através do fluxo reverso e também pela alta variabilidade da geração fotovoltaica. O método desenvolvido foi baseado em uma rede neural *Long Short Term Memory* (LSTM), modelada através de uma base de dados de irradiação solar e temperatura de operação dos módulos fotovoltaicos, ambas coletadas durante 365 dias efetivos de medição, em intervalo de tempo de 1 minuto. A operação da rede neural tomou como base uma janela deslizante de 20 dados (minutos) retroativos, estimando 1 minuto à frente. Os dados fornecidos pela rede LSTM foram utilizados como parâmetros de entrada juntamente com o padrão da curva de carga, a partir de um valor de permissão de injeção de potência reversa realizou-se o acionamento e integração de um conjunto de baterias elétricas. O programa *Distribution System Simulator (OpenDSS)*, foi utilizado como ferramenta de simulação para execução do fluxo de potência diante das diversas condições da irradiação solar, permitindo a investigação pontual do perfil da tensão elétrica no ponto de fornecimento da unidade consumidora. Sendo a etapa de previsão, o estágio mais crítico para o pleno funcionamento da ferramenta de mitigação, em dias de alta variabilidade da geração fotovoltaica a rede neural LSTM atingiu um RMSE de 121,36 W/m². Em dias menos perturbados, o RMSE foi de 96,39 W/m². Para esta mesma métrica, a performance da rede neural obteve o mesmo ritmo de desempenho para a estimativa da temperatura de operação do módulo fotovoltaico. O dia de alta variabilidade, apresentou-se como a maior fonte de ocorrências de sobretensões durante um determinado período de tempo de operação do gerador fotovoltaico, assim, houve maior necessidade do uso do armazenamento para esta condição, onde 22,56% da energia útil disponibilizada pelo gerador fotovoltaico precisou ser armazenada para manter a estabilidade dos níveis de tensão.

Palavras-chave: previsão da irradiação solar; armazenamento; sistemas fotovoltaicos; fluxo de potência; modelagem de redes de distribuição.

ABSTRACT

One of the greatest challenges today is to maximize the hosting of photovoltaic generators distributed in the electrical system without compromising the quality of energy available to a consumer. This work presented a method for mitigating the overvoltages that arise in the face of high electrical power injection through reverse flow and also due to the high variability of photovoltaic generation. The developed method was based on a Long Short Term Memory (LSTM) neural network, modeled through a database of solar irradiation and operating temperature of the photovoltaic modules, both collected during 365 days of measurement, at a time interval of 1 minute. The operation of the neural network was based on a sliding window of 20 data (minutes) retroactively, estimating 1 minute ahead. The data provided by the LSTM network were used as input parameters along with the load curve pattern, from a reverse power injection permission value, the activation and integration of a set of electric batteries was performed. The Distribution System Simulator (OpenDSS) software was used as a simulation tool to execute the power flow under the different conditions of solar irradiation, allowing the punctual investigation of the electrical voltage profile at the point of supply of the consumer unit. As the forecasting stage, is the most critical stage for the full functioning of the mitigation tool, on days of high variability of photovoltaic generation the LSTM neural network reached an RMSE of 121.36 W/m². On less disturbed days, the RMSE was 96.39 W/m². When considering the same performance metric for the analysis of solar irradiation, the same performance was observed for the operating temperature of the photovoltaic modules. The high variability day was the biggest source of overvoltage occurrences during a certain period of time of operation of the photovoltaic generator, thus, there was a greater need to use storage for this condition, where 22.56% of the useful energy made available by the photovoltaic generator had to be stored to maintain the stability of the voltage levels.

Keywords: prediction of solar radiation; storage; photovoltaic systems; power flow; modeling of distribution networks.

LISTA DE FIGURAS

Figura 1 – Potencial fotovoltaico instalado no Brasil considerando a maior e menor capacidade instalada, assim como todo o potencial instalado na região nordeste.	19
Figura 2 – Sistema de distribuição ativo.	21
Figura 3 – Perfis típicos da irradiação solar na superfície terrestre.	22
Figura 4 – Amostras de vários dias exemplificando a variabilidade da potência na saída de um inversor fotovoltaico.	23
Figura 5 – Diagrama elétrico simplificado da interligação de um prossumidor à rede elétrica.	29
Figura 6 – Representação do fluxo de potência bidirecional.	31
Figura 7 – Representação da intermitência solar e da flutuação de potência.	33
Figura 8 – Formas de armazenamento de energia.	36
Figura 9 – Suavização da potência injetada na rede considerando o armazenamento.	38
Figura 10 – Representação da potência simulada injetada na rede mediante a estratégia de suavização.	39
Figura 11 – Comparação entre a estrutura de tarifação branca e convencional.	40
Figura 12 – Cenários de possibilidades de aplicação da GLD.	43
Figura 13 – Representação da intermitência solar e da flutuação de potência.	44
Figura 14 – Esquemático de um neurônio artificial.	45
Figura 15 – Aplicações da previsão da irradiação solar.	46
Figura 16 – Fluxograma operacional de uma rede neural recorrente - RNN.	47
Figura 17 – Estrutura de uma rede neural LSTM.	48
Figura 18 – Rede de distribuição real.	52
Figura 19 – Composição dos elementos do sistema fotovoltaico experimental.	53
Figura 20 – Sistema fotovoltaico experimental e estação meteorológica.	53
Figura 21 – Disposição real dos transdutores de sinais utilizados no monitoramento das variáveis elétricas.	54
Figura 22 – Fluxograma para análise da viabilidade técnica em redes de distribuição considerando a inserção de SFVCR's.	56
Figura 23 – Modelo elétrico de um gerador fotovoltaico conectado à rede.	59
Figura 24 – Modelo de uma linha trifásica a quatro fios apoiada em barras terminais.	60

Figura 25 – Fluxograma de resolução do fluxo de potência.	62
Figura 26 – Perfil de irradiância solar, curva de demanda e temperatura do módulo FV utilizados para simulação.	63
Figura 27 – Etapas para classificação das rampas de potência.	66
Figura 28 – Frequência de ocorrências da sobretensão em função da potência injetada.	68
Figura 29 – Método proposto para regulação da tensão de curto prazo.	69
Figura 30 – Tratamento dos dados.	71
Figura 31 – Arquitetura do modelo da rede neural LSTM utilizada.	72
Figura 32 – Representação de uma bateria.	73
Figura 33 – Bateria elétrica no sistema de potência.	74
Figura 34 – Diagrama elétrico dos elementos integrantes da rede elétrica diante do ponto de acoplamento comum.	77
Figura 35 – Representação dos subcasos simulados pelo caso 1 (5 kWp)	78
Figura 36 – Resultados do caso 1 - Subcaso 1.	79
Figura 37 – Resultados do caso 1 - Subcaso 2.	80
Figura 38 – Resultados caso 1 - Subcaso 3.	81
Figura 39 – Resultados caso 2 - Subcaso 1 e 2.	82
Figura 40 – Resultados caso 2 - Subcaso 3.	83
Figura 41 – Representação das variações de tensão em torno dos valores de referência.	83
Figura 42 – Resultado comparativo do subcaso 3 antes e depois da redefinição do SFVCR.	84
Figura 43 – Análise das perdas técnicas nos ramais de conexão das UC e no trecho fim de rede influenciadas pelo gerador fotovoltaico.	86
Figura 44 – Representação das perdas relativas para cada unidade consumidora (UC), acompanhadas do grau de intensidade de redução em cada ramal condutor.	87
Figura 45 – Comparação entre os valores de tensão obtidos experimentalmente e computacionalmente.	88
Figura 46 – Ilustração do efeito das rampas de potência na tensão do ponto de acoplamento.	89
Figura 47 – Frequência de ocorrência das taxas de rampas de potência que excederam a $r_{MÁX}$	90
Figura 48 – Quantificação das tensões acima do limite crítico em função das flutuações de potência acima de $r_{MÁX}$	91

Figura 49 – Frequência relativa da flutuação de potência máxima diária avaliada por um ano.	92
Figura 50 – Comparação entre a radiação predita e experimental.	93
Figura 51 – Amostra representativa entre os valores de predição e experimental da irradiação solar.	95
Figura 52 – Resultados da temperatura de operação do módulo fotovoltaico, esboçando o perfil previsto e experimental.	96
Figura 53 – Resultados das simulações dos perfis de potência fotovoltaica comparado com os dados mensurados.	98
Figura 54 – Perfil da tensão de acoplamento para cada tipo característico da irradiação solar.	100
Figura 55 – Cálculo do fluxo de potência reverso observado pelo rompimento do limite de permissão de potência evidenciando o perfil de demanda.	101
Figura 56 – Comparação entre a tensão nominal e a tensão regulada após o armazenamento de energia.	104
Figura 57 – Monitoramento do estado da carga do sistema de armazenamento por grupo de baterias, observando as condições de contorno da irradiação solar. . . .	106
Figura 58 – Quantitativo de disparos efetuados por cada nível de armazenamento. . . .	108
Figura 59 – Perfil comparativo entra a tensão real e calculada obtida pelo método proposto para os dias de alta variabilidade e céu claro	109
Figura 60 – Perfil comparativo entra a tensão real e calculada obtida pelo método proposto para o dia de baixa variabilidade.	110

LISTA DE TABELAS

Tabela 1 – Classificação dos níveis de tensão.	28
Tabela 2 – Características das baterias eletroquímicas.	36
Tabela 3 – Especificação dos sensores.	54
Tabela 4 – Dados elétricos do alimentador real	58
Tabela 5 – Especificação dos condutores empregados no alimentador	58
Tabela 6 – Subcasos de simulação.	64
Tabela 7 – Tabela resumo do perfil de acionamento do sistema de armazenamento. . .	76
Tabela 8 – Subcasos de simulação.	84
Tabela 9 – Comparativo da variabilidade da tensão após a mitigação.	85
Tabela 10 – Performance da previsão da irradiação solar.	94
Tabela 11 – Resultados de desempenho da rede neural LSTM em função dos parâmetros de entrada e saída.	95
Tabela 12 – Informações das ocorrências de sobretensão e potência acima do limite de permissão de potência definido.	102
Tabela 13 – Resumo das ocorrências simultâneas.	103
Tabela 14 – Custo energético efetivo do SAE por nível de potência.	105
Tabela 15 – Tamanho do banco de baterias em Wh para cada nível de potência (ΔP) restrita às condições de carga.	107

LISTA DE ABREVIATURAS E SIGLAS

ABSOLAR	Associação Brasileira de Energia Solar
AF	<i>activation function</i>
ANEEL	Agência Nacional de Energia Elétrica
ARIMA	<i>Autoregressive Integrated Moving Average</i>
ARMA	<i>Autoregressive Moving Average</i>
BESS	<i>Batery Energy Storage System</i>
BRT	<i>Bagged Regression Trees</i>
BT	baixa tensão
CAEE	custo anual da energia elétrica
CLNR	<i>customer led network revolution</i>
CNN	<i>Convolutional Neural Network</i>
DoD	<i>Depth of Discharge</i>
EMA	<i>Exponential Moving Average</i>
EPIA	<i>European Photovoltaic Industry Association</i>
GBR	<i>Gradient Boosting Regression</i>
GC	geração centralizada
GD	geração distribuída
GDFV	geração distribuída fotovoltaica
GLD	gerenciamento pelo lado da demanda
GW	GigaWatt
K-NN	<i>K-Nearest Neighbors</i>
LPF	<i>Low-Pass Filter - First Ordem</i>

LPF-2	<i>Low-Pass Filter - Second Ordem</i>
LSTM	<i>Long Short Term Memory</i>
MA	<i>Moving Average</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MIT	<i>Massachusetts Institute of Technology</i>
MLP	<i>Multilayer Perceptron</i>
MLR	<i>Multiple Linear Regression</i>
MW	MegaWatt
NN	<i>Neural Network</i>
NRMSE	<i>Normalized Root Mean Squared Erro</i>
OEL	<i>overexcitation limiter</i>
OLTC	<i>on load tap changer</i>
OpenDSS	<i>Open Distribution System Simulator</i>
P.U.	Por Unidade
PAC	ponto de acoplamento comum
PREPA	<i>Puerto Rico Electric Authority</i>
PRODIST	Procedimentos de Distribuição de Energia Elétrica
RFR	<i>Random Forest Regresssion</i>
RMSE	<i>Root Mean Square Error</i>
RNA	Rede Neural Artificial
RNN	<i>Recurrent Neural Network</i>
RT	reguladores de tensão

SAE	sistema de armazenamento elétrico
SDEE	sistema de distribuição de energia elétrica
SEP	sistema elétrico de potência
SFVCR	sistema fotovoltaico conectados à rede
SoC	<i>State of Charge</i>
SVM	<i>Support Vector Machine</i>
SVR	<i>Support Vector Machine</i>
UC	unidade consumidora
VRSA	<i>Voltage Ranking Search Algorithm</i>

LISTA DE SÍMBOLOS

ΔP	Flutuação de potência
Δt	Intervalo de tempo
V_{G_1}	Tensão na barra 1
V_{G_2}	Tensão na barra 2
Z_G	Impedância da linha
r_G	Resistência da linha
x_G	Reatância da linha
Z_E	Impedância do ramal da unidade consumidora
r_E	Resistência do ramal
x_E	Reatância do ramal
V_C	Tensão na barra de carga
V_L^*	Tensão complexa
P_L	Potência ativa da carga
V_{FV}	Tensão na barra do gerador fotovoltaico
P_{FV}	Potência ativa gerada pelo gerador fotovoltaico
$P_{FV(t)}$	Potência do gerador fotovoltaico no tempo atual
$P_{FV(t-\Delta t)}$	Potência do gerador fotovoltaico no tempo anterior
V_{r_E}	Queda de tensão na resistência
I_L	Corrente da carga
I_{FV}	Corrente do gerador fotovoltaico
$S_{FV,inj}$	Potência injetada pelo gerador fotovoltaico
ΔV	Queda de tensão entre duas barras

P_{inj}	Potência ativa injetada na rede
Q_{inj}	Potência reativa injetada na rede
I_{inj}	Corrente injetada na rede
X/R	Relação reatância-resistência
h_i	Nível de atividade da rede neural
w	Multiplicador de peso da rede neural
θ	Fator de ajuste da rede neural
$O_{(t)}$	Saída da rede neural recorrente
S	Multiplicador de peso da rede neural recorrente
R^2	Coefficiente de determinação
\bar{x}_i	Conjunto das médias de dados reais
\hat{y}_i	Dados previstos pela rede neural
y_i	Dados reais coletados pelo <i>datalogger</i>

SUMÁRIO

1	INTRODUÇÃO	18
1.1	CONTEXTUALIZAÇÃO	18
1.2	CARACTERIZAÇÃO DO PROBLEMA	22
1.3	CONTRIBUIÇÕES	25
1.4	OBJETIVOS E METAS	25
2	REVISÃO DA LITERATURA	27
2.1	PROBLEMAS ASSOCIADOS À GERAÇÃO FOTOVOLTAICA	27
2.1.1	Restrições operacionais aos limites de tensão	28
2.1.2	Elevação da tensão em prosumidores residenciais	29
2.1.3	Flutuação de potência	32
2.2	ESTRATÉGIAS MITIGATÓRIAS PARA INTERMITÊNCIA FOTOVOLTAICA	34
2.2.1	Reguladores de tensão	34
2.2.2	Tecnologias de armazenamento de energia	35
2.2.2.1	<i>Controle da potência ativa por baterias</i>	37
2.2.2.2	<i>Armazenamento como aliado à tarifa branca</i>	39
2.2.2.3	<i>Armazenamento para controle de tensão</i>	40
2.2.3	Resposta à demanda	42
2.2.4	Previsão do recurso solar	44
3	MATERIAIS E MÉTODOS	51
3.1	MATERIAIS	51
3.1.1	Rede de distribuição real	51
3.1.2	Sistema fotovoltaico experimental	52
3.1.3	Instrumentação e base de dados	53
3.1.4	Ambiente de simulação - OpenDSS	55
3.2	INTERAÇÃO DE UM SFVCR COM A TENSÃO DE FORNECIMENTO.	55
3.2.1	Método de estudo para conexão de um SFVCR	55
3.2.2	Modelagem da rede de distribuição	57
3.2.3	Modelagem do sistema fotovoltaico	58
3.2.4	Fluxo de potência	59
3.2.5	Cenários de simulação	62

3.3	ESTRATÉGIA PARA MITIGAÇÃO DA SOBRETENSÃO	64
3.3.1	Caracterização das rampas de potência	64
3.3.2	Relação entre tensão e a potência injetada	67
3.3.3	Método proposto	68
3.3.4	Previsão da irradiação solar e temperatura do módulo	70
3.3.4.1	<i>Rede neural recorrente</i>	<i>70</i>
3.3.5	Armazenamento de energia elétrica	73
3.3.5.1	<i>Planejamento operacional do dispositivo de armazenamento</i>	<i>74</i>
4	RESULTADOS E DISCUSSÕES	78
4.1	IMPACTOS DO SFVCR NA TENSÃO DE FORNECIMENTO	78
4.1.1	Resultados do caso 1	78
4.1.2	Resultados do caso 2	81
4.1.3	Estudo comparativo das análises teórica e experimental	87
4.2	MITIGAÇÃO DA TENSÃO DE CURTO PRAZO	88
4.2.1	Análise das rampas de potência	88
4.2.2	Previsão da irradiação solar e temperatura do módulo FV	92
4.2.3	Análise da potência fotovoltaica	97
4.2.4	Verificação da tensão e potência injetada	99
4.2.5	Análise do perfil de tensão	103
4.2.6	Desempenho da estratégia de mitigação	108
5	CONCLUSÕES	112
6	PERSPECTIVAS FUTURAS	116
	REFERÊNCIAS	117
	APÊNDICE A – SCRIPT REDE NEURAL	125

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

O grande caminho em busca do desenvolvimento tecnológico e econômico de um país implica indubitavelmente em maior demanda por eletricidade. O cenário mundial apresenta constantemente fatos que comprovam o esgotamento dos recursos energéticos naturais. Tratando-se de matrizes energéticas que utilizam fontes convencionais e não renováveis, agrava-se cada vez mais, com a emissão dos gases poluentes que provocam o efeito estufa. Nos últimos 4 anos, a inserção de geradores fotovoltaicos vem crescendo exponencialmente, assim, a capacidade mundial instalada de geração elétrica fotovoltaica passou de cerca de 6 GigaWatt (GW) em 2006 para próximo dos 760 GW registrados ao fim do ano de 2020 (REN21, 2021). Esses números comprovam a verdadeira quebra de paradigmas nas práticas de geração de eletricidade, envolvendo mais esforços e investimentos. Refletindo essas atuais mudanças na matriz elétrica brasileira, pode-se afirmar que em capacidade instalada para produção de eletricidade, de acordo com a Agência Nacional de Energia Elétrica (ANEEL), o Brasil teve uma potência fiscalizada de 170 GW, onde as energias renováveis abarcaram 75% de toda a capacidade, restringindo-se às grandes centrais fotovoltaica e eólica, cada uma agregou 551 MegaWatt (MW) e 971 MW, respectivamente, ao fim do ano de 2019 (ANEEL, 2020).

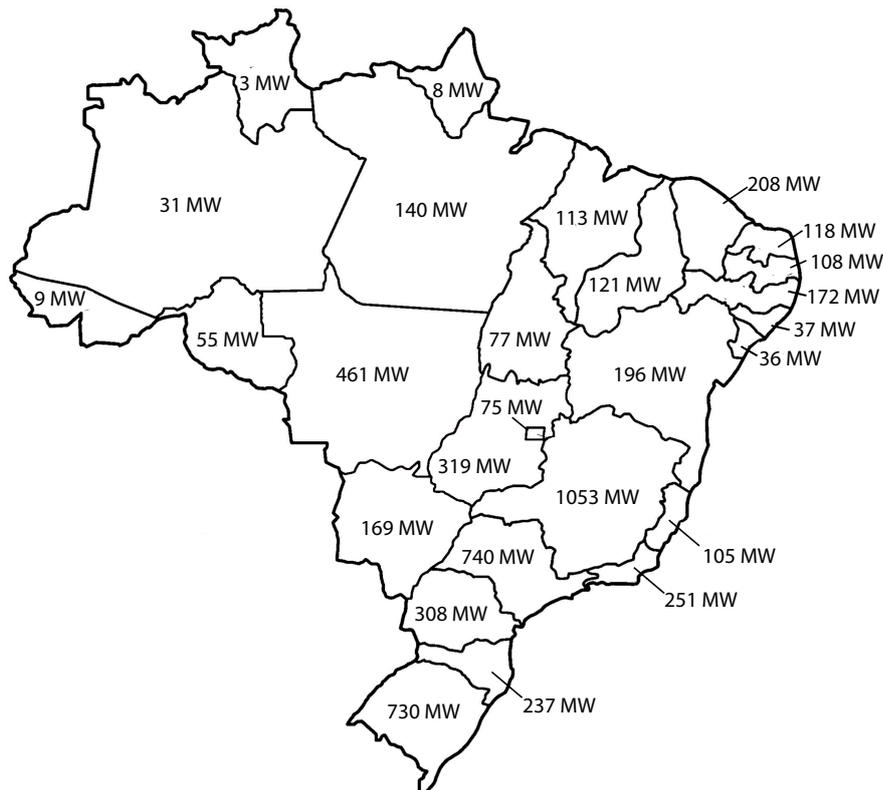
Um conjunto de fatores impulsionou a tecnologia fotovoltaica, tendo como marco principal no Brasil a deliberação decorrente da Resolução Normativa 482/2012 da ANEEL, vigorada em 17 de abril de 2012, enquadrando o consumidor brasileiro conectado em baixa tensão (BT) como um prossumidor de energia elétrica, permitindo que o mesmo seja capaz de acessar o sistema elétrico e gerar sua própria eletricidade a partir de fontes renováveis ou geração qualificada, fornecendo o excedente à rede de distribuição dentro da área de concessão (ANEEL, 2012). Posteriormente, visando reduzir custos e tempo para a conexão da microgeração e minigeração; compatibilizar o sistema de compensação de energia elétrica com as condições gerais de fornecimento; aumentar o público alvo; detalhar as informações da fatura; a ANEEL publicou a Resolução Normativa de nº 687/2015 revisando assim a atual resolução.

Decorrente desse processo de normatização e devido ao enorme potencial para utilização do recurso solar no Brasil, até o fim do primeiro semestre de 2021, totalizaram-se 505 mil usinas fotovoltaicas, beneficiando remotamente 640 mil UC na modalidade microgeração (ANEEL, 2021a), este valor quando comparado a outra fonte, representa 99% do número de

instalações, deixando o setor residencial responsável por compor 75,2% do total de usinas instaladas (ABSOLAR, 2021).

A consequência desse gigantesco número de conexões de unidades geradoras distribuídas na classe residencial, especificamente nos alimentadores de baixa tensão, surge com os diversos problemas de estabilidade na rede, tais como: o fluxo de potência reverso nos trechos de linha e em transformadores; aumento de tensão inesperado nas barras de cargas; ilhamento ocasional e efeito *flicker* (CHEN et al., 2012). O retardo em investimentos e modernização, principalmente do sistema de distribuição secundário, torna-se uma tarefa desafiadora (SILVA JÚNIOR, 2010). O mapeamento do potencial agregado em geração distribuída a partir dos sistemas fotovoltaicos é disposto na Figura 1, explicitando o valor agregado da capacidade instalada para cada estado brasileiro.

Figura 1 – Potencial fotovoltaico instalado no Brasil considerando a maior e menor capacidade instalada, assim como todo o potencial instalado na região nordeste.



Fonte: O autor, 2021.

Os dados que compõem a Figura 1 foram adquiridos em meados do ano de 2021, coletados no *site* da ANEEL, as atualizações dos quantitativos e potenciais instalados são inseridos na base de dados diariamente, podendo ser consultados no filtro de resumo por distribuidora (ANEEL, 2021a). A implementação não somente dos sistema fotovoltaico conectados à rede

(SFVCR), mas da geração distribuída (GD) como um todo, vem causando mudanças referente à concepção inicial do sistema elétrico de potência, pois as quilométricas linhas de transmissão e distribuição foram desenvolvidas para operar em dinâmica unidirecional. A inserção massiva da GD tem entusiasmado profissionais, pesquisadores, empresas geradoras e distribuidoras de eletricidade, a buscarem novas técnicas e métodos para mitigar os efeitos adversos causados pela tecnologia. Um dos modelos que acompanha esse processo é o gerenciamento pelo lado da demanda (GLD) que simultaneamente incorpora o modelo de rede elétrica inteligente, popularmente conhecida como *Smart Grid*. No cenário mundial, principalmente em países mais desenvolvidos, já são relatadas algumas experiências sobre o uso da tecnologia fotovoltaica integrada à rede elétrica, ao verificar o trabalho de Bayer et al. (2018), o autor fez um levantamento sobre a vivência prática e operacional de várias empresas distribuidoras de energia elétrica, onde foram listados os desafios acerca da inserção da geração distribuída fotovoltaica (GDFV).

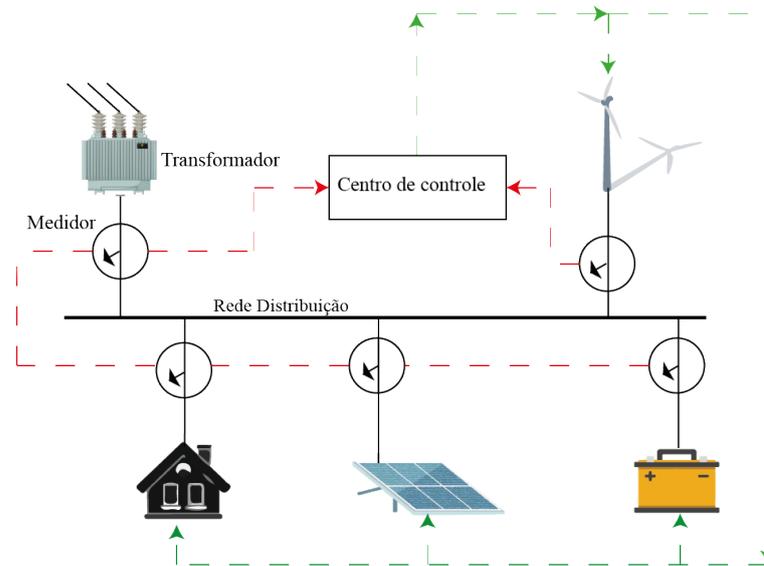
O sistema elétrico de potência (SEP) tradicional é o ambiente que acomoda todos os dispositivos de geração, transporte e distribuição de energia elétrica. Nessa configuração, os sistemas de geração de energia elétrica convencionais são preparados para reagir bruscamente às variações de demanda e manter a estabilidade de todo o conjunto, garantindo o equilíbrio entre demanda e geração (MURTHY, 2007). O SEP apresenta uma estrutura hierarquizada, onde o fluxo de energia elétrica sai da geração, permeando por todos os estágios da transmissão e subtransmissão, até chegar ao sistema de distribuição, a partir daí a energia elétrica atende as diversas classes consumidoras, estando o fluxo de carga em única direção e sempre partindo de níveis altos de tensão elétrica e abertura angular para os menores níveis de tensão (BARATA, 2017).

Como já citado no tópico anterior, as fortes ações do governo estão tornando as redes de distribuição que, inicialmente apresentavam característica de passividade, em redes ativas graças a conexão da GD. O novo formato operacional da redes de distribuição foi tecnicamente aceito quando os geradores distribuídos passaram a integrar as redes de distribuição em BT (ALAM; MUTTTAQUI; SUTANO, 2013). No início, os geradores fotovoltaicos foram caracterizados como uma alternativa de descentralizar a geração de energia elétrica convencional, pelo motivo de estar alocado próximo as cargas.

É relevante afirmar que o uso dessa categoria de geração apresenta diversas vantagens ao SEP, a exemplo a diminuição dos custos devido à necessidade de novos investimentos em expansão dos alimentadores, redução das perdas técnicas na transmissão e na distribuição de

energia elétrica, além de sua flexibilidade de implantação (BARATA, 2017). De outra forma, os SFVCR também apresentam desvantagens quando o assunto concerne à estabilidade e qualidade de energia elétrica. Contudo, no futuro o esperado é que a tipologia das redes elétricas sejam bastante atualizadas, agregando novos elementos e componentes de sistemas. A Figura 2 a seguir ilustra a concepção destas tecnologias inseridas no sistema elétrico de potência, vislumbrando um conceito de SEP ativo moderno.

Figura 2 – Sistema de distribuição ativo.



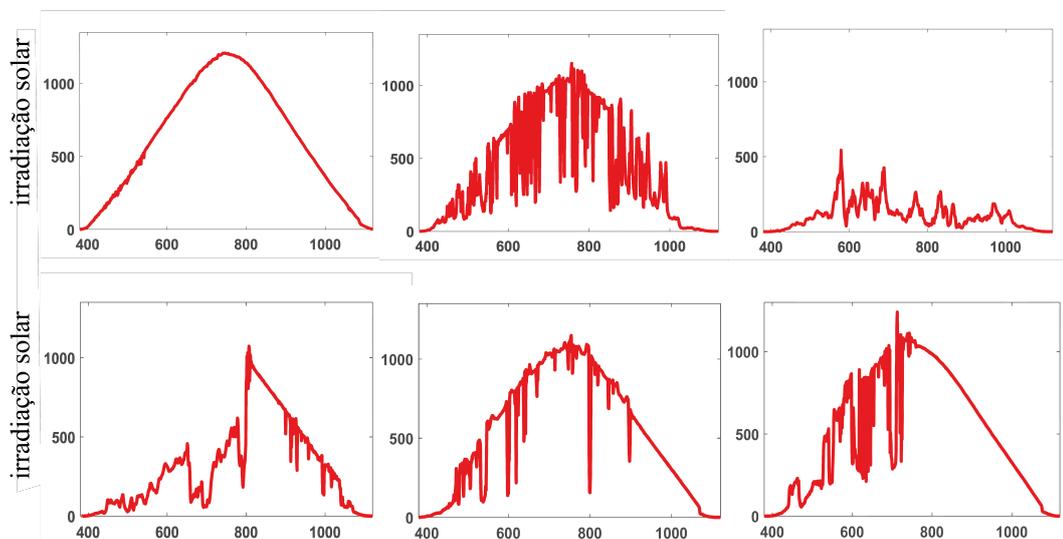
Fonte: O autor, 2021.

A evolução da inserção dos SFVCR's e das grandes centrais fotovoltaicas serão cada vez mais iminentes, sendo assim, considerando a diversificação da infraestrutura e das regulamentações dos sistemas de distribuição de energia elétrica (SDEE) entre os países do mundo, deve-se ter ciência dos métodos e ferramentas de análise de redes, e conseqüentemente dos seus resultados. Nos dias atuais, a energia solar impulsiona tanto o crescimento tecnológico quanto econômico de diversos países do mundo. De acordo com a Associação Brasileira de Energia Solar (ABSOLAR), do potencial total instalado de SFVCR no Brasil (9.187 MW), 36% correspondem a geração centralizada (GC) e 64% referem-se a GD solar fotovoltaica, para a matriz elétrica brasileira considera-se a fonte solar com 1.6% da composição total da matriz elétrica (ABSOLAR, 2021). A alavancagem da energia solar fotovoltaica no Brasil é monitorada pelo posicionamento no ranking dos países que mais investiram em energia solar no mundo, encontrando-se atualmente em 12º lugar.

1.2 CARACTERIZAÇÃO DO PROBLEMA

A alta densidade de carga dos SDEE e o grande volume de ramificações das ligações residenciais, atreladas quase sempre à carência de informações em pontos específicos do sistema, desafia a representação completa do processo de um sistema. Quando se tem um ou mais SFVCR's conectados as demais barras do SEP, é necessário ter ciência da potência produzida por esses dispositivos. O entendimento da potência fotogerada parte da energia incidente na superfície terrestre, sofrendo variações ao longo do dia, mês, ano e latitude. A variação da irradiação solar divide-se em duas componentes primordiais: uma determinística e a outra estocástica (CAMPOS FILHO, 2019). Com um dado conjunto de equações inferidos da análise geográfica e geométrica da posição e movimento relativo terra-sol é possível calcular todo o recurso solar incidente sobre uma superfície genérica, a esse fato caracteriza-se a componente determinística (RABL, 1985). A característica estocástica da irradiação solar, é consequência das alterações de um conjunto de fatores da atmosfera, um exemplo disso é a aleatoriedade das passagens ou aproximações de nuvens e o sombreamento esporádico por movimentações de objetos. Resumidamente, o comportamento da irradiação solar depende de um cenário bastante complexo diante da natureza estocástica e determinística. O fenômeno da variabilidade é atribuído às características meteorológicas do dia em questão, evidenciando formatos de aleatoriedade impactando no perfil diário da irradiação solar (CAMPOS FILHO, 2019). Logo abaixo, a Figura 3 esboça os perfis típicos que caracterizam o dia solar em função do seu contorno.

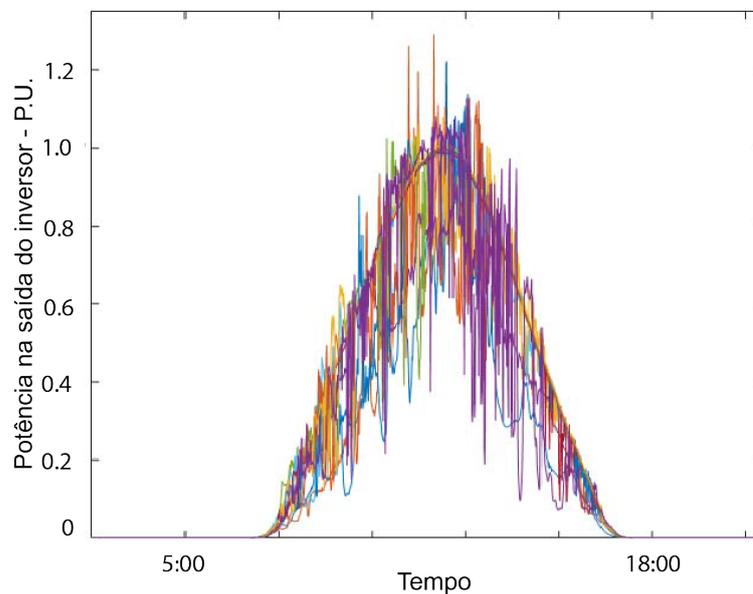
Figura 3 – Perfis típicos da irradiação solar na superfície terrestre.



Fonte: O autor, 2021.

Do ponto de vista prático, a variabilidade do recurso solar é provocada pelas passagens de nuvens (PELLAND; GALANIS; KALLOS, 2013), implicando em severas flutuações de potência entregue à rede elétrica por um sistema fotovoltaico. Os possíveis perfis característicos destacados pela Figura 3, causam insegurança aos operadores do sistema elétrico quanto a garantia do despacho energético diante da não garantia da produção de energia elétrica a partir de uma usina solar fotovoltaica. Formato convencional há reservas de potência para manter a necessidade do suprimento de eletricidade, com o intuito de satisfazer o balanço energético, mantendo os níveis de tensão e frequência dentro do tolerável. Supondo a geração fotovoltaica, as reservas de potência não são suficientemente ágeis para fornecer a energia elétrica necessária num instante de tempo muito curto, essa particularidade dificulta uma reação ou tomada de decisão pelo operador do SEP, fazendo com que algumas variações abruptas na potência não sejam absorvidas. A seguir, Figura 4, uma mera ilustração retirada de um sistema fotovoltaico real esboça um conjunto de dados diários da potência normalizada na saída de um inversor.

Figura 4 – Amostras de vários dias exemplificando a variabilidade da potência na saída de um inversor fotovoltaico.



Fonte: O autor, 2021.

Como notado acima, a “instabilidade” de potência pode ser propagada ao sistema elétrico através de perturbações nos sinais elétricos. Essas adversidades tem mobilizado diversas instituições e profissionais da engenharia no progresso de novas técnicas de análise e ferramentas mitigatórias. Por exemplo, no trabalho de Almeida (2017), o mesmo cita o acontecimento de eventos que promoveram discussões acerca das possíveis instabilidades causadas ao grande

sistema elétrico, tais eventos foram realizados pelo *Massachusetts Institute of Technology (MIT)*, o evento teve o seguinte tema: *Managing Large-scale Penetration of Intermittent Renewables*. Em 2012, a *European Photovoltaic Industry Association (EPIA)* lançou um estudo de base sobre breves ações que deveriam ser implementadas para participação da geração fotovoltaica. Novas definições também foram repensadas para explicar e categorizar as flutuações de potência, na Figura 4 por exemplo, as formas de onda sobrepostas são atribuídas ao fenômeno das rampas de potência, podendo ser calculadas através do coeficiente de taxas de rampas (HARPER, 2010). Numericamente, a taxa de rampa pode ser calculada pela razão entre a diferença das potências ΔP (potência no instante de tempo atual e a potência no tempo anterior) pelo intervalo de tempo Δt ou pela potência nominal do inversor P^* (DIAZ, 2019). O conceito de rampa de potência surgiu com o intuito de classificar a variabilidade de potência verificando os distúrbios induzidos no sistema de transmissão e distribuição de energia elétrica. No Brasil, ainda é bastante escasso encontrar uma gama diversificada de estudos relatando os efeitos negativos da energia solar fotovoltaica. Conforme exposto por Diaz (2019), o Brasil ainda está em busca de experiências e resultados robustos para elaboração de normas a respeito das taxas de rampas, diferentemente de alguns países que já largaram na frente, como Porto Rico, Irlanda e México.

Enquadrando o cenário de alta penetração da microgeração fotovoltaica distribuída em redes elétricas de baixa tensão, o Brasil ainda está atrasado em relação ao cenário mundial, isso comprova que os desafios encontram-se em perspectiva de médio e longo prazo. Decorrente dessa afirmação, há de se levantar um grande ponto preocupante que é a desconsideração nos estudos de operação e planejamento no acoplamento das redes de distribuição e transmissão (BARATA, 2017). Com relação a viabilidade técnica e a permissão de acesso ao sistema de distribuição, novas técnicas de estudo precisam ser adotadas.

Mediante tais fatores sintetizados acima, é preocupante o futuro da energia solar fotovoltaica no Brasil, negligenciar estudos de impactos da geração distribuída certamente fomenta conclusões errôneas e incertas quanto à operacionalidade da rede. Este trabalho engloba todo esse contexto, contribuindo para uma construção de ferramentas e métodos para solucionar essa problemática.

1.3 CONTRIBUIÇÕES

De acordo com o que foi encontrado em buscas na literatura atual, há um grande número de relatos sobre trabalhos envolvendo a temática do impacto causado por usinas fotovoltaicas nos sistemas de transmissão e distribuição primária. Pode-se observar discussões acerca do uso de ferramentas de previsão baseadas em técnicas de inteligência artificial, que combinadas a modelos matemáticos de produção de eletricidade, estimam o despacho de energia elétrica no horizonte de tempo de minutos, horas e até mesmo alguns dias à frente.

Remetendo-se a um ambiente de rede de distribuição secundária, a ausência de informações a respeito dos parâmetros elétricos e comportamento operacional é um grande gargalo para a realização de estudos mais específicos, principalmente nos circuitos residenciais. Esta pesquisa destacou um formato de estudo para que as empresas concessionárias distribuidoras de energia elétrica, entendam o estado da rede elétrica observando o perfil da tensão no ponto de fornecimento, promovendo a capacidade de interpretar e anteceder possíveis impactos em um ou mais pontos do sistema elétrico.

A partir da observação do perfil de tensão, elaborou-se uma técnica para mitigação da sobretensão em regime permanente. O método proposto nessa trabalho partiu do planejamento de um dispositivo de armazenamento de energia elétrica escalonado em grupos de potência distintos, onde o acionamento do dispositivo foi mediado a partir de uma rede neural. A etapa primária foi constituída por um algoritmo previsor de irradiação solar e temperatura operacional do módulo fotovoltaico em horizonte temporal de curto prazo, posteriormente as tensões foram calculadas mediante a modelagem da rede elétrica e solução do fluxo de potência. O valores utilizados como critérios limitantes foram referidos aos listados pelo Procedimentos de Distribuição de Energia Elétrica (PRODIST) em seu módulo 8, que trata dos valores da tensão precária e crítica do produto fornecido.

1.4 OBJETIVOS E METAS

Para o novo modelo de operação do SDEE, há a necessidade do surgimento de novas metodologias de estudos para verificação do estado da rede, bem como associada às soluções mitigadoras que promovam o estado operativo do sistema. De acordo com esta realidade, o objetivo geral deste trabalho foi analisar a interação operacional entre uma UC, a rede de distribuição secundária e um SFVCR. Neste contexto, a partir das combinações de cenários

específicos entre essas principais variáveis citadas, esse trabalho traça dois grandes objetivos gerais:

- Apresentar um método de estudo para avaliação e solução prática do impacto da GDFV em redes de distribuição, relatando, caso haja, os impactos no ponto de fornecimento da UC e/ou em diferentes pontos da rede;
- Avaliar o impacto da alta variabilidade da irradiação solar na tensão de curto prazo, propondo uma técnica de mitigação para atenuação e melhoramento dos níveis da tensão de fornecimento da UC.

Para que os objetivos gerais sejam atingidos, traçaram-se as seguintes etapas:

- Instalação de um SFVCR com 5 kWp de potência em uma UC residencial, localizada na última barra (Fim de Rede), em uma rede de distribuição real;
- Instrumentação completa do SFVCR, UC e das grandezas climatológicas;
- Modelagem da rede real de distribuição de eletricidade *Open Distribution System Simulator (OpenDSS)*;
- Planejamento e simulação dos casos de inserção da geração fotovoltaica sob as condições típicas da irradiação solar, e em horizonte de tempo horário e de curto prazo (1 minuto), avaliando o estado da rede em função dos níveis de tensão;
- Modelagem da irradiação solar e temperatura do módulo fotovoltaico, utilizando redes neurais recorrentes *Recurrent Neural Network (RNN)* para previsões de curto prazo;
- Desenvolvimento de um método para antecipar e mitigar o estado da rede a partir dos dados de previsão da irradiação solar e temperatura, utilizando um sistema de armazenamento elétrico;
- Testar o desempenho do método através dos dias reais monitorados pelo sistema de aquisição de dados.

2 REVISÃO DA LITERATURA

2.1 PROBLEMAS ASSOCIADOS À GERAÇÃO FOTOVOLTAICA

O principal marco da energia solar fotovoltaica no Brasil foi promovido pela criação da 482/2012 da ANEEL, a partir dela diversos incentivos governamentais também foram responsáveis pelo início do rápido crescimento tecnológico, assim como da implantação da GD no sistema elétrico brasileiro. Apesar de ser um ponto muito positivo para as questões econômicas, permitindo que o consumidor praticamente elimine sua fatura de energia elétrica, a crescente taxa de penetração de geradores fotovoltaicos vêm preocupando profissionais da área com relação aos aspectos técnicos. Apesar de todo o favorecimento para a inserção da energia solar fotovoltaica, o Brasil ainda se acomoda em um panorama de amadurecimento, onde nesse horizonte várias pesquisas e experiências estão em constante formação.

No cenário mundial é um pouco diferente, visto que a corrida pela energia solar fotovoltaica teve seu início prematuramente. Tomando a Alemanha como referência, com potencial instalado de 54 GWp computados até o final do ano de 2020 (REN21, 2021). Em Bayer et al. (2018) foram apresentados relatos sobre as experiências práticas de dez empresas de distribuição de eletricidade da Alemanha, que desempenham um papel de liderança neste campo.

Os resultados discutidos acenaram para uma preocupação em manter os níveis de tensão da rede dentro do permitido. As medidas de otimização de rede representam a etapa inicial mais econômica e incluem, por exemplo, mudanças na estrutura da rede e controle da área. Quando a máxima capacidade é alcançada, medidas como a expansão da rede e repotencialização, necessitam ser otimizadas para suportar o fluxo de potência. Em casos individuais, a rede de distribuição é reforçada pelos chamados equipamentos operacionais, como reguladores de tensão apropriados e até implantação de transformadores de distribuição local. Ainda com relação ao estudo de Bayer et al. (2018), a motivação partiu da condição que a capacidade instalada de sistemas fotovoltaicos estão espalhadas pelas redes de baixa tensão compondo a arquitetura dos telhados, onde 90% desses sistemas são inferiores a 30 kWp.

A literatura atual destaca muitas pesquisas relacionadas a grandes centrais fotovoltaicas integradas ao sistema de transmissão. Porém, quando o assunto é refletido para a microgeração distribuída, há relatos pontuais, ou até mesmo restrição do assunto quanto a uma abordagem mais completa e detalhada. A dificuldade de se estudar os impactos da geração distribuída em redes de distribuição muitas vezes é fortemente influenciada pela complexidade e ausência de

um conjunto de informações e características, recaindo em suposições. As seções e subseções deste capítulo, discorrem sobre as problemáticas observadas por alguns estudos aplicados aos sistemas de distribuição de energia elétrica.

2.1.1 Restrições operacionais aos limites de tensão

A técnica mais comum para a manutenção da estabilidade da tensão elétrica em uma barra é mediada pelo controle da excitação dos geradores síncronos, a ação é desempenhada pelos limitadores de sobrecorrentes, *overexcitation limiter (OEL)*, atuando de forma a ajustar a injeção da potência reativa pelo motor síncrono (BARATA, 2017). Ao longo dos circuitos de transmissão e distribuição a estabilidade da tensão é desempenhada pelos transformadores, especialmente os equipados com os comutadores de taps, *on load tap changer (OLTC)*, possibilitando a regulação automática dos níveis de tensão ao longo da rede (QUEVEDO, 2018), esse tipo de equipamento está situado em redes de distribuição primária atendidas em média tensão, ou em grandes subestações de distribuição. Como grande parte da GD está incorporada as redes radiais, as violações de tensão devido à alta injeção de potência elétrica podem ser frequentemente localizadas. Nesse sentido, os patamares permissíveis dos valores apresentados na Tabela 1 abaixo, contempla os níveis permitidos que devem ser acompanhados nas redes de distribuição (ANEEL, 2021b):

Tabela 1 – Classificação dos níveis de tensão.

Classificação	Monofásico (Volts)	Trifásico (Volts)
Normal	$202 \leq V \leq 231$	$350 \leq V \leq 399$
Limite crítico (Superior)	$V > 233$	$V > 403$
Limite crítico (Inferior)	$V < 191$	$V < 331$
Limite precário (Superior)	$231 < V \leq 233$	$399 < V \leq 403$
Limite precário (Inferior)	$191 \leq V < 202$	$331 \leq V < 350$

Fonte: (ANEEL, 2021a).

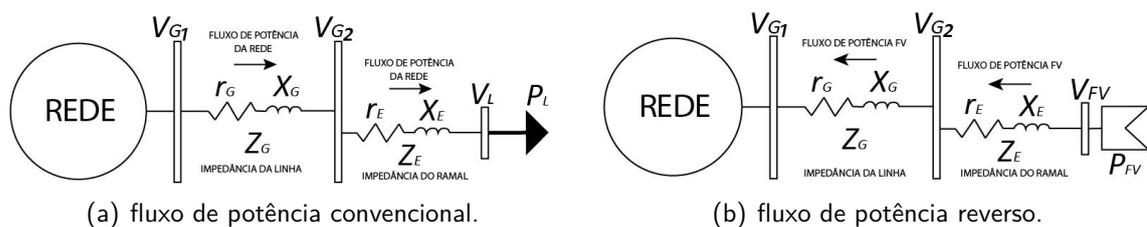
Os dados da Tabela 1 refletem a condição onde o valor de base ou de referência está em 220 volts monofásico ou 380 volts trifásico. A qualidade do nível de tensão em regime permanente é avaliada por indicadores, não devendo superar 3% de leituras precárias ou 0,5% de leituras críticas dentro de um conjunto de 1008 leituras válidas (LIMA; BERNARDON; OLIVEIRA, 2017). A garantia da manutenção dos níveis de tensão são requisitos que embasa a criação de normalização que garantam o ingresso da GD na rede de distribuição, mantendo o

desempenho de ambas as partes, assim como a qualidade de energia fornecida.

2.1.2 Elevação da tensão em prossumidores residenciais

A entrada da energia solar fotovoltaica no novo modelo de redes de distribuição divide opiniões em vários aspectos, muitos defendem a empregabilidade dos SFVCR pelo caráter sustentável, para outros, a tecnologia é encarada como uma fonte de transtornos ao sistema elétrico. É sabido que a participação dos SFVCR tem obtido uma expressiva participação na matriz elétrica brasileira, com isso surgem os questionamentos sobre as inúmeras inconsistências operacionais, exigindo um sistema elétrico mais ativo e automatizado (BOKHARI et al., 2016). Um SEP é apresentado em contexto resumido pela Figura 5, modelando a dinâmica do fluxo de potência. Essa representação pode ser expandida em um sistema mais complexo, com diversas unidades consumidoras e barras.

Figura 5 – Diagrama elétrico simplificado da interligação de um prossumidor à rede elétrica.



Fonte: O autor, 2021.

Ao examinar a Figura 5.a a carga residencial está conectada diretamente à rede através da impedância Z_E , esta representa o condutor ramal responsável por interligar fisicamente a residência ao sistema fornecedor de energia elétrica. A impedância equivalente da rede, para fins de simplificação, está representada pela variável Z_G , este elemento serve para modelar a impedância vista por um ponto específico do sistema. As impedâncias $(R+jX)$ representam as componentes resistiva (R) e reativa (jX), a predominância de ambas as componentes é ditada pelas características construtivas da rede, influenciando a sensibilidade da relação reatância/resistência (X/R) (BRAZ, 2003). Em Alves (2017), foi relatado a respeito da relação X/R das redes de distribuição, onde a forte predominância da componente resistiva pode levar esta relação a um valor inferior a 1.0. Sendo P_L a potência demandada pela carga, dentre os variados modelos destacam-se as de: potência, corrente e impedância constante (OLIVEIRA, 2017). Ainda assim, tomando a Figura 5.a, ressalta-se que o sistema elétrico de baixa tensão

foi inicialmente projetado para este modo de operação, onde o sentido da queda de tensão entre as barras é sempre do lado do consumidor ($V_G > V_C$).

Na Figura 5.b, considera-se ausência da carga residencial, então tem-se que $P_{FV} > 0$, assumindo esses fatos todo o fluxo de energia é revertido à rede elétrica, neste princípio, a tensão no ponto de conexão do gerador fotovoltaico tende a se elevar em função da quantidade de injeção de potência ($V_{FV} > V_G$). Tanto as Figuras 5.a e 5.b, representam conexões onde ocorre o fluxo de carga em apenas uma direção, ora direto, ora reverso. Considerando inicialmente o fluxo de energia que parte da fonte à carga (P_L), é possível formalizar matematicamente a variação da tensão nas barras fonte (V_{G_1} e V_{G_2}) e carga (V_L) pelas seguintes equações 2.1 e 2.2:

$$V_{G_1} - V_{G_2} = I_L \cdot Z_G = I_L \cdot (r_G + jX_G) \quad (2.1)$$

$$V_{G_2} - V_L = I_L \cdot Z_E = I_L \cdot (r_E + jX_E) \quad (2.2)$$

Para as redes de distribuição, a componente resistiva predomina sobre a reativa devido as características dos circuitos e condutores (BORGES, 2014). Neste contexto, representa-se a equação 2.2 desprezando a componente reativa do ramo de conexão da UC residencial, expandindo-a para 2.3.

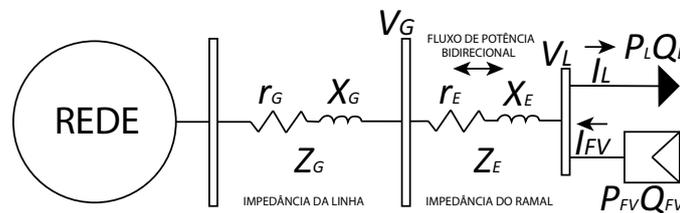
$$V_{G_2} - V_L = I_L \cdot Z_E = I_L \cdot (r_E) \quad (2.3)$$

$$V_L = V_{G_2} - V_{r_E} \quad (2.4)$$

A equação 2.4, demonstra que a tensão na barra de carga é dada pela diferença entre a tensão na barra da rede e a queda de tensão (V_{r_E}) ao longo do condutor do ramo de conexão. A impedância do ramo de interligação, na maioria das vezes, por considerar fatores intrínsecos de projetos, trata-se de um condutor singelo, e por isso a impedância está intimamente ligada as suas características, tais como: seção transversal, material utilizado na fabricação e comprimento linear do condutor. Diante dessas reflexões, o desafio está verdadeiramente atrelado a situações de microgeradores posicionados em alimentadores de preponderância residencial, quando envolve a dinâmica entre a irradiância solar, potência fotogerada e potência deman-

dada pela residência. Uma visão mais contemporânea de um sistema de potência em baixa tensão pode ser apresentado pela Figura 6.

Figura 6 – Representação do fluxo de potência bidirecional.



Fonte: O autor, 2021.

Para o circuito exposto acima, as variáveis elétricas Z_G , Z_E , V_G , V_L , P_{FV} , Q_{FV} , P_L , Q_L , I_{FV} e I_L , são respectivamente as: impedância da rede, impedância do ramal de interligação do consumidor, tensão na barra da rede, tensão no ponto de entrega ao consumidor, potência ativa fotogerada, potência reativa fotogerada, potência ativa demandada, potência reativa demandada, corrente fotogerada e corrente demandada pela UC. Para efeitos de cálculo, sabe-se que as componentes de potência ativa e reativa compõem a potência complexa.

Mantendo a convenção do sinal positivo para o fluxo de corrente unidirecional e supondo que nesta análise $P_{FV} \gg P_L$, tem-se que a potência complexa que flui reversamente pela impedância Z_G e Z_C será obtida pela diferença entre as potências complexas de geração fotovoltaica e carga, conforme a equação 2.5.

$$S_{FV,inj} = (P_{FV} + jQ_{FV}) - (P_L + jQ_L) \quad (2.5)$$

Admitindo-se que potência fotogerada é superior a potência demandada, a corrente fotogerada (I_{inj}) segue da barra de carga no sentido da barra da subestação é expressada por 2.6.

$$I_{inj} = \frac{P_{inj} - jQ_{inj}}{V_L^*} \quad (2.6)$$

Polarizando a queda de tensão em função do sentido da corrente injetada pelo sistema fotovoltaico, tem-se que a variação da tensão exibida pela equação 2.7, sendo essa mesma equação expandida em função dos potenciais de tensão em cada barra, a equação 2.7 pode

ser expandida em 2.8.

$$\Delta V = I_{inj} \cdot Z_E \quad (2.7)$$

$$V_L - V_G = I_{inj} \cdot (r_E + jX_E) \quad (2.8)$$

Substituindo o termo I_{inj} da equação 2.8 em função dos termos da equação 2.6, a expressão 2.8 pode ser reorganizada da seguinte forma:

$$V_L - V_G = \frac{P_{inj} - jQ_{inj}}{V_L^*} \cdot (r_E + jX_E) \quad (2.9)$$

$$V_L - V_G = \frac{(r_E \cdot P_{inj} + x_E \cdot Q_{inj}) + j(X_E \cdot P_{inj} - r_E \cdot Q_{inj})}{V_L^*} \quad (2.10)$$

Em Borges (2014), é citado que a abertura angular entre duas barras em um alimentador de distribuição enquadrado em BT é praticamente zero. Em Lima, Bernardon e Oliveira (2017), também é relatado sobre a invariabilidade angular entre barras no sistema de distribuição BT. Sendo assim, para o cálculo da queda de tensão entre as barras considera-se apenas a componente real do numerador da equação 2.10.

2.1.3 Flutuação de potência

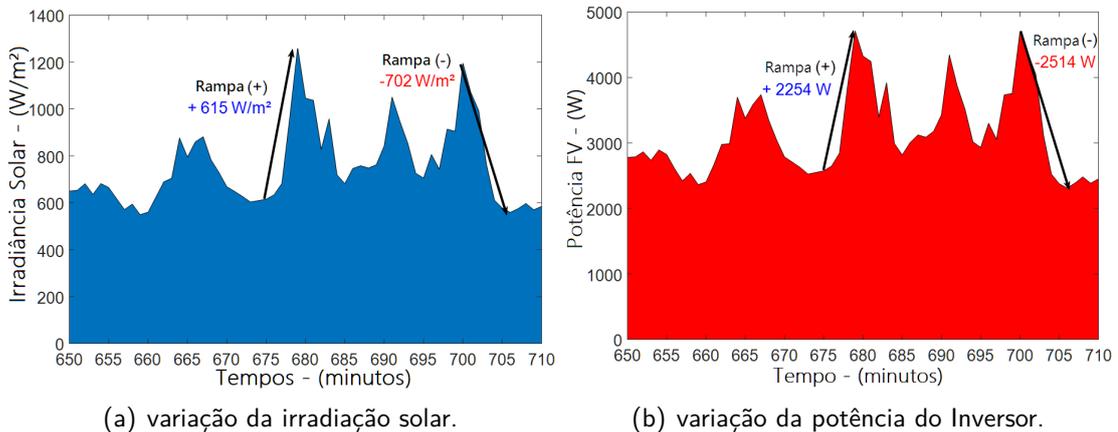
Em termos práticos, o conceito de rampa de potência serve para caracterizar os fenômenos de flutuação de potência, a mesma ocorre devido ao comportamento característico da irradiação solar. No entanto, essas flutuações podem causar variações na tensão e corrente do sistema de distribuição (MA et al., 2019). Em Gevorgian e Booth (2013), são definidos vários procedimentos para cálculos de rampas de potência. Como exemplo, pode conceituar da seguinte forma: a diferença entre dois pontos finais de um intervalo de 1 minuto, ou a diferença entre os pontos máximos e mínimos compreendidos em um intervalo de tempo (Δt) (MARTINS et al., 2019). Matematicamente, a taxa de rampa de potência (ΔP) normalizada pela potência nominal do inversor (P^*) é definida em um intervalo de tempo (Δt) como a diferença entre as amostras consecutivas da potência fotovoltaica injetada na rede no tempo

atual ($P_{FV(t)}$), e a potência que a antecede ($P_{FV(t-\Delta t)}$) (DIAZ, 2019), conforme expressado em 2.11.

$$\Delta P = \frac{P_{FV(t)} - P_{FV(t-\Delta t)}}{P^*} \quad (2.11)$$

O gráfico a seguir foi elaborado com dados reais desta pesquisa e aplicado nesta seção para ilustrar um exemplo de variabilidade da irradiação solar, Figura 7.a, e da flutuação de potência na saída do inversor, Figura 7.b. Os gráficos estão apresentados em função das respectivas grandezas, desconsiderando a normalização da potência nominal do inversor e da irradiação solar de referência ($H_\beta = 1000kW/m^2$).

Figura 7 – Representação da intermitência solar e da flutuação de potência.



Fonte: O autor, 2021.

Para Campos Filho (2019), o fenômeno da variabilidade foi atribuído às características meteorológicas do dia em questão, evidenciando contornos de aleatoriedade. É notório a forte correlação entre o perfil comportamental dos gráficos na Figura 7, sendo assim, a equação 2.11 também pode ser aplicada para o cálculo da variabilidade da irradiação solar. A quantificação da taxa de rampa pode ser feita usando medições de potência na saída do inversor ou de radiação solar (DIAZ, 2019). Algumas pesquisas já realizadas em todo o mundo marca o início da regulamentação das taxas de rampas. Na Irlanda, foi catalogado uma taxa de rampa positiva de 30MW/minuto e no Havaí, uma rampa variável de $\pm 2MW$ /minuto. Na dinamarca, é aceitável uma rampa de potência de 100KW/segundo (ENERGINET, 2016). Em WengKow et al. (2016), foram relatadas informações a respeito da regulamentação própria do valor de taxa de rampa, permitindo 10%/minuto, valor normatizado pela *Puerto Rico Electric Authority (PREPA)*.

No México, aceita-se uma flutuação de potência entre uma faixa de 1% à 5%/minuto da capacidade do sistema fotovoltaico instalado (MARCOS et al., 2014).

Entretanto, o Brasil ainda não há exigências com relação a padronização para aceitação das taxas de rampas (DIAZ, 2019). De acordo com os valores de taxas de rampas exemplificados no parágrafo anterior, surge constantemente a forte motivação para o desenvolvimento de novas pesquisa com ênfase em controle das flutuações de potência, objetivando amenizar os impactos negativos no sistema elétrico.

2.2 ESTRATÉGIAS MITIGATÓRIAS PARA INTERMITÊNCIA FOTOVOLTAICA

Essa seção trata de algumas ações utilizadas para solucionar problemas a respeito da inserção massiva da GD fotovoltaica. Além dos problemas ocasionados por efeitos de curta duração, como os transitórios, um grave problema consequente da penetração da geração distribuída, especificamente a solar FV, é o surgimento do fluxo reverso em períodos onde não há uma demanda considerável, assim, provocando anormalidades no sistema de distribuição. Outro ponto de enfoque, é quando as frequentes passagens de nuvens sobre esses sistemas, altera o fluxo de potência e os indicadores de qualidade.

2.2.1 Reguladores de tensão

Os reguladores de tensão (RT) são considerados autotransformadores com relação de transformação direta, ou seja 1:1. O arranjo de três reguladores de tensão monofásicos pode tranquilamente equipar um sistema trifásico, sendo um para cada fase. Por definição, é um equipamento elétrico de indução que possui um ou mais enrolamentos em paralelo com o circuito primário, sendo excitado por este. O regulador de tensão é tradicionalmente utilizado em redes de distribuição com o objetivo de controlar a tensão em determinados pontos do sistema de potência, genericamente, a sua instalação é feita em subestações e em pontos intermediários distantes da mesma, onde comumente tem-se uma diminuição do potencial.

Como já dito anteriormente, o transitório resultante ocasionado por passagens de nuvens influencia diretamente na potência de saída do sistema fotovoltaico, que por sua vez pode provocar variações severas na qualidade da tensão elétrica. Essa condição remete a uma atenção especial em reaver a necessidade de modificações na parametrização do regulador de tensão, isto porque, em função da frequência de passagens de nuvens, os transitórios que irão

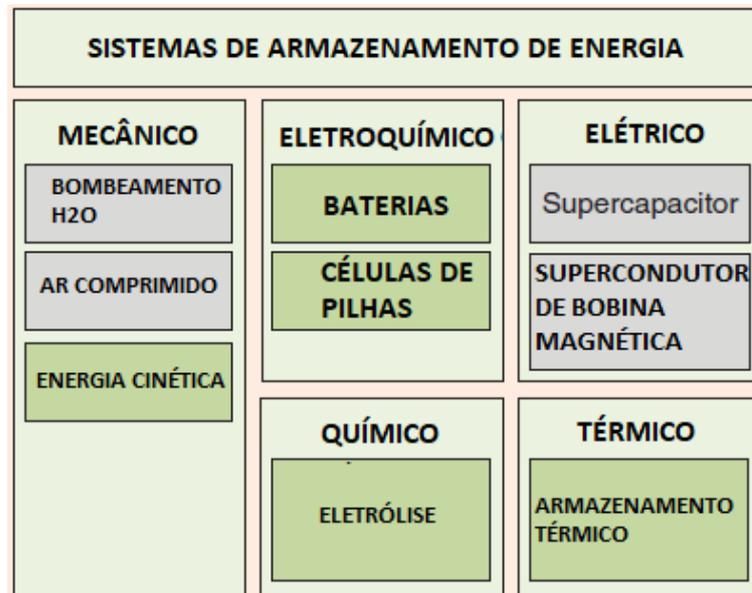
ocorrer podem ser de curta ou longa duração, fazendo com que o RT seja ineficaz (GRANZOTO; FERREIRA; TRINDADE, 2016). A quantidade de mudanças do tap de um regulador de tensão pode atingir até 400 ciclos para um dia nublado, reduzindo significativamente sua vida útil (ROGERS; GREEN, 2013).

A partir desse novo conceito de redes de distribuição, novas práticas e conceitos estão sendo adotados pelas distribuidoras e agências reguladoras, intuindo diminuir os impactos causados a estes equipamentos. Como exemplo, é possível citar países como a Alemanha, que restringe a 2% as variações de tensão de curta duração no ponto de conexão entre o gerador fotovoltaico e a rede elétrica (BDEW, 2008). Em Granzoto, Ferreira e Trindade (2016), foi proposto um método analítico com o objetivo de verificar os impactos na variação de tensão causadas pela passagens de nuvens sobre os sistemas fotovoltaicos no número de atuações dos RT, os dados foram simulados no programa *OpenDSS*.

2.2.2 Tecnologias de armazenamento de energia

Considerado como uma fonte de benefícios ao consumidor, a intensa penetração de SFVCR pode ser uma eventual fonte de problemas para o SDEE. Em alguns países já ocorrem exigências para alocação de baterias junto ao sistema de distribuição de eletricidade, através de legislações que forçam a compra de toda energia produzida pela geração distribuída, seja essa produção utilizada ou não (DAZA; SPERANDIO, 2018). Com este avanço, o modo com o qual os profissionais analisam o sistema elétrico precisa ser rapidamente adaptado para o novo contexto, utilizando novas soluções para o estudo do fluxo de potência (DUGAN; TAYLOR; MONTENEGRO, 2017). Sistemas de armazenamento de energia, também denominados de *Battery Energy Storage System (BESS)*, tais como: supercapacitores, volantes de inércia, compressores de ar comprimido, bombas hidráulicas e baterias elétricas, são elementos que atualmente integram o contexto de um sistema elétrico de potência (FARROKHABADI et al., 2017). A depender das premissas funcionais, técnicas e financeiras, as tecnologias desenvolvidas para sistemas de armazenamento são classificadas a partir da Figura 8.

Figura 8 – Formas de armazenamento de energia.



Fonte: Adaptado (FARROKHABADI et al., 2017).

Mais especificamente, a necessidade de introdução de baterias elétricas voltou a ser uma realidade com o intuito de sanar os problemas de flutuações anormais da magnitude da tensão que não são tolerados além dos limites especificados na Tabela 13. Foi extraído do trabalho de Diaz (2019), e exposto na tabela 2 a seguir, uma síntese das principais tecnologias e seus respectivos atributos.

Tabela 2 – Características das baterias eletroquímicas.

Elemento	Atributos				
	Energia Específica (kWh/kg)	Vida Útil (anos)	Eficiência (%)	Ciclos	Tempo de Resposta
Chumbo-Ácido	50 a 80	3 a 15	75 a 90	< 1800	milisegundos
Íon-Lítio	200 a 400	5 a 15	85 a 90	> 4000	milisegundos
NiCd	< 150	15 a 20	70 a 75	> 2500	milisegundos

Fonte: Adaptado (DIAZ, 2019).

Há um consenso em diversos trabalhos pelo uso de baterias de chumbo-ácido e íons de lítio. Em De La Parra et al. (2018), é elaborado um estudo experimental com uso de baterias de íon-lítio, com eficiência bidirecional de 95%. Apesar das baterias de chumbo-ácido possuírem uma menor relação custo-benefício, em alguns casos pode ser viável aplicar esta tecnologia em relação a de íon-lítio (DIAZ, 2019). O grande dilema relacionado a aplicação das baterias

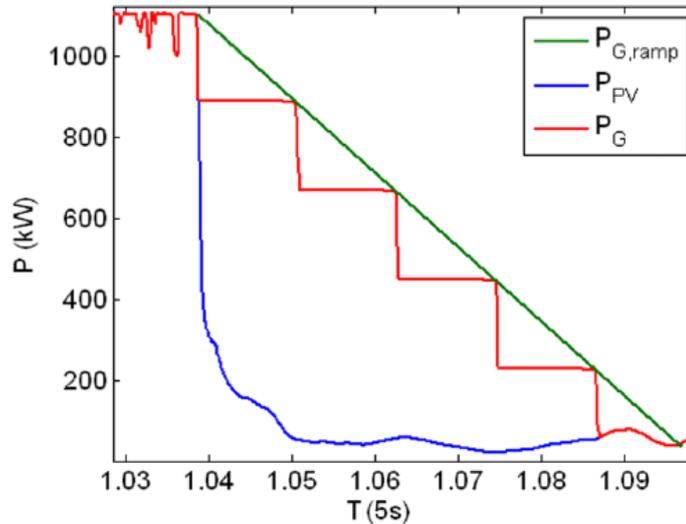
é a capacidade do seu número de ciclos, estando esta totalmente ligada a profundidade de descarga, *Depth of Discharge (DoD)*, e temperatura de operação (DIAZ, 2019).

2.2.2.1 Controle da potência ativa por baterias

Do ponto de vista global coordenar a inserção da GD nas redes de distribuição é um grande desafio, até mesmo para os países que detêm um certo grau de experiência e maturidade com a tecnologia fotovoltaica. As primeiras intervenções para evitar o colapso na rede de distribuição se baseavam no corte ou redução da potência gerada. Em Tonkoski, Lopes e El-Fouly (2011), o autor discute técnicas de corte de potência ativa para prevenir sobretensão, aplicando o seu método proposto em dois alimentadores urbanos com características semelhantes as redes de distribuição no Brasil. O método de corte e/ou redução da potência ativa é bastante contraditório ao propósito operacional de um gerador fotovoltaico, este tipo de método pode levar a redução da eficiência de todo o conjunto fotovoltaico (TORRES; NEGREIROS; TIBA, 2019).

A combinação do uso de baterias com módulos fotovoltaicos é uma técnica utilizada em sistemas fotovoltaicos, que objetiva o controle da potência injetada no sistema (MARCOS et al., 2014). A Figura 9, ilustra o resultado para a potência injetada a partir de dois tipos de controle, sendo: a potência injetada pela função degrau na cor vermelha (P_G) e pela função rampa na cor verde ($P_{G,ramp}$). A redução abrupta da potência do gerador fotovoltaico, curva azul (P_{FV}), simboliza a diminuição de produção de potência por obstrução do fluxo de irradiação solar.

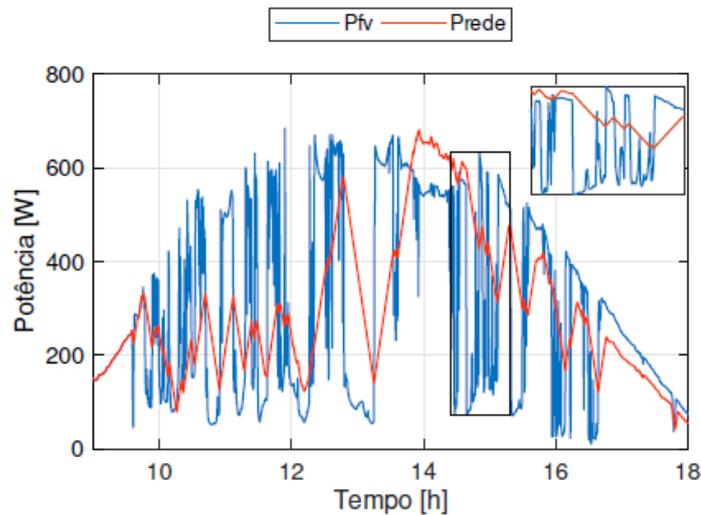
Figura 9 – Suavização da potência injetada na rede considerando o armazenamento.



Fonte: adaptado (MARCOS et al., 2014).

Dentro desse mesmo contexto, Martins et al. (2019) verificou as estratégias de *Moving Average* (MA), *Low-Pass Filter - First Ordem* (LPF), *Low-Pass Filter - Second Ordem* (LPF-2) e *Exponential Moving Average* (EMA), para controle do amortecimento da potência ativa injetada na rede. Como resultado, a técnica LPF-2 despreendeu menor energia em sua operação, sendo 1,5% mais econômico que o método MA e 3% mais econômico que o método LPF, em termos de energia, significou 4,5 Wh e 9 Wh, respectivamente. No trabalho de Diaz (2019), foi realizada uma simulação utilizando um dia de alta variabilidade, o objetivo do estudo foi gerar um perfil da potência FV injetada na rede respeitando a rampa máxima de 10%/min; as rampas de potência superiores à essa taxa de rampa foram mitigadas com a inserção do sistema de armazenamento elétrico (SAE). A Figura 10, ilustra um dos resultados obtidos, onde é possível ver a evolução da potência do gerador fotovoltaico desenhada na cor azul (P_{FV}), e a potência simulada injetada na rede P_{rede} , demarcada na cor vermelha.

Figura 10 – Representação da potência simulada injetada na rede mediante a estratégia de suavização.



Fonte: (DIAZ, 2019)

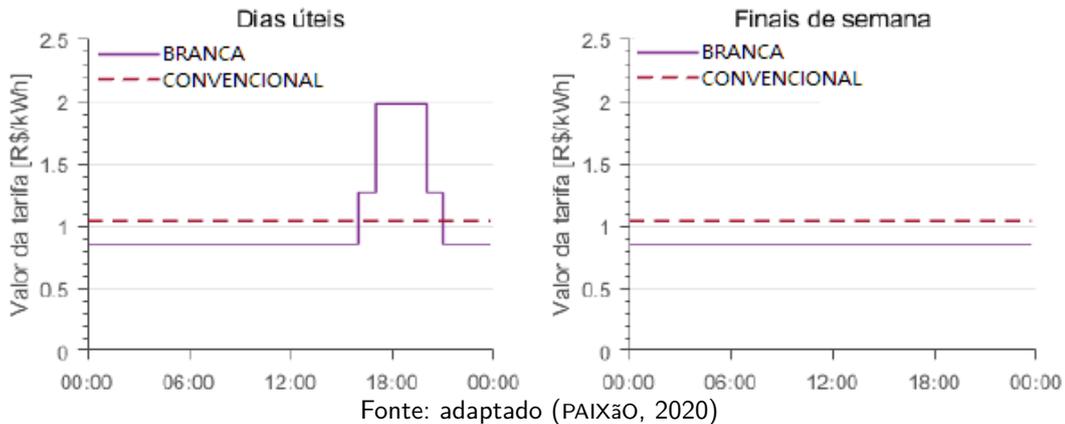
Segundo Diaz (2019), a utilização da bateria atingiu 66% da potência máxima do banco, correspondendo a 524 W em capacidade energética, obteve-se um valor de 64 kWh. Ao correlacionar a capacidade energética com a potência nominal do inversor, seria equivalente à 3 minutos de funcionamento pleno do inversor. Um sistema de armazenamento centralizado com capacidade instalada/carga de 16 MW/71 MWh foi inserido para amenizar as flutuações de potência em um sistema experimental realizado na China, com isso as flutuações de potência positivas foram suavizadas pelo modo de carregamento da acumulador (LI; YAO; HUI, 2016). Além disso, estratégias de controle de baterias para alcançar a redução de perda de rendimento dos inversores, foram investigadas por Parra et al. (2016).

2.2.2.2 Armazenamento como aliado à tarifa branca

O enquadramento tarifário é uma modalidade de tarifação restrita a clientes especiais, através dela um consumidor de energia elétrica pode ajustar o seu perfil de consumo em estruturas tarifárias, tais como: tarifa convencional, tarifa verde ou tarifa azul (PROCEL, 2011). A Resolução Normativa 733/2016 da ANEEL estabelecida em setembro de 2016, facultou a todos os consumidores do grupo B e a consumidores específicos do grupo A, a migrar para a modalidade de tarifação variável, denominada esta de tarifa branca (ANEEL, 2016). A tarifa branca é configurada em três faixas horárias, definidas como: hora de ponta (Das 17h30 às 20h30), hora intermediária (Das 16h30 às 17h29 e das 20h31 às 21h30) e hora fora ponta

(Das 22h00 às 15h59 em fins de semana e feriados nacionais) uma ilustração gráfica do valor tarifário foi extraído do trabalho de Paixão (2020), na Figura 11, apresenta-se o valor do kWh para cada posto horário e dias específicos.

Figura 11 – Comparação entre a estrutura de tarifação branca e convencional.



Ainda nesse contexto, a tarifa branca surge como uma forma de mitigar a alta demanda no momento de sobrecarga do sistema de distribuição, estimulando a UC a planejar a utilização da carga em períodos menos críticos do sistema elétrico. Em seu artigo, Finotti, Almeida e Zilles (2018) estudou a integração de um banco de baterias como um estímulo para o consumidor adotar a tarifa branca, calculou-se então, o custo anual da energia elétrica (CAEE) para demonstrar sua viabilidade financeira frente ao custo do kWh convencional. Já em Paixão (2020), é demonstrado acerca das vantagens do uso de baterias de chumbo-ácido carbono e ferro-lítio para diminuir os custos no momento de ponta diante da opção pela tarifa branca. Técnicas de otimização evidenciando o consumo residencial variável em função da sazonalidade do clima é realizado por Zhao, Hernando-Gil e Wu (2018), em laboratórios de microrredes.

2.2.2.3 Armazenamento para controle de tensão

No Brasil, a tensão em regime permanente deve ser mantida de acordo com os limites estabelecidos na Tabela 13, ao considerar a tensão de base monofásica em 220 V, o valor nominal não deve ultrapassar 1,059 P.U., esse argumento obriga que os acessantes à rede por meio da GD tolerem os limite operacionais. No Reino Unido foi iniciado o projeto de *customer led network revolution* (CLNR), que significa a revolução da rede conduzida pelo cliente, essa ação foi financiada pelo órgão regulador do Reino Unido (WANG et al., 2014). Além das variadas

aplicações do armazenamento elétrico já citadas no decorrer deste trabalho, a utilidade desse dispositivo também está em grande ascensão para as aplicações remetidas à regulação de tensão, no campo de redes de média e baixa tensão.

Dada a possibilidade de controlar a tensão por injeção de potência reativa em ambiente de média tensão, o armazenamento também surge como uma boa proposta. Em Hill et al. (2012), o autor testou o suporte de energia reativa para regulação de tensão utilizando o controle de tempo real para uma capacidade de armazenamento de 1 MW/1,5 MWh em uma rede de alta tensão. Em Devlin et al. (2016), o armazenamento foi aplicado para mitigação do impacto negativo da alta incidência da energia eólica aliado a alta intermitência de produção de potência, neste trabalho o autor preocupou-se em identificar um novo emprego para o armazenamento, o cenário adotado aplicou um SAE de aproximadamente 100 MWh. No contexto de sistemas de alta potência, operacionalizados em alta tensão, o trabalho de Farhadi e Mohammed (2016) relatou os desafios sobre a integração de grandes sistemas de baterias para o controle tanto da tensão como da também da frequência.

Embora os relatos da literatura sejam direcionados para sistemas fotovoltaicos de alta potência e conectados ao sistema elétrico de média e alta tensão, as inconsistências observadas em pequenos geradores fotovoltaicos conectados à rede de baixa tensão incrementam ainda mais o desafio na mitigação do problema, mesmo com os grandes avanços tecnológicos nos últimos anos. No entanto, alguns trabalhos vislumbram a importância de novas rotinas de estudo e planejamento das redes de distribuição para integração dos SAE (SABOORI et al., 2017) (TORRES et al., 2021). Provavelmente, esse artifício pode ser oportuno, quando comparados as intervenções na rede elétrica para o melhoramento da qualidade da tensão de fornecimento.

Um outro fator de alavancagem para os SAE são os problemas técnicos encontrados em redes secundária, por exemplo, as construídas a quatro fios e multiterradas, estas são suscetíveis ao surgimento de tensão no neutro, decorrente da penetração aleatória de unidades geradoras fotovoltaicas, nesse sentido, o SAE pode ser utilizado como um agente mitigador deste problema (ALAM; MUTTAQI; SUTANTO, 2015). O surgimento de fenômenos como o desbalanço de cargas e perdas elétricas excessivas nos ramais e trechos da rede de distribuição também são identificados (TORRES; NEGREIROS; TIBA, 2019).

A responsabilidade assumida pelos dispositivos armazenadores de energia, originou um encadeamento de sucessivos estudos no que concerne ao planejamento operacional das redes de distribuição de baixa tensão e o modo de controle do SAE. Em Asensio et al. (2015), é empreendido um planejamento da expansão da rede de distribuição, considerando as condições

de fontes de energias alternativas e o armazenamento. As técnicas de estudos são canalizadas para diversas modalidades de controle e acionamento dos SAE, objetivando a solução específica (DIAZ, 2019) (LEE; HENG, 2017).

2.2.3 Resposta à demanda

Resposta à demanda, ou, GLD, é entendido como o planejamento e a implementação que envolve ações das concessionárias para conscientização dos consumidores, produzindo deslocamentos intencionais na curva de carga. Em síntese, essas medidas englobam algumas metodologias, tais como: gerenciamento de carga, conservação estratégica, eletrificação, geração distribuída e substituição de equipamentos com maior nível de eficiência (BRAGA, 2014).

O GLD permite um uso mais racional dos recursos energéticos, evitando assim que novos investimentos como repotencialização, construção de novas linhas de transmissão, aumento da capacidade de usinas geradoras, acionamento emergencial de usinas termoelétricas por entre outros. Os objetivos do GLD são:

- Melhorar a confiabilidade da rede;
- Reduzir picos de demanda e consumo de energia;
- Deslocamento de carga quando o sistema estiver operando próximo a capacidade de geração;
- Aumento da eficiência energética;
- Gerenciar gastos com energia;
- Favorecer a geração distribuída;
- Proporcionar um maior controle dos equipamentos.

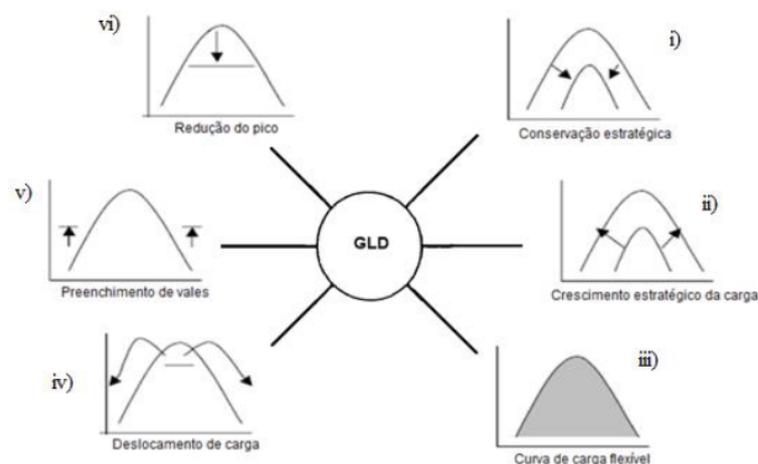
Estas modalidades citadas são facultativas entre a distribuidora e o cliente, porém, uma gama variada de esquemas de preços de energia elétrica pode ser um ponto de alavancagem para o uso da resposta à demanda (KUSAKANA, 2017). As técnicas de resposta à demanda promovem benefícios tanto para o consumidor quanto para a concessionária de energia, do ponto de vista do cliente é proporcionada a redução na fatura de eletricidade, do outro lado, a empresa distribuidora minimiza os investimentos em intervenções de reforço na

rede (KHANNA et al., 2020). Atrelado a todos esses fatos, essa combinação ainda favorece ao meio ambiente, pois essa economia resulta em redução na emissão de gases poluentes. Uma série de potenciais sobre a resposta à demanda foi apresentado mediante um relatório elaborado pelo departamento *Department for Business, Energy and Industrial Strategy*, situado no Reino Unido (FOSTER et al., 2016). Em (KHANNA et al., 2020), o próprio autor argumentou algumas barreiras frente à implantação da resposta à demanda, citadas nesse mesmo relatório e categorizadas pela seguinte ordem:

- Barreiras técnicas;
- Operacionalidade e padronização dos equipamentos;
- Aspectos de segurança dos equipamentos e pessoal;
- Aspectos econômicos;
- Barreiras para regulamentação;
- Adaptação do consumidor;
- Desenvolvimento de novas tecnologias relacionadas à integração ao sistema.

O GLD influencia numa atuação mais confiável e econômica do sistema elétrico, uma vez que a demanda é reduzida significativamente, assim como a retomada de cargas. Em função das características citadas acima, existem seis cenários para o ajuste da curva de carga mostrados na Figura 12 a seguir:

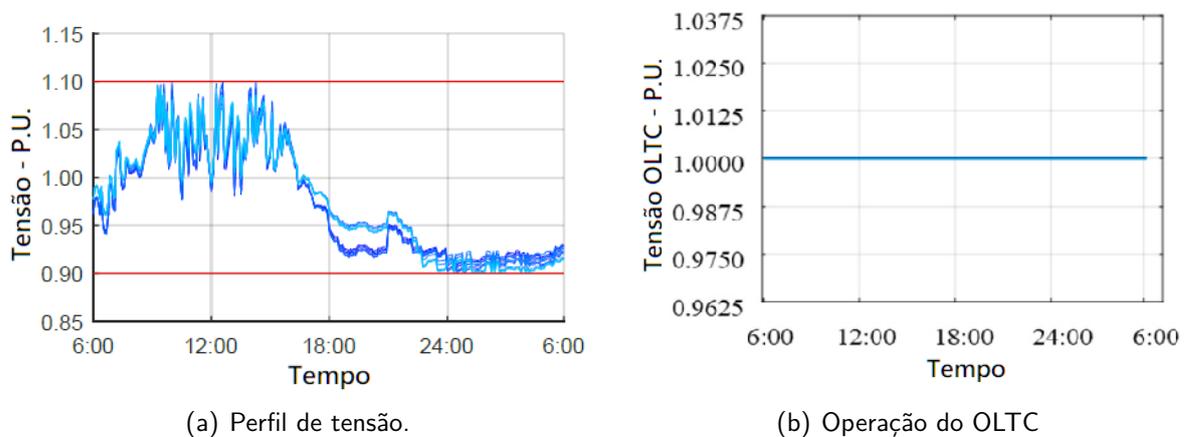
Figura 12 – Cenários de possibilidades de aplicação da GLD.



Fonte: adaptado (ABOBOREIRA; CRUZ, 2016).

Diante das possibilidades de flexibilização de dispositivos elétricos que compõem um cenário residencial, por exemplo, recomenda-se a implementação de um cronograma de acionamento, obtendo uma forma mais barata no aproveitamento instantâneo do recurso energético disponível. Em Xie et al. (2019), foi aplicado um método de *Voltage Ranking Search Algorithm (VRSA)*, para coordenação do OLTC, intuindo na diminuição operacional do equipamento. A Figura 13.a apresenta o perfil da tensão a partir da aplicação do método VRSA, já a Figura 13.b ilustra o comportamento do OLTC.

Figura 13 – Representação da intermitência solar e da flutuação de potência.



Fonte: adaptado (XIE et al., 2019).

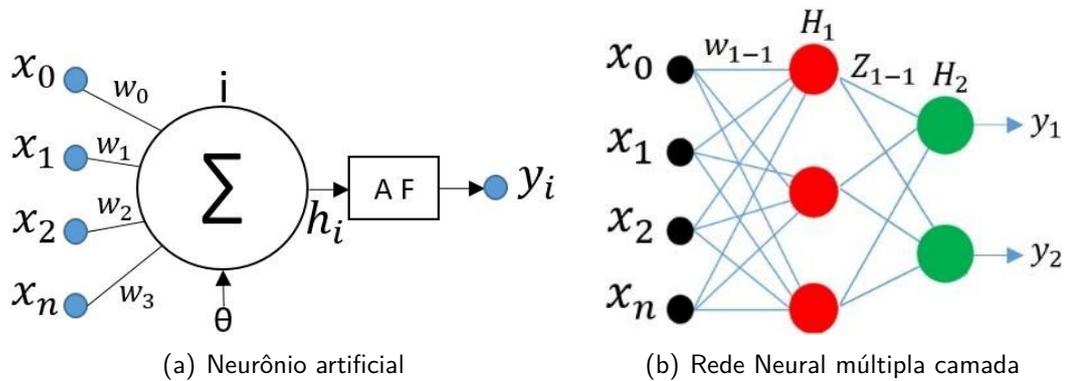
Conforme demonstrado graficamente, o perfil da tensão se enquadrou dentro dos limites mínimos e máximos, o OLTC praticamente permaneceu inerte durante o período analisado. Já no trabalho de Khanna et al. (2020), foi utilizado uma técnica de otimização em dois estágios considerando a resposta à demanda implicitamente em função do preço. Neste mesmo trabalho, o autor utilizou uma vasta quantidade de dispositivos modernos e tecnologias interligados a medidores inteligentes, por fim foi proposto um estudo de caso e verificado que através das simulações, ocorreu uma redução equivalente de 7,1 ktons/ano de emissão de CO_2 .

2.2.4 Previsão do recurso solar

Uma Rede Neural Artificial (RNA) é uma ferramenta matemática inspirada no funcionamento de um cérebro humano (HIPPERT; PEDREIRA; SOUZA, 2001)(ASSAS et al., 2014). A representação de uma unidade básica de um neurônio pode ser visualizada na Figura 14.a. Em aplicações complexas há a necessidade de se organizar os neurônios em *Multilayer Perceptron (MLP)* a fim de obter um melhor desempenho na resposta de saída, ilustra-se na Figura 14.b

uma rede neural com dupla camada.

Figura 14 – Esquemático de um neurônio artificial.



(a) Neurônio artificial

(b) Rede Neural múltipla camadas

Fonte: O autor, 2021.

Cada neurônio equivale a uma unidade de processamento. A concepção de uma rede neural compreende-se pela interligação de vários neurônios, esta interligação é ponderada por um peso (w), o somatório do sinal de entrada pode ser influenciado pelo fator de ajuste (θ), parâmetro interno do neurônio. O nível de atividade (h_i) é equacionado na expressão 2.12, tomando a Figura 14.a como representação.

$$h_i = \sum_{k=0}^n w_{ik}x_k - \theta \quad (2.12)$$

A saída do neurônio geralmente é combinada com *activation function* (AF) gerando um valor efetivo (y_i). Comumente as funções podem ser do tipo degrau binário (*step*) linear, sigmoide, tangente hiperbólica, dentre outras. Sendo λ a função de ativação para a saída do neurônio, a combinação resultante pode ser finalmente escrita pela equação 2.13.

$$y_i = \theta h_i \quad (2.13)$$

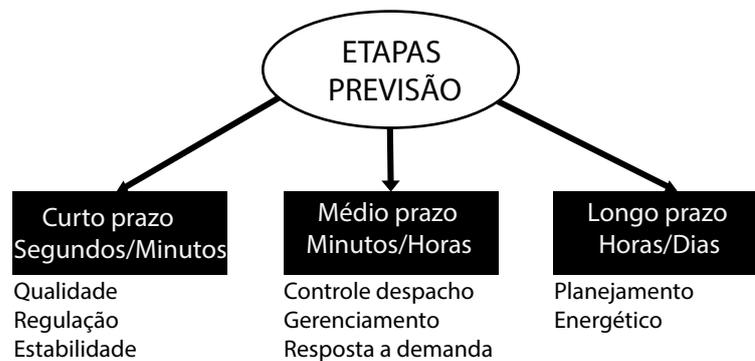
A implementação de uma RNA depende de uma base de informações robusta e confiável para a execução do algoritmo de inteligência artificial, para que a relação entre a entrada e a saída seja a mais confiável possível. Para isso o acervo de dados deve ser separado em estágio de treinamento e validação. Para fins práticos, as redes neurais precisam, na maioria das vezes, de múltiplas camadas de processamento (GHANBARZADEH et al., 2009).

Em aplicações de energia solar, a RNA é uma grande aliada para estabelecer a previsão do recurso energético em qualquer que seja o horizonte temporal de previsão, quando combinada com modelos matemáticos de estimação de produção de energia elétrica, auxilia

na antecipação de problemas referentes a sobreoferta e o despacho da energia elétrica. Em Sabino (2019) foi desenvolvido um modelo de previsão para irradiação solar global horizontal e temperatura em escala horária para auxiliar a tomada de decisão do ONS um dia a frente. Já Campos Filho (2019), criou uma metodologia composta por algoritmos de previsão da irradiação solar em horizontes temporais de curto prazo, utilizando imagens processadas de uma câmera de baixo custo.

Cabe citar que, a parametrização do sistema predictor deve estar fundamentada na necessidade de aplicação, a seguir na Figura 15, apresentam-se as aplicabilidades das etapas de previsão em função do horizonte temporal, atribuindo as respectivas aplicações junto ao SEP.

Figura 15 – Aplicações da previsão da irradiação solar.



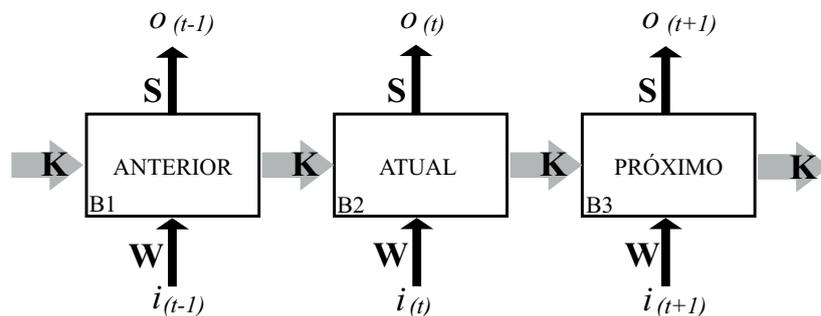
Fonte: adaptado (ALZHARANI et al., 2017b).

O órgão responsável pela gestão da rede de energia se importa com horizonte de previsão de um dia à frente ($h + 24$), intervalados em escala horária, para um dia isso representa uma taxa de uma previsão por hora, quantificando 24 patamares ao dia (VOYANT et al., 2017). O operador do sistema elétrico da Califórnia (CAISO), utiliza duas topologias de previsão: a de um dia à frente e a de uma hora à frente (PELLAND et al., 2013). A previsão de médio prazo se estende de 6 horas à 6 dias, por fim, a previsão de longo prazo considera o intervalo de meses até anos à frente. A modelagem da irradiação solar pode ser separada em três categorias: físico, estatístico e empírico (ALZHARANI et al., 2017b). As ferramentas de previsão são utilizadas para prever um certo comportamento futuro, utilizando como base uma série temporal histórica remanescente (MONTGOMERY; JENNINGS; KULAHCI, 2015). Técnicas aplicadas à previsão da irradiação solar tem sido um assunto muito discutido em diversos institutos de pesquisas. A previsão bem elaborada, ajuda a planejar e operar o sistema elétrico, antecipando a produção FV (ALZHARANI et al., 2017a), com isso, implicando sempre em vantagens

econômicas e operacionais. O problema da previsão da irradiação solar pode ser bem resolvido por metodologias de aprendizado de máquina sobre conjuntos de dados históricos (SHARMA; KAKKAR, 2018).

Com o avanço da computação matemática e as necessidades de aplicações mais exigentes, surgiram novos modelos de redes neurais, a rede neural recorrente é uma delas. Uma rede neural recorrente tem como característica a realimentação própria. Para séries temporais bastante dinâmicas, as redes *Long Short Term Memory* (LSTM), apresentam-se com elevada representatividade em termos de eficácia (WANG et al., 2018). No trabalho proposto por Wang et al. (2018), é relatado sobre os pontos vantajosos da LSTM. Em Vassalli (2018) é feito um detalhamento sobre toda a operacionalidade da rede LSTM. Aplicações específicas da LSTM refletidas à produção de potência a partir de sistemas fotovoltaicos, foram propostas por Abdel-Nasser e Mahmoud (2019). Uma simples estruturação gráfica deste tipo de rede é apresentada pela Figura 16.

Figura 16 – Fluxograma operacional de uma rede neural recorrente - RNN.



Fonte: O autor, 2021.

Os parâmetros de entrada são introduzidos a cada passo de tempo, na Figura 16, a sequência de entrada é cadenciada pelo tempo anterior ($i_{(t-1)}$), tempo atual ($i_{(t)}$) e o tempo previsto no futuro ($i_{(t+1)}$); matematicamente simbolizada por um vetor. As informações passadas na entrada são ponderadas por um multiplicador denotado por W . O valor de saída $O_{(t)}$ sempre levará em consideração a informação do estágio anterior K e o valor do peso multiplicador S . Considerando os estágios da Figura 16 e sendo B1 o resultado do processamento no tempo anterior $O_{(t-1)}$, a etapa atual B2 é matematicamente expressada por 2.14.

$$B2 = i_{(t)}W + KB1 \quad (2.14)$$

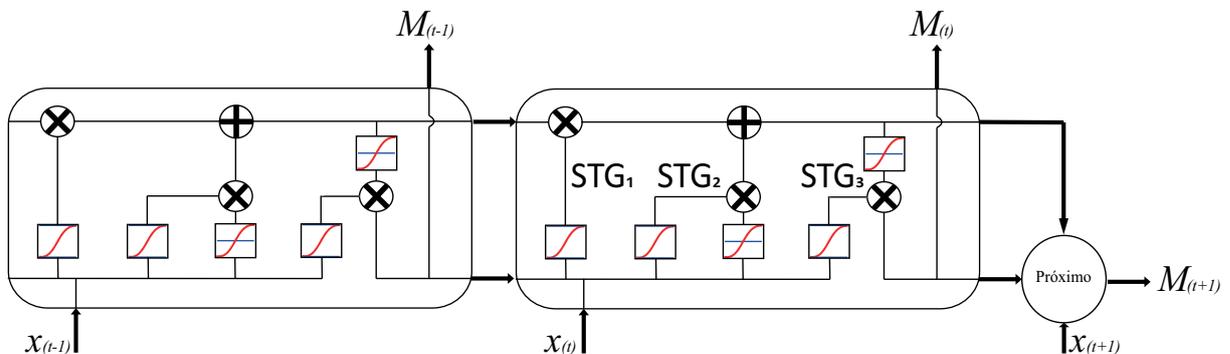
A *Long Short Term Memory* é um tipo de aprendizagem profunda que utiliza camadas recorrentes para aprender e lembrar da informação após as interações. A saída utiliza funções

de ativação (σ) e constantes de tendências (c) para delimitar os resultados, considerando este parâmetro, a saída $O_{(t)}$ no estágio atual B2 é determinada por 2.15.

$$O_{(t)} = \sigma(SB2 + c) \quad (2.15)$$

Esta recorrência é responsável por introduzir uma noção de tempo ou sequência nos modelos. Com isso, é possível dizer que a LSTM sofre influência não apenas da entrada atual $x_{(t)}$, mas também das entradas anteriores $x_{(t-\tau)}$, configurando uma espécie de memória. A exposição de uma rede LSTM desdobrada no tempo a partir de 3 entradas é demonstrada pela Figura 17.

Figura 17 – Estrutura de uma rede neural LSTM.



Fonte: Adaptado (OLAH, 2015).

A partir da saída antecedente informada pela tempo anterior visualizada por M_{t-1} , é possível utilizar esta informação no processamento atual da rede neural através do (STG_1), combinando com a informação de entrada no tempo atual (X_t). A linha superior apresentada na estrutura da rede serve para armazenar a informação, mas quem vai decidir se ela será útil é operador de multiplicação situado na parte superior do lado direito da célula estrutural, essa operação é denominada de *forget gate* e está condicionada a uma função de limitação, como por exemplo, uma função sigmoide. Geralmente quando a função sigmoide apresenta valor "0", a informação pode ser deletada.

No STG_2 , configura o procedimento chamado de *input gate*, simbolizado pelo símbolo da soma, nele é atribuído a possibilidade de alterar e adicionar a informação na memória, é ressaltado também que a informação é condicionada pelas funções *sigmoid* ou tangente hiperbólica, em geral após passar por essas funções é criado um conjunto de valores a serem propagados para os próximos estágios. O STG_3 , efetiva o valor real da saída da rede neural LSTM, associado pela variável $M_{(t)}$. Esse último estágio é denominado de *output gate*. Uma

rede neural LSTM tende a se desdobrar em vários neurônios e camadas, pois de certa forma essa configuração é empregada em problemas complexos. Portanto, para auxiliar o gerenciamento de operação, principalmente no caso de usinas fotovoltaicas, entre outros fatores. Necessita-se de pesquisas que permitam conhecer a fundo o recurso solar disponível, ainda mais no cenário de curto e médio prazo.

O trabalho de Coelho (2016), realizou a previsão da radiação de cinco cidades do Brasil e propôs métodos como: Regressão Polinomial, Ajuste de curvas com a linearização de equações não lineares e Regressão Linear por Mínimos Quadrados utilizando dados como: irradiação média mensal e índice de claridade, obtendo *Root Mean Square Error* (RMSE) abaixo de 5% utilizando modelo linear para radiação solar global e RMSE abaixo de 8% utilizando modelo polinomial para radiação solar difusa.

Já Capo (2018), abordou um modelo de RNA para a previsão de 3 horas à frente da radiação solar global, onde foi desenvolvida uma rede neural MLP. Os dados foram espaçados em 5 minutos e divididos em: 70% treino, 15% validação e 15% teste. Foram utilizadas as seguintes variáveis: irradiação, velocidade do vento, umidade, e horário. Os resultados encontrados mostraram um erro de 2,38% para previsão média anual e RMSE acima de 79 W/m².

Deb et al. (2017), elencou os modelos em: *Autoregressive Integrated Moving Average* (ARIMA), RNA, Lógica Fuzzy, Média Móvel, *Support Vector Machine* (SVM) e Híbridos, para previsão da irradiação e demanda elétrica de uma localidade, de minutos à meses. Os resultados encontrados são avaliados através da métrica *Mean Absolute Percentage Error* (MAPE) obtendo valores abaixo de 1% ao utilizar o método SVM.

Enquanto Kim, Jung e Sim (2019), comparou os modelos *Random Forest Regression* (RFR), *Support Vector Machine* (SVR), RNA e *K-Nearest Neighbors* (K-NN), ao utilizar como variáveis independentes: direção do vento, umidade, temperatura, velocidade do vento, tipo do céu (claro, nublado, chuvoso), elevação da cidade, radiação e horário, obtendo os melhores resultados para o RFR com R^2 de 97%.

Abdel-Nasser e Mahmoud (2019) comparou quatro modelos: *Multiple Linear Regression* (MLR), *Bagged Regression Trees* (BRT), *Neural Network* (NN) e LSTM para previsão da potência dos painéis fotovoltaicos. A LSTM qualificou-se com o melhor resultado, atingindo um RMSE de 82 W.

O trabalho de Alzharani et al. (2017b) comparou os modelos RNA, SVR e LSTM para previsão da irradiação solar, obtendo melhor resultado ao utilizar um modelo de LSTM com

2 camadas ocultas e 35 neurônios, mantendo o RMSE de 0,086 W/m².

Ao comparar as técnicas LSTM, RNA e *Gradient Boosting Regression* (GBR), Srivastava e Lessmann (2018) realizou a previsão da irradiação solar em várias regiões da Austrália, Espanha, EUA, Áustria, Alemanha e França para diversificar os dados ao máximo. Obtendo em quase todas as localidades o destaque para o modelo LSTM, com RMSE abaixo de 30 W/m².

A proposta de Wang et al. (2018), foi comparar alguns modelos utilizando *Convolutional Neural Network* (CNN), LSTM, Modelo Híbrido e ARIMA para dias ensolarados, nublados, parcialmente nublados e chuvosos, contemplando duas regiões distintas. Para previsão da irradiação solar foram utilizados os dados brutos, aplicando a esses a transformada Wavelet para estratificação das características dos sinais de irradiação. O modelo Híbrido (CNN + LSTM) utilizando o segundo nível da transformada Wavelet, enquadrou o melhor resultado, RMSE próximo de 37 W/m² para dias de céu claro e RMSE de 140 W/m² para dias chuvosos.

Por fim, Sorkun, Incel e Paoli (2020) compararam os modelos LSTM, RNA e *Auto-regressive Moving Average* (ARMA) para a previsão da irradiação solar. Dentre os modelos propostos, o que obteve a melhor métrica foi o LSTM multivariável, obtendo o *Normalized Root Mean Squared Error* (NRMSE) de 0,18 W/m².

3 MATERIAIS E MÉTODOS

A metodologia adotada neste trabalho trata da mitigação dos problemas encontrados em sistemas de baixa tensão. Os dados utilizados nessa pesquisa foram providenciados em um ambiente experimental, envolvendo os seguintes componentes: a rede de distribuição, sistema fotovoltaico experimental de 5 kWp, sensores climatológicos e elétricos, e o ambiente computacional. As próximas subseções deste capítulo, descrevem os materiais e métodos empregados para a elaboração da pesquisa.

A metodologia foi dividida em dois passos, a primeira fase investigou o perfil da tensão no ponto de acoplamento entre a UC, rede e o gerador fotovoltaico, sob condição de irradiação plena, ou seja, em céu claro. Feito isso, foi elaborada uma combinação de rotinas para a realização do estudo de desempenho da rede de distribuição, buscando interpretar as ocorrências das sobretensões. Após a observação dos eventos, foram apresentadas as medidas para resolução do problema. É importante lembrar que nessa etapa, os resultados restringiu-se a condição determinística, onde não há interferência das variáveis climatológicas como por exemplo, passagens de nuvens.

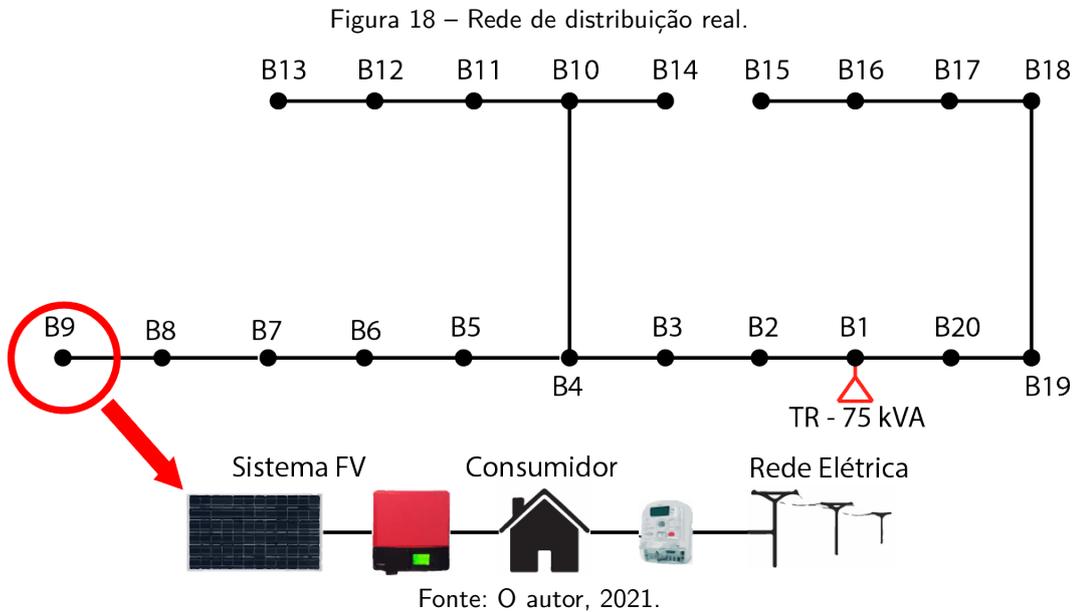
A segunda proposta da metodologia realizou as simulações comparando-as aos quatro perfis típicos da irradiação solar: céu claro, céu nublado, baixa variabilidade e alta variabilidade. Para essas configurações, foi analisado o comportamento da tensão, principalmente em condições de alta e baixa intermitência da irradiação solar. A solução mitigadora foi pensada na conjugação de um sistema de baterias acionado por uma sistema previsor. A simulação do fluxo de potência foi realizada no *software OpenDSS*, utilizando os parâmetros de entradas provenientes das etapas antecedentes, compondo os perfis de irradiação solar e temperatura de operação do arranjo fotovoltaico. Ao final, confrontou-se o perfil da tensão com o limite de tolerância.

3.1 MATERIAIS

3.1.1 Rede de distribuição real

Representar um sistema de distribuição em BT requer uma tarefa bastante complexa, exigindo um alto grau de modelagem de todos os componentes, além de maior exigência computacional. Muitos dos estudos encontrados na literatura baseiam-se frequentemente nos

clássicos sistemas testes *IEEE*, onde estes, muitas vezes não oferecem uma representação dos dados específicos e necessários para verificação dos resultados. Nesta seção foram levantadas as informações do circuito de distribuição real, a ser utilizado nas simulações. Uma ilustração é apresentada na Figura 18 a seguir.



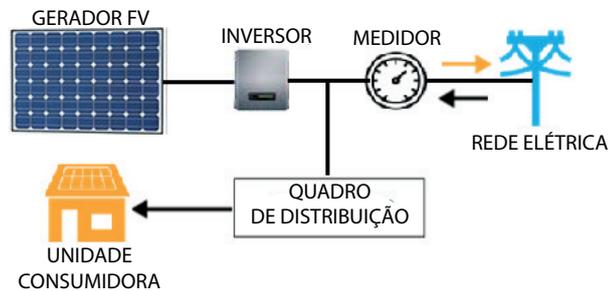
De acordo com a Figura 18, os condutores do circuito foram modelados levando em consideração a disposição e geometria dos postes, características reais dos cabos e espaçamento entre as barras (todas levantadas em campo); como todo o circuito se trata de uma rede de distribuição convencional, dados com relação ao espaçamento entre as fases e extensão do ramal de conexão estão detalhados em (ED-AL, 2014). Assim, foram definidas as matrizes admitâncias nodais, a partir das informações de suas impedâncias sequenciais, resistência e reatância. A parametrização das barras e trechos de rede foram declaradas em uma das rotinas (Elementos *line* e *linecode*) do script principal do código.

3.1.2 Sistema fotovoltaico experimental

O SFVCR utilizado pertence a este mesmo alimentador, exposto pela Figura 18. A unidade geradora está integrada a uma residência monofásica, situada no telhado com inclinação de 6 graus e totalmente orientada para o norte ($\Phi = 0^\circ$). A configuração do arranjo FV é de 19 painéis, totalizando 5100 Wp de capacidade instalada, fornecendo potência à rede local através de um inversor de 5000 W nominais. Logo abaixo, Figura 19, apresenta as possibilidades de

transição do fluxo de potência do sistema fotovoltaico.

Figura 19 – Composição dos elementos do sistema fotovoltaico experimental.



Fonte: O autor, 2021.

Estrategicamente, o sistema real foi inserido na barra 09, em fim de rede. Este cenário foi viabilizado devido ao fácil acesso as unidades consumidoras adjacentes à UC principal, possibilitando realizar medições elétricas de curto à médio prazo de tempo. Uma imagem real do sistema fotovoltaico experimental, dos dispositivos e sensores climatológicos estão na Figura 20.

Figura 20 – Sistema fotovoltaico experimental e estação meteorológica.



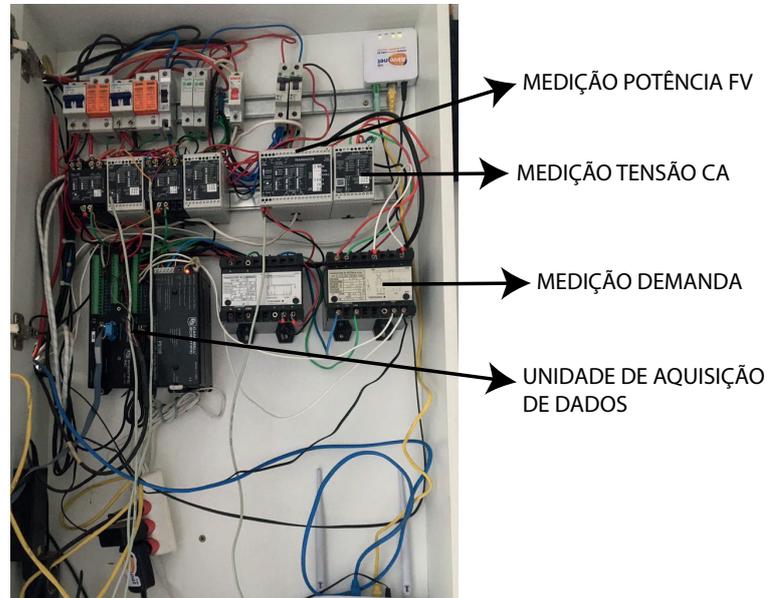
Fonte: O autor, 2021.

3.1.3 Instrumentação e base de dados

A etapa de instrumentação contou com a instalação dos seguintes sensores: irradiação solar, posicionado junto ao SFVCR experimental, sensor de temperatura ambiente e temperatura operacional do módulo FV, potência injetada na rede elétrica, demanda local da residência e tensão no ponto de acoplamento comum (PAC). A Figura 21 e a Tabela 3, contemplam a

imagem real da disposição dos sensores elétricos, evidenciando as variáveis específicas utilizadas no projeto, com os respectivos valores de calibração e tipos de sinais de saída.

Figura 21 – Disposição real dos transdutores de sinais utilizados no monitoramento das variáveis elétricas.



Fonte: O autor, 2021.

Tabela 3 – Especificação dos sensores.

Sensor	Grandeza	Referência	Calibração	Saída (V - mV)
Solarímetro	Irradiação Solar	Licor	74,0740	0 a 25 mV
Wattímetro 1	Potência FV	Secon	$-3,5899x + 9000$	0 a 5 V
Wattímetro 2	Demanda	Secon	0,969	0 a 5 V
Voltímetro	Tensão PAC	Secon	0,05	0 a 5 V
Termopar 1	Temperatura Ambiente	Campbell	0,78	0 a 25 mV
Termopar 2	Temperatura Módulo	LM35	0,1	0 a 5 V

Fonte: O autor, 2021.

Cada sensor foi conectado ao datalogger, equipamento responsável pela coleta e armazenamento dos dados, o equipamento selecionado trata-se do *Scientific Campbell CR1000*. O equipamento foi instalado com a alimentação convencional e com backup de energia para suprimento alternativo. A campanha de medição desta pesquisa deu-se início no dia primeiro de janeiro do ano de 2019 prosseguindo continuamente até o final do ano de 2020, resultando em 639 dias monitorados. A cadência temporal de armazenamento para cada variável foi predefinida a cada 1 minuto, assim para 1 dia coletado, têm-se 1.440 registros por minuto para cada variável, dessa forma foram armazenados pouco mais de 920 mil registros por variável.

3.1.4 Ambiente de simulação - OpenDSS

O programa *OpenDSS* é um software livre, desenvolvido pela *Electric Power Research Institute* (EPRI) para análise e estudos específicos em sistemas elétricos de potência. O circuito de distribuição e os componentes de rede, foram modelados diretamente através dos comandos específicos, além disso, a interface de comunicação pode habilitar o *OpenDSS* para a integração com diversos programas como *Python*, *MatLab* e pacote *Microsoft Office*.

3.2 INTERAÇÃO DE UM SFVCR COM A TENSÃO DE FORNECIMENTO.

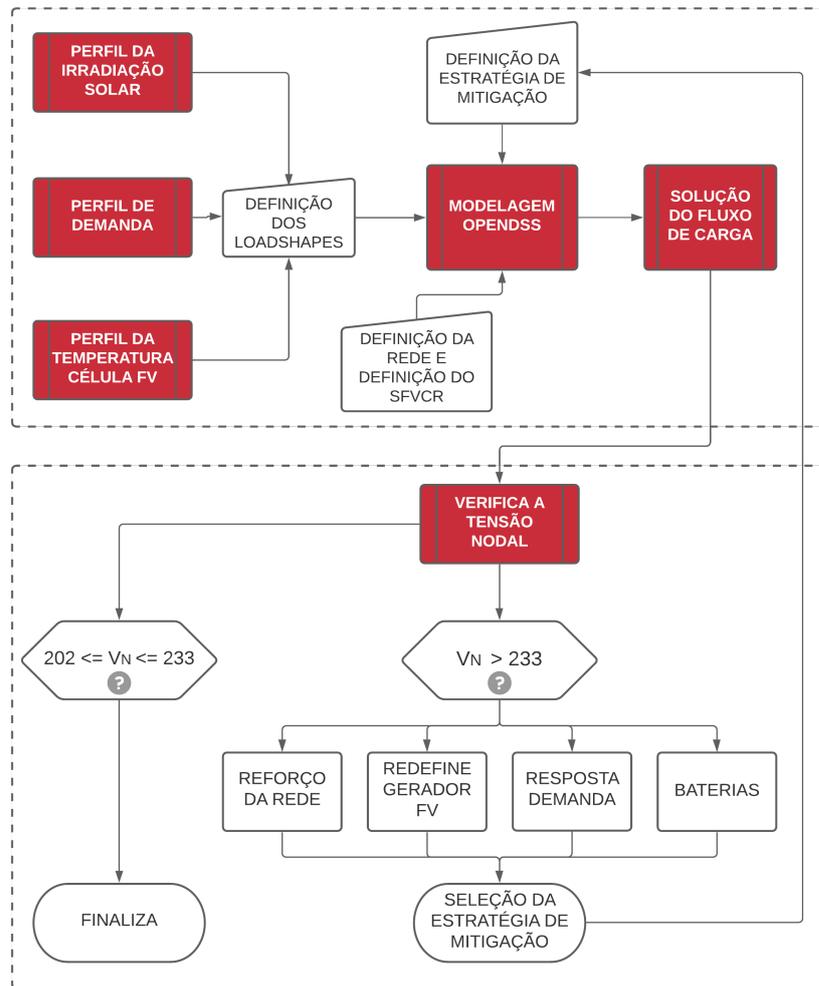
A resolução 482/2012 ANEEL permite o autoconsumo remoto, incentivando que uma UC produza mais energia elétrica que o necessário para o consumo local. Baseado nisso, esta seção relata a primeira fase do método proposto nesse trabalho, construído para avaliar o estado da rede elétrica, simulando a inserção pontual dos geradores fotovoltaicos na barra 09 da Figura 18, as simulações obedeceram os tipos de conexão em função da máxima potência admissível citadas na norma 414 da ANEEL e na norma da concessionária local.

3.2.1 Método de estudo para conexão de um SFVCR

Em um sistema fotovoltaico o inversor é dotado por dispositivos de proteção, capazes de interromper a geração para garantir a integridade no ponto de fornecimento da UC. A parada indesejada do gerador fotovoltaico implica em diminuição da eficiência e maiores custos operacionais, elevando o preço da energia produzida. Todas essas desvantagens citadas são remetidas ao consumidor, que opta pelo emprego dessa tecnologia, para justamente obter o máximo do recurso energético com o maior desempenho possível.

Baseado nesses argumentos, o método proposto buscou o fornecimento dos resultados do estado da rede elétrica, revelando o perfil de tensão tanto no ponto de fornecimento à UC, como ao longo das barras do sistema. Posteriormente, um conjunto de soluções mitigadoras foram apresentadas com o intuito de intervir na UC ou no próprio sistema elétrico. O método foi testado no alimentador de distribuição citado na seção 3.1.1. A seguir, o fluxograma ilustrado na Figura 22, contempla o planejamento de cada etapa pertencente ao método proposto.

Figura 22 – Fluxograma para análise da viabilidade técnica em redes de distribuição considerando a inserção de SFVCR's.



Fonte: O autor, 2021.

O método se dividiu em dois grandes blocos, o primeiro bloco tratou as condições de entradas. Os *Loadshapes* contemplaram o perfil da irradiação solar, temperatura da célula e perfil do carregamento em escala temporal. Ainda no bloco inicial, foi realizada a modelagem da rede, características dos condutores, quantidade dos consumidores, tipos de ligação e equipamentos, como o transformador de potência, feito isso, os elementos foram programados em ambiente computacional. Essa etapa foi finalizada com a solução do fluxo de potência, executada no modo série temporal (*Time-Series*).

O segundo bloco realizou a comparação do valor calculado com o limite crítico estabelecido pela resolução normativa, visualizados na Tabela 1, após isso, dispõe-se as modalidades empregadas para a mitigação do problema. Na etapa de comparação, permanecendo os valores dentro dos limites de operação, o processo se encerra, por outro lado, se os limites de tensão excederem o limite crítico, propõem-se medidas mitigatórias para regulação da tensão

no ponto de fornecimento à UC. As estratégias de mitigação podem variar conforme sua aplicação, podendo ir de uma solução mais simples até uma mais complexa. As ações de reforço de rede e redefinição do SFVCR são ações factíveis, geralmente é a primeira atitude a ser tomada. Apesar de simples, essa ação apresenta grandes desvantagens acarretando, na maioria das vezes, a diminuição da capacidade de hospedagem de novos sistemas fotovoltaicos. Já a resposta à demanda e o armazenamento são soluções que possuem como desvantagem a complexidade de implementação, porém otimizam a capacidade de hospedagem de SFVCR na rede elétrica e maximização da produção de eletricidade.

O método proposto favoreceu à integração cautelosa do sistema fotovoltaico na rede. Mesmo o inversor sendo capaz de se desconectar da rede por motivos de má qualidade no fornecimento de energia elétrica, a ocorrência de outros problemas como ineficiência do sistema, danos aos equipamentos elétricos e inviabilidade financeira do projeto, também são fatores preocupantes e por hora não podem ser evitados através do desligamento do SFVCR.

3.2.2 Modelagem da rede de distribuição

A tensão de base do sistema adotada para a modelagem foi de 380 V trifásico e 220 V monofásico, os condutores foram dispostos em configuração aérea, fornecendo potência a quatro fios para 202 consumidores residenciais, alocados nas 20 barras do sistema, sendo 189 ligados em circuito monofásico e os demais ligados em circuito trifásico. A subestação de alimentação possui 75 kVA de potência nominal atendida em média tensão (13.8 kV), a conexão do circuito secundário ao transformador foi parametrizada por condutores de 70mm², cujo recomendado por norma (EQUATORIAL, 2019). A Tabela 4 segue com a composição global física e da disposição das linhas e barras em função da distância da rede.

Tabela 4 – Dados elétricos do alimentador real

Linha	Início	Fim	Distância (m)	Linha	Início	Fim	Distância (m)
1	B2	B3	31	11	B12	B13	25
2	B3	B4	34	12	B10	B14	18
3	B4	B5	20	13	B14	B15	17
4	B5	B6	31	14	B2	B20	10
5	B6	B7	32	15	B20	B19	40
6	B7	B8	27	16	B19	B18	32
7	B8	B9	42	17	B18	B17	30
8	B4	B10	40	18	B17	B16	30
9	B10	B11	22	19	B16	B15	20
10	B11	B12	24				

Fonte: O autor, 2021.

As características dos cabos que compõem os trechos do circuito estão evidenciadas na Tabela 5, onde foi possível associar as características elétricas de cada condutor e sua alocação física nos trechos do circuito associado à coluna "Linha" das Tabelas 4 e 5.

Tabela 5 – Especificação dos condutores empregados no alimentador

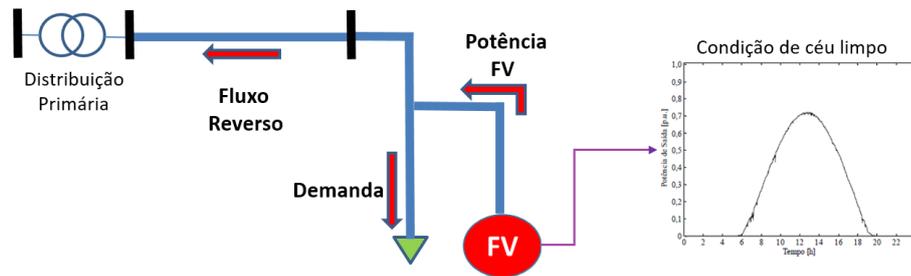
Linha	Condutor	Trecho	Linha	Condutor	Alocação
1	Al70 mm ²	Tronco	11	Al25 mm ²	Meio de linha
2	Al70 mm ²	Tronco	12	Al25 mm ²	Meio de linha
3	Al70 mm ²	Tronco	13	Al25 mm ²	Meio de linha
4	Al50 mm ²	Intermediário	14	Al50 mm ²	Neutro
5	Al25 mm ²	Tronco	15	Al50 mm ²	Fim de linha
6	Al25 mm ²	Tronco	16	Al50 mm ²	Meio de linha
7	Al25 mm ²	Fim de linha	17	Al50 mm ²	Meio de linha
8	Al25 mm ²	Fim de linha	18	Al70 mm ²	Tronco
9	Al50 mm ²	Meio de linha	19	Al70 mm ²	Tronco
10	Al25 mm ²	Tronco			

Fonte: O autor, 2021.

3.2.3 Modelagem do sistema fotovoltaico

A título de representação, a imagem da Figura 23, apresenta um trecho equivalente de rede, onde há um gerador fotovoltaico e uma UC representada pela demanda. A condição de fluxo reverso acontece quando o gerador está em sua máxima potência, por exemplo num dia de céu claro.

Figura 23 – Modelo elétrico de um gerador fotovoltaico conectado à rede.



Fonte: O autor, 2021.

A injeção de potência ativa de um gerador fotovoltaico é dependente também da temperatura, eficiência de conversão e do rastreamento do ponto de máxima potência dos inversores. Em Radatz (RADATZ, 2015), foi apresentado um conjunto de equações combinadas que resultam no modelo matemático utilizado pelo programa *OpenDSS* para estimar a potência elétrica de um SFVCR. A seguir, a expressão 3.1, apresenta o modelo de potência extraído do *software OpenDSS* com intuito de exemplificar a interconexão das variáveis.

$$P_{FV(t)} = P_{mp(base)} \cdot I_{(P.U.)} \cdot I_{(base)} \cdot P_{mp(T)}^{(t)} \quad (3.1)$$

O modelo calcula a potência instantânea produzida pelos painéis fotovoltaicos, onde $P_{mp(base)}$ e $I_{(base)}$ são grandezas de base referentes ao ponto de máxima potência do gerador e irradiância solar, respectivamente. A grandeza $I_{P.U.}$ é a curva normalizada em valor Por Unidade (P.U.) da irradiância solar ao longo de um período e $P_{mp(T)}^{(t)}$ é um fator de correção da potência dos painéis FV pela temperatura. O valor da potência efetivamente injetado numa barra é calculado por 3.2.

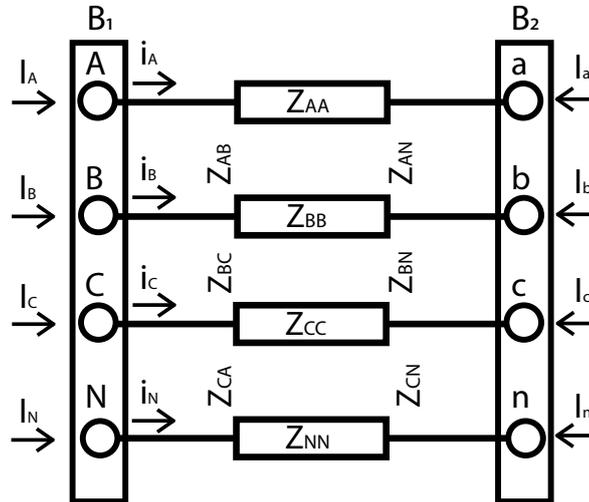
$$P_{CA(t)} = P_{FV(t)} \cdot (\eta \cdot P_{CA(t)}) \quad (3.2)$$

3.2.4 Fluxo de potência

A resolução do fluxo de potência é geralmente formulada em uma matriz de admitância nodal, onde cada elemento dessa matriz está associado a uma admitância, os pontos de junção entre os elementos representados pelos nós ou barras do sistema, são referenciados pelas linhas e colunas da matriz. No *OpenDSS* cada elemento da matriz de admitância nodal está sempre associado a um par de nós (RADATZ; ROCHA, 2018).

A representação expandida de um dos elementos do sistema elétrico, no caso de um trecho a quatro fios, é ilustrada na Figura 24. Destaca-se a interligação do elemento por um par de barras terminais (B_1 e B_2).

Figura 24 – Modelo de uma linha trifásica a quatro fios apoiada em barras terminais.



Fonte: O autor, 2021.

As impedâncias da linha exposta na Figura 24, exprime a componente série do sistema de potência, sendo organizada numa matriz de impedâncias. Aplicando a Lei de Kirchhoff das Tensões em cada ramo do trecho, compondo as expressões das quedas de tensão nos trechos em representação matricial. Na matriz de impedâncias da expressão 3.3, os elementos possuem seus subíndices iguais, ou seja, tomando um elemento genérico Z_{mn} onde $m = n$ representam a impedância própria do trecho, já os elementos onde têm-se $m \neq n$, referem-se as impedâncias de acoplamento entre as linhas.

$$\begin{bmatrix} \Delta V_A \\ \Delta V_B \\ \Delta V_C \\ \Delta V_N \end{bmatrix} = \begin{bmatrix} V_A \\ V_B \\ V_C \\ V_N \end{bmatrix} - \begin{bmatrix} V_a \\ V_b \\ V_c \\ V_n \end{bmatrix} = \begin{bmatrix} Z_{aa} & Z_{ab} & Z_{ac} & Z_{an} \\ Z_{ba} & Z_{bb} & Z_{bc} & Z_{bn} \\ Z_{ca} & Z_{cb} & Z_{cc} & Z_{cn} \\ Z_{na} & Z_{nb} & Z_{nc} & Z_{nn} \end{bmatrix} X \begin{bmatrix} i_a \\ i_b \\ i_c \\ i_n \end{bmatrix} \quad (3.3)$$

Ainda da Figura 24, as correntes injetadas nas linhas são convencionadas pelo sentido das correntes nos ramos, a partir da imagem foi possível estabelecer a relação entre as correntes pela expressão 3.4 abaixo.

$$\begin{bmatrix} I_A \\ I_B \\ I_C \\ I_N \end{bmatrix} = \begin{bmatrix} i_A \\ i_B \\ i_B \\ i_N \end{bmatrix} = - \begin{bmatrix} I_a \\ I_b \\ I_c \\ I_n \end{bmatrix} \quad (3.4)$$

Partindo de todas as considerações, a matriz de admitância representa a relação entre a tensão nodal e a corrente injetada, assim obtêm-se expressão 3.5, sendo a matriz de admitância $[Y] = [Z^{-1}]$.

$$\begin{bmatrix} I_A \\ I_B \\ I_C \\ I_N \\ I_a \\ I_b \\ I_c \\ I_n \end{bmatrix} = [Y] \begin{bmatrix} V_A \\ V_B \\ V_C \\ V_N \\ v_a \\ v_b \\ v_c \\ v_n \end{bmatrix} \quad (3.5)$$

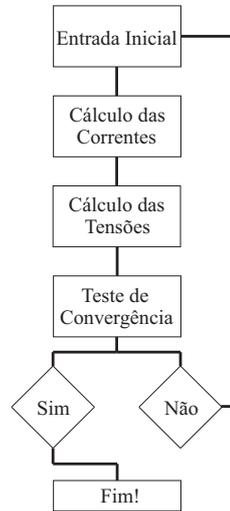
A partir da convenção dos potenciais nas barras terminais e admitindo as correntes injetadas nas respectivas barras, para esse exemplo, a matriz admitância é composta por submatrizes assumindo um tamanho total de 8×8 .

$$[Y] = \begin{bmatrix} Z_{4 \times 4}^{-1} & -Z_{4 \times 4}^{-1} \\ -Z_{4 \times 4}^{-1} & Z_{4 \times 4}^{-1} \end{bmatrix} \quad (3.6)$$

No *OpenDSS* a $[Y]$ é denominada de matriz de admitância nodal primitiva $[Y]_{primitiva}$, ela é fundamental para a construção da matriz de admitância do sistema, como todo elemento possui sua admitância primitiva, cada componente matricial é adicionada à matriz de admitância do sistema $[Y]_{sistema}$. O método iterativo para solucionar o fluxo de potência no *OpenDSS* é denominado de método "*Normal*", seu algoritmo é semelhante ao método *Backward-Forward*,

desempenhando seu papel em redes de distribuição secundária (RADATZ; ROCHA, 2018). O diagrama de blocos da Figura 25, contempla as etapas executadas pelo método "Normal".

Figura 25 – Fluxograma de resolução do fluxo de potência.



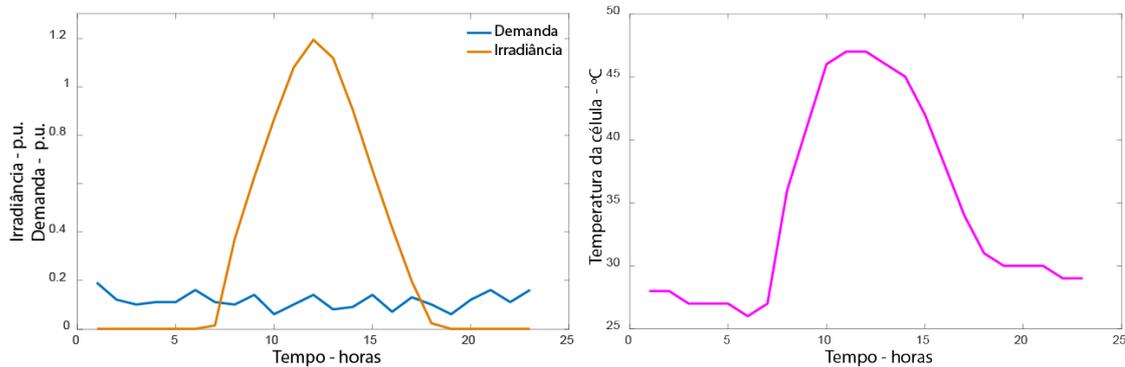
Fonte: O autor, 2021.

A formulação explanada nessa seção é inerente ao funcionamento do *OpenDSS*, a contextualização foi adaptada para melhor entendimento, porém o conteúdo é baseado no descritivo técnico elaborado por Radatz e Rocha (2018).

3.2.5 Cenários de simulação

Todos os dados de entrada para simulação foram provenientes do sistema de aquisição de dados, citado na seção 3.1.3. A simulação foi executada em modo temporal ao longo de um dia, em patamar horário de 24 horas. As simulações foram pautadas em condição de alta irradiância solar permanente (Céu claro) e curva de demanda residencial, conferidas em P.U. na Figura 26 abaixo.

Figura 26 – Perfil de irradiância solar, curva de demanda e temperatura do módulo FV utilizados para simulação.



Fonte: O autor, 2021.

Os dados apresentados na Tabela 4 e Tabela 5, junto com as descrições do alimentador foram utilizados para a montagem do circuito no *OpenDSS*. Os casos de simulação assumiram as topologias de conexões impostas pelos requisitos técnicos de acesso à rede elétrica (ANEEL, 2021b), sendo a conexão monofásica de até 15 kW e a trifásica iniciando em 15 kW até 75 kW. Assim, definiu-se os dois casos de simulação abaixo.

- Caso 1: P_{FV} instalada de 5 kWp por UC;
- Caso 2: P_{FV} instalada de 10 kWp por UC.

Os casos 1 e 2, representam respectivamente 33% e 66% do limite máximo permitido em ligação monofásica. Ao todo foram propostos seis subcasos, três subcasos para cada caso, para simular a penetração massiva gradual na barra 9, essa barra fornece potência para seis UC's monofásicas, então, os níveis de padronização para inserção dos SFVCR's foram definidos pelos seguintes critérios:

- Subcaso 1: 1 UC com SFVCR;
- Subcaso 2: 3 UC's com SFVCR;
- Subcaso 3: 6 UC's com SFVCR.

Na simulação do caso 1, considerou-se de forma gradativa a inserção da GD, mantendo as condições de irradiância e demanda constante (conforme Figura 26). A potência instalada para as unidades de geração fotovoltaica assumidas nos subcasos fixada inicialmente em 5 kWp. De acordo com os três subcasos citados acima, os níveis de penetração foram: 16%, 50% e

100%, respectivamente para os 3 subcasos. O subcaso 3, correspondeu a 41,6% da potência total da subestação de potência, assim como o subcaso 1 esteve apenas em 7% da potência total da subestação. A Tabela abaixo sintetiza a organização para todas as simulações:

Tabela 6 – Subcasos de simulação.

UC's	Subcasos			Casos (P=5kW e P=10kW)
	Subcaso 1	Subcaso 2	Subcaso 3	
75	5 kW e 10 kW	5 kW e 10 kW	5 kW e 10 kW	1 - 2
76		5 kW e 10 kW	5 kW e 10 kW	1 - 2
77		5 kW e 10 kW	5 kW e 10 kW	1 - 2
78			5 kW e 10 kW	1 - 2
79			5 kW e 10 kW	1 - 2
80			5 kW e 10 kW	1 - 2

Fonte: O autor, 2021.

Diante da formatação dos casos, as análises na seção 3.2.1, referiu-se a metodologia para o estudo do desempenho da rede elétrica, diagnosticando o perfil da tensão especificamente junto a UC, sob a ótica de céu claro.

3.3 ESTRATÉGIA PARA MITIGAÇÃO DA SOBRETENSÃO

Os relatos sobre a qualidade da energia elétrica a respeito das sobretensões em pontos próximos aos sistemas fotovoltaicos é um fato observado na literatura (MA et al., 2019)(KOW et al., 2016). A partir dessas evidências, elaborou-se um método capaz de antecipar o estado da rede de distribuição, utilizando a previsão climatológica como padrão de entrada para o sistema de armazenamento. Daqui em diante, serão apresentados os estágios planejados referente à técnica do uso de baterias em modo passivo aplicado na melhoria da qualidade do fornecimento da tensão.

3.3.1 Caracterização das rampas de potência

De início, graças à campanha de medição, foi realizado um amplo estudo buscando quantificar e qualificar as flutuações de potência oriundas da variabilidade do recurso solar. Métodos que abordam estudos a respeito das flutuações de potência podem ser conferidos nas literaturas: (MARCOS et al., 2014) (ALMEIDA, 2017) (DIAZ, 2019) (DE LA PARRA et al., 2018) (GEVORGIAN; BOOTH, 2013); assim, as seções 3.3.1 e 3.3.2 apenas demonstram o problema,

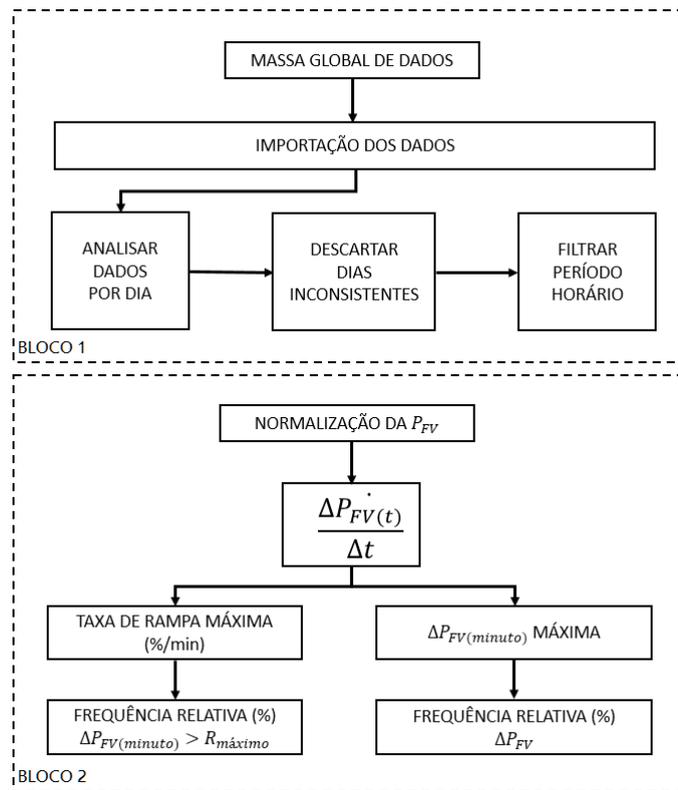
provendo subsídios que justificam o desenvolvimento das etapas subsequentes.

O método descrito para quantificação das rampas é semelhante ao utilizado por Diaz (2019) e Marcos et al. (2014), onde os autores enfatizaram em caráter geral a suavização da potência injetada na rede, citando preocupações com o estado de carga da bateria. Ao pensar nisso, antes de adentrar na metodologia propriamente dita, foi desenvolvido um estudo específico da variabilidade do recurso solar no local do estudo, o método utilizado pode ser visto na Figura 27.

Separado em dois blocos, no bloco 1, foi apresentado o tratamento dos dados, onde os 365 dias do ano de 2020 foram analisados diariamente, durante o período horário de 6 às 18 horas, totalizando 262.800 dados brutos para cada variável. Os dias inconsistentes excluídos referem-se aos momentos que ocorreram por exemplo, falta de energia ou desligamento para manutenção, os dados faltantes representaram 0.54% do conjunto total, ou seja, baixíssima representatividade que venha inviabilizar o estudo.

Após a etapa de descarte, montou-se uma base de dados com os perfis mensais, contendo os dados diários mensais dentro de um período horário das 6 horas às 18 horas. Após o processamento das informações, a base de dados é enviada ao próximo estágio. No bloco 2, contempla-se a metodologia empregada para análise de rampas, citada na revisão bibliográfica (Capítulo 3 seção 2.1.3), onde inicialmente é realizada a normalização da variável potência (P_{FV}) com a grandeza de base, nesse caso, a capacidade instalada do sistema fotovoltaico experimental (5000 W). Feito isso, no próximo passo foi realizado o cálculo da taxa de variação da potência no tempo, essa relação exprime as taxas de rampas em faixa percentual (%/min).

Figura 27 – Etapas para classificação das rampas de potência.



Fonte: O autor, 2021.

O bloco 2 exprime dois resultados importantes, um deles informa a taxa de ocorrência das flutuações de potência que excederam um valor máximo ($\Delta P > R_{m\acute{a}xima}$), essa métrica informa através da frequência o percentual do tempo total da operação do SFVCR que as flutuações de potência excederam a rampa máxima. Neste trabalho, definiu-se a $R_{m\acute{a}xima}$ partindo de 2%/minuto, sendo incrementada até um valor final de 34%/minuto. Cabe ressaltar que o valor de $r_{M\acute{A}X}$ é um atributo bastante particular, para dimensioná-lo é imprescindível estudos prévios relacionado à capacidade de reação que um sistema de distribuição ou transmissão possui quando submetido as inúmeras flutuações de potência advindas do gerador fotovoltaico, garantindo a operação confiável dos indicadores de qualidade. A segunda análise permitiu quantificar a ocorrência das máximas flutuações de potência diária ($\Delta P_{M\acute{A}X}$) ao longo de todo o ano, separando-as em classes, por exemplo: 0 à 10%/min, 10 à 20%/min, e assim por diante.

Uma vez determinadas as flutuações de potência máxima, com o suporte das medições experimentais da demanda, potência do gerador fotovoltaico e tensão no ponto de acoplamento comum (PAC), efetuou-se a tabulação dos dados estruturando-os na mesma base de tempo. Essa ação buscou transparecer a relação entre a rampa de potência ascendente com a elevação

da tensão no ponto de acoplamento, a informação da demanda serve não só para calcular o que está sendo injetado na rede, mas também para explicar os momentos os quais as tensões não responderam de forma ascendente diante da elevada rampa de potência. Além disso, os equipamentos que são fundamentais para a operação da rede como: reguladores de tensão, banco de capacitores, comutadores de tap de transformador, mesmo que não tão próximos dos pontos de fornecimento de tensão, também podem interferir no perfil da tensão de uma UC. No mesmo sentido, a dinâmica repentina de grandes blocos de cargas também podem alterar o perfil de tensão de um alimentador. Diante dessas afirmações, o termo “dinâmica da rede” foi adotado para justificar os eventos onde a flutuação de potência não foi significativa na perturbação da tensão.

3.3.2 Relação entre tensão e a potência injetada

Com o advento da microgeração distribuída, o estudo do fluxo de potência em redes de distribuição tem absorvido grande relevância, forçando ao desenvolvimento de métodos de estudos preliminares, direcionando de forma confiável a inserção da microgeração fotovoltaica. No contexto atual, o estudo do fluxo de potência é frequentemente aplicado em estudos de rede de distribuição primária, consolidando todo o circuito secundário através da unificação das demanda ativa e reativa em uma única barra.

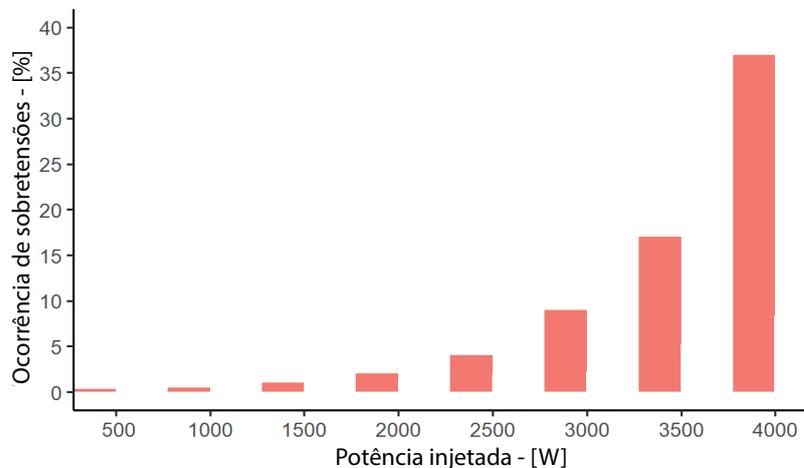
A potência reversa que flui pelo ramal de interligação depende basicamente de duas variáveis, o quanto está sendo produzido (P_{FV}) e o quanto está sendo consumido (P_{DMD}), instantaneamente. Conforme apresentado na seção 2.1.2 do capítulo 3, o perfil de tensão em uma UC pode se elevar acentuadamente com o aumento da intensidade da potência residual, ou seja, injetada na rede (P_{inj}). Com a posse dos dados instantâneos das grandezas (P_{FV}) e da (P_{DMD}), possibilitou-se calcular a (P_{inj}) instantânea utilizando a expressão 3.7.

$$P_{inj} = P_{FV} - P_{DMD} \quad (3.7)$$

Com os dados da (P_{inj}), foi possível correlacionar essas informações com o perfil da tensão, com base nisso, o gráfico apresentado na Figura 28 demonstra as ocorrências de sobretensões restritas à condição de baixo carregamento ($P_{DMD} \ll P_{FV}$), esse artifício funciona como um filtro para a base de dados e isola os momentos que a demanda não impacta na tensão. Em termos numéricos, baseado também pela caracterização real da medição da de-

manda, a janela de P_{DMD} aplicada para relacionar as $V_N > V_{crítica}$ com a P_{inj} foi especificada entre 0 à 400 W, a fim de garantir a característica de baixo carregamento. Outro aspecto que motiva o estudo nas circunstâncias de baixo carregamento da demanda, é a abordagem da própria resolução normativa 482/2012 da ANEEL, mediante o autoconsumo remoto (ANEEL, 2012).

Figura 28 – Frequência de ocorrências da sobretensão em função da potência injetada.



Fonte: O autor, 2021.

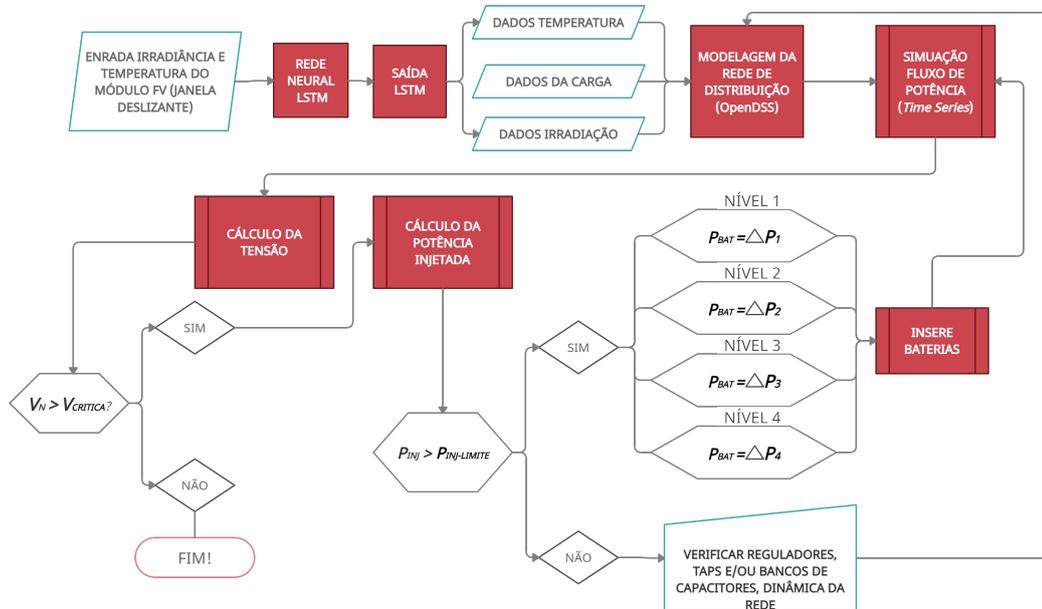
O gráfico da Figura 28 correlaciona a progressão do fluxo de potência reverso com a ocorrência de sobretensões, quantitativamente as ocorrências de sobretensão estão significativamente no patamar de 5%, para uma faixa de carregamento de 50% ($P_{inj} = 2500W$) da capacidade instalada do SFVCR. A importância dessa análise serviu para definir um limite de injeção de potência na rede, sendo esse valor fundamental para o desenvolvimento das etapas futuras. Daqui em diante, a taxa de limitação de injeção de potência está mencionada pela variável $P_{inj-limite}$, o valor definido e aplicado ao longo desse trabalho foi de 50% da capacidade instalada do sistema fotovoltaico, ou seja, $P_{inj-limite} = 2500W$, onde as ocorrências de sobretensão estão limitadas a 5% do tempo total de operação ao longo do ano.

3.3.3 Método proposto

O fluxograma que descreve o percurso das etapas desenvolvidas pelo método proposto pode ser visto na Figura 29. O acionamento do sistema de baterias é condicionado à rede neural artificial LSTM, onde as informações de irradiação solar e temperatura da célula são

encaminhadas antecipadamente, 1 minuto à frente, para a solução do fluxo de potência. Combinada com as condições de demanda, é realizado o cálculo da possível potência que será injetada reversamente no sistema elétrico. O estado operacional da rede de distribuição é estimado antecipadamente, dessa forma, é possível conhecer a tensão nodal. Seguindo adiante, é executada a comparação da tensão calculada com os valores normalizados, e paralelamente verifica se a potência reversa ultrapassa o máximo limite de injeção de potência ($P_{inj-limite}$). Em condições de violação dos valores de referência, é determinado o nível de potência de bateria adequado para se conectar ao sistema elétrico, a fim de desviar o fluxo de potência que seria injetado na rede, minimizando a amplitude da tensão no PAC.

Figura 29 – Método proposto para regulação da tensão de curto prazo.



Fonte: O autor, 2021.

O estágio de inserção das baterias foi configurado para aplicação em multinível, promovendo a flexibilização do SAE. O requisito de potência necessário para cada grupo de armazenamento, baseou-se em intervalos mínimos e máximos de potência, iniciando no valor predefinido da $P_{inj-limite}$. O uso da previsão tem se mostrado como um ótimo aliado para otimização da capacidade de baterias, no artigo de Marcos et al. (2013), foi alcançada uma redução do uso do sistema de armazenamento em pouco mais de 25%, porém, para uma janela de tempo de 1 dia à frente (24 horas) para um planta fotovoltaica de 1,1 MWp. Além disso, outros aspectos que minimizam a requisição de baterias estão relacionado ao planejamento do controle do armazenamento, levando em conta grupos de sistemas fotovoltaicos e ao aumento

da aceitação da taxa de rampas (ALMEIDA, 2017). Nessa metodologia o problema foi abordado de outra forma, quando se trata tanto da questão da janela de previsão, bem como da inserção de baterias junto a UC não somente para armazenar energia elétrica, como também um dispositivo para regulação da sobretensão. Mais adiante, a partir da seção 3.3.4, todos os estágios dos fluxogramas foram abordados de forma mais detalhada.

3.3.4 Previsão da irradiação solar e temperatura do módulo

O passo inicial de um processo de previsão é a seleção das variáveis de entrada. Os métodos mais comuns encontrados na literatura, utilizando modelos de autocorrelação, são viáveis para aplicações em modelos lineares, porém, quando o assunto é voltado para modelos de redes neurais artificiais, essa metodologia pode não ser tão eficiente (SFETSOS; COONICK, 2000). Uma gama de trabalhos relatam o efeito que a climatologia provoca na eficiência de um arranjo fotovoltaico, penalizando quase sempre a geração de energia elétrica. Diante dessa posição, já que o propósito é estabilizar a tensão em horizonte de tempo de curto prazo, a rede neural deve possuir alto desempenho, sendo capaz de prever dias com alta intermitência da irradiação solar, paralelamente o modelo também foi calibrado para prever a temperatura de operação do módulo. A performance da rede neural foi tratada como um ponto de alta relevância nesse estudo, pois uma boa acurácia garante a boa informação da irradiação solar, conseqüentemente, as etapas subsequentes serão mais assertivas.

3.3.4.1 Rede neural recorrente

A rede neural empregada no sistema predictor foi uma RNN, do tipo LSTM, destacando-se pela alta sensibilidade de perceber todo o histórico de processamento ao longo da rede neural, a resposta em função da entrada é alcançada de forma complexa graças ao mapeamento de todo o caminho referente as entradas anteriores, através da alimentação reversa.

A formatação e configuração da rede propriamente dita foi baseada em uma campanha de medição local, aferida pela estação meteorológica junto ao sistema fotovoltaico experimental. A ilustração da Figura 30, apresenta as etapas da aquisição e tratamento dos dados, montagem dos conjuntos de treino e teste para a modelagem da rede.

Figura 30 – Tratamento dos dados.



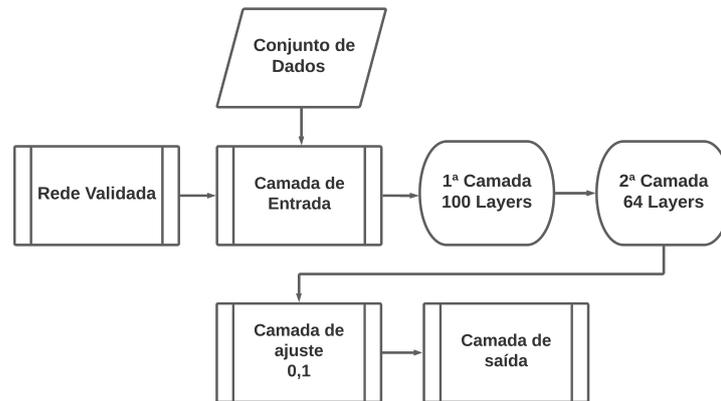
Fonte: O autor, 2021.

A base de dados totalizou um montante 1.840.320 registros, sendo 920.160 dados para cada variável. Na etapa de qualificação das informações, foram excluídos cerca de 196 mil registros do conjunto global, o equivalente a 10,65%. Após a primeira etapa de filtragem das informações inconsistentes, os dados de irradiação solar e temperatura de operação do módulo fotovoltaico foram normalizados com base nos valores máximos e mínimos do *dataset*, conforme apresentado pela equação 3.8.

$$(I_i)_N = \frac{I_i + I_{min}}{I_{max} - I_{min}} \quad (3.8)$$

Desta forma, $(I_i)_N$ é a grandeza normalizada de 0 a 1, I_i o valor instantâneo no momento, I_{min} o valor mínimo, e I_{max} é o máximo registro. A próxima etapa foi a separação para determinar o conjunto de treino e teste, 80% dos dados registrados foram utilizados para montar o conjunto de treino e 20% para compor a etapa de teste. O modelo da rede neural validado para este trabalho contou com duas camadas de processamento, a primeira com 100 *layers* e a segunda com 64 *layers*, assim, a rede definida procedeu com a estimativa de 1 minuto à frente (camada de saída), tomando como base uma sequência de 20 minutos de registros retroativos (camada de entrada) da irradiância solar e temperatura de operação do módulo FV. A Figura 31, apresenta a estrutura simplificada da rede neural LSTM utilizada ao longo deste trabalho.

Figura 31 – Arquitetura do modelo da rede neural LSTM utilizada.



Fonte: O autor, 2021.

O algoritmo de processamento da rede neural foi implementado em um computador *Intel Core I5 7th* geração, escrito na linguagem *Python* e fundamentado na biblioteca *TensorFlow 2.0.0*. As função de otimização *adam* e a função de erro *mse*, também foram incorporadas ao algoritmo estrutural da rede neural. Os procedimentos de escrita do código podem ser verificados no apêndice A dessa tese.

A busca por esses resultados demandou o uso de métricas clássicas utilizadas para comparar o valor real (y_i) e o previsto (\hat{y}_i). As expressões matemáticas empregadas para calcular o RMSE, *Mean Absolute Error* (MAE) e o coeficiente de correlação de Pearson (R), estão descritas pelas equações 3.9, 3.10 e 3.11, respectivamente.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}}, \quad (3.9)$$

$$MAE = \frac{\sum_{i=1}^N |y_i - \hat{y}_i|}{N}, \quad (3.10)$$

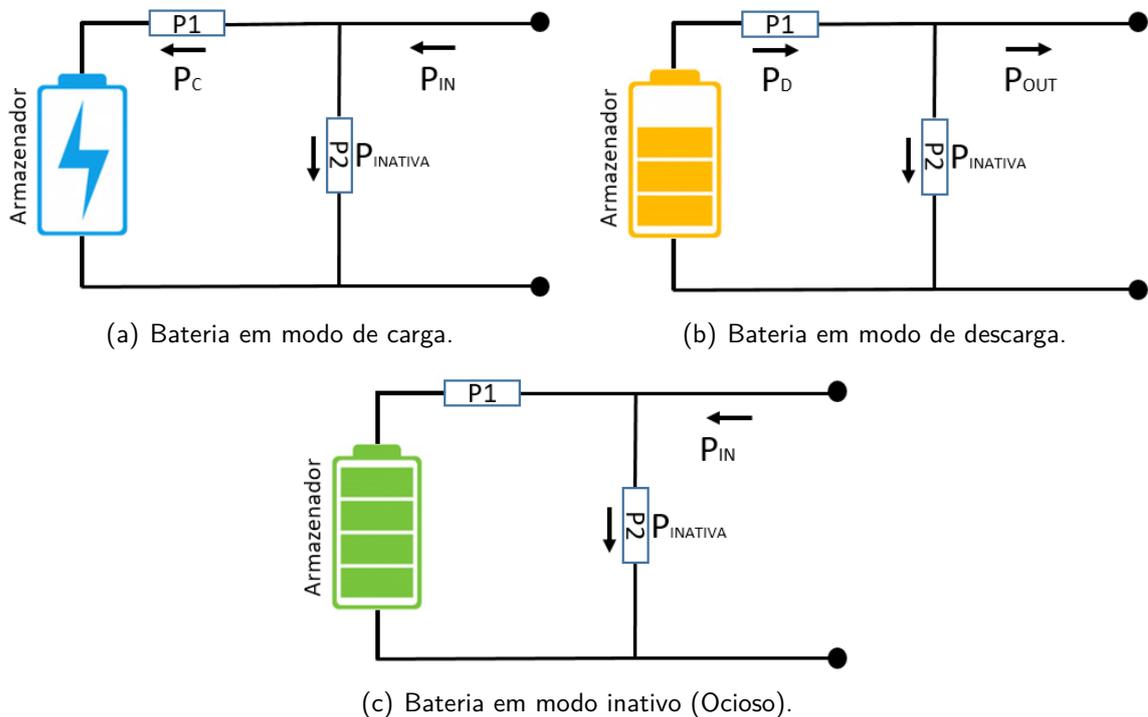
$$\rho_{X,Y} = \frac{Cov(X,Y)}{\sigma_X \sigma_Y} \quad (3.11)$$

Para o cálculo do coeficiente de Pearson o numerador “Cov” representa a covariância entre as variáveis, o denominador expresso pelo “ σ ” é o desvio padrão das variáveis. O coeficiente de Pearson explica o grau de afinidade entre as variáveis real e prevista (LEHOLO; OWOLAWI; AKINDEJI, 2019), quão mais próximo de “1” for a correlação, o modelo tem maior representatividade.

3.3.5 Armazenamento de energia elétrica

O modelo elétrico utilizado pelo sistema de armazenamento pode contar com a presença de um inversor, a bateria injeta ou armazena energia em corrente contínua, sendo imprescindível o inversor para realizar a conversão CC/CA com a rede elétrica. Os circuitos representativos de cada modo de funcionamento da bateria são ilustrados na Figura 32.

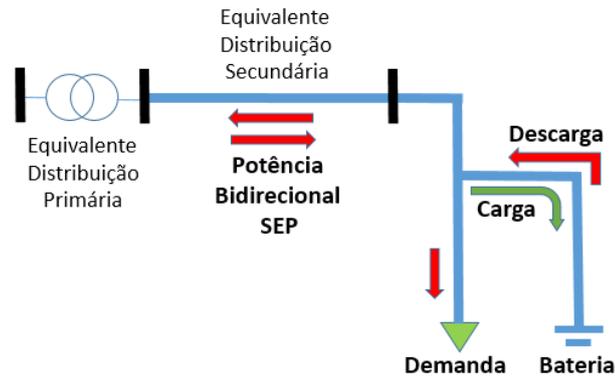
Figura 32 – Representação de uma bateria.



Fonte: O autor, 2021.

A Figura 32, representa os componentes básicos do modelo armazenador de eletricidade, o componente P1, refere-se a parcela das perdas tanto no estágio ao qual a bateria encontra-se em carregamento (Figura 32.a), bem como no momento de descarregamento (Figura 32.b), esse componente agrega em grande parte a eficiência da bateria (η_{BAT}). A representação de uma bateria em um diagrama elétrico para o estudo do fluxo de carga é apresentado a seguir pela Figura 33.

Figura 33 – Bateria elétrica no sistema de potência.



Fonte: O autor, 2021.

Tal como os elementos de injeção de potência, um banco de baterias é representado através de uma barra de grandezas conhecidas, enquadrando-se como uma barra do tipo potência-tensão (PV) ou potência ativa-reativa (PQ) conhecidas (GOMES, 2019).

3.3.5.1 Planejamento operacional do dispositivo de armazenamento

O planejamento do acionamento foi direcionado pela situação da dinâmica da potência ($P_{dinâmica}$), que permeia através do ramal de conexão da UC. A potência dinâmica foi obtida decorrente das condições de geração e demanda, um entendimento matemático é demonstrado a seguir, interpretando quando uma UC qualquer está operando sob condição do fluxo direto (consumindo energia elétrica), reverso (fornecendo energia elétrica) ou em equilíbrio (autônoma), tal aspecto é demonstrado na equação 3.12.

$$P_{dinâmica} = P_{FV} - P_{DMD} \begin{cases} Fluxo Direto, & \text{Se } (P_{FV} < P_{DMD}) \\ Fluxo Reverso, & \text{Se } (P_{FV} > P_{DMD}) \\ Autônoma, & \text{Se } (P_{FV} = P_{DMD}) \end{cases} \quad (3.12)$$

A utilidade do sistema de armazenamento para essa situação limitou a $P_{dinâmica}$ a uma $P_{inj-limite}$, sob a condição do fluxo reverso. Nessas circunstâncias, sendo a $P_{inj-limite} = 2500$ W, todas as vezes que o fluxo de potência exceder o valor de injeção limite, o banco de baterias se conecta em modo passivo, a potência requerida pela bateria é calculada instantaneamente pela equação 3.13:

$$P_{BAT(t)} = P_{dinâmica(t)} - P_{inj-limite} \quad (3.13)$$

A escolha do valor da $P_{inj-limite} = 2500$ W, refletiu na observação da série temporal de 1 ano em condição de baixa demanda, nesse formato o SFVCR injetou quase toda a energia na rede de distribuição. Diante desse fato, valores de $P_{inj} = a$ 2500 W foram enquadrados para 5% das ocorrências de sobretensão acima do limite crítico, maiores relatos podem ser vistos na seção 3.3.1. O valor da $P_{inj-limite}$ foi definido de acordo com o grau de conservação, já que nessa faixa de carregamento, as ocorrências das tensões que ultrapassaram o limite crítico estavam aproximadamente em 5%.

O modo operacional do sistema de armazenamento foi traduzido pela equação condicional 3.14, a partir do resultado da diferença entre a geração fotovoltaica e a demanda. O sinal adotado para P_{BAT} se baseou na convenção positiva para carga e negativa para a descarga. As condições para o funcionamento da bateria quanto ao seu modo de operação (Carga, Descarga e Ociosa) é interpretado pelas seguinte condicionantes a seguir.

$$P_{BAT} = \begin{cases} \text{Carga,} & \text{Se } (P_{FV(t)} > P_{DMD(t)}) \text{ E } (P_{dinâmica(t)} > P_{inj-limite}) \\ \text{Ociosa,} & \text{Se } (P_{FV(t)} > P_{DMD(t)}) \text{ E } (P_{dinâmica(t)} < P_{inj-limite}) \\ \text{Ociosa,} & \text{Se } (P_{DMD(t)} > P_{FV(t)}) \\ \text{Descarga,} & \text{Se } P_{FV(t)} = 0 \text{ E } \forall P_{DMD(t)} \end{cases} \quad (3.14)$$

O valor de P_{BAT} está intimamente ligado ao valor da $P_{inj-limite}$, uma vez que, se o valor da limitação de potência for muito baixo e a capacidade do banco permanecer a mesma, isso reflete no aumento da profundidade de descarga da bateria, consequentemente reduzindo sua vida útil. Para tal contexto, o aumento da capacidade do banco de baterias, a fim de manter o *State of Charge* (SoC) dentro de uma faixa operacional que otimize a vida útil das baterias é crucial. Em Diaz (2019), o autor abordou uma outra metodologia para calcular a potência da bateria, foi utilizada diferença entre os limites mínimo e máximo. Em termos de capacidade do sistema de armazenamento, o valor pode ser obtido pela integração de P_{BAT} , presente na equação 3.13.

A convenção do sinal para os modos de operação do sistema de armazenamento está atrelada à componente P_{BAT} , a Tabela 7 abaixo, parametrizou o modo de operação em função das principais variáveis envolvidas no processo.

Tabela 7 – Tabela resumo do perfil de acionamento do sistema de armazenamento.

Modo de Operação	Potência da Bateria	Potência do SFVCR	Potência da UC
Carga (Passivo)	$P_{BAT} > 0$	$P_{FV} > 0$	$P_{DMD} > 0$
Ociosa (Neutro)	$P_{BAT} = 0$	$P_{FV} > 0$	$P_{DMD} > 0$
Descarga (Ativo)	$P_{BAT} < 0$	$P_{FV} = 0$	$\forall P_{DMD}$

Fonte: O autor, 2021.

Por fim, o banco de baterias adotado foi escalonado em 4 níveis de potência. O intuito dessa configuração foi para proporcionar uma maior flexibilidade no uso das baterias. Cada nível de potência corresponde a um ΔP distinto, onde o primeiro passo limita a potência dinâmica em modo reverso a um valor de potência injetada máxima $P_{inj-máxima}$. O objetivo desta configuração buscou a maior flexibilidade operacional, além do que, em caso de eventual manutenção do dispositivo, este contexto garante o funcionamento parcial. Cada nível de potência corresponde a um ΔP diferente, onde primeiramente limita-se a potência dinâmica injetada na rede ao patamar mínimo ($MIN(P_{inj})$) e máximo ($MAX(P_{inj})$). Nesse sentido, o valor mínimo da potência injetada foi igual ao valor limite da injeção de potência definido previamente, portanto $MIN(P_{inj}) = P_{inj-limite}$, o valor máximo foi arbitrado para cada incremento de potência de 500 W. A variação de potência (ΔP) em função da potência dinâmica para cada nível é calculada a partir do conjunto de inequações abaixo:

$$\Delta P(P_{dinâmica}) = \begin{cases} 500W, & \text{Se } MIN(P_{inj}) \leq P_{dinâmica} \leq MAX(P_{inj}), \text{ Para } MAX(P_{inj}) = 3000 \text{ W} \\ 1000W, & \text{Se } MIN(P_{inj}) \leq P_{dinâmica} \leq MAX(P_{inj}), \text{ Para } MAX(P_{inj}) = 3500 \text{ W} \\ 1500W, & \text{Se } MIN(P_{inj}) \leq P_{dinâmica} \leq MAX(P_{inj}), \text{ Para } MAX(P_{inj}) = 4000 \text{ W} \\ 2000W, & \text{Se } MIN(P_{inj}) \leq P_{dinâmica} \leq MAX(P_{inj}), \text{ Para } MAX(P_{inj}) = 4500 \text{ W} \end{cases} \quad (3.15)$$

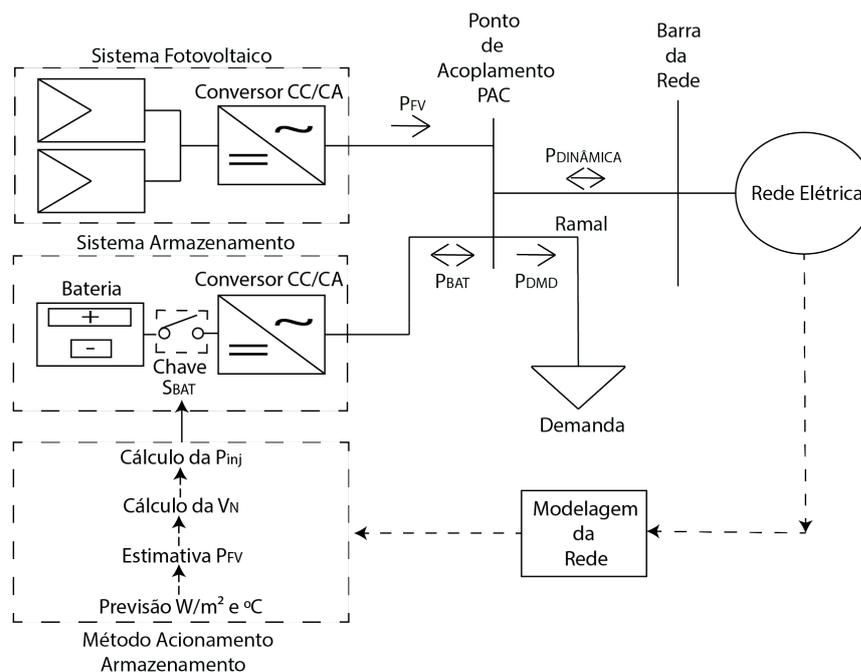
A energia elétrica total desprendida em modo de carga pelos grupos de potência do sistema de armazenamento foi calculada a partir do somatório da energia de cada grupo ΔP_{BAT} . A equação 3.16 a seguir, calcula e converte a energia global armazenada em Watt-hora (Wh) pelo banco de baterias.

$$E_{STB}(t) = \frac{1}{60} \left[\sum_{t=1}^n P_{STBNivel1}(n) + \sum_{t=1}^n P_{STBNivel2}(n) + \sum_{t=1}^n P_{STBNivel3}(n) + \sum_{t=1}^n P_{STBNivel4}(n) \right] \quad (3.16)$$

A determinação da capacidade de armazenamento total está relacionada com a carga efetiva necessária. Recomenda-se, que o valor da carga efetiva adotado obedeça os critérios do limite de profundidade de descarga, bem como garanta o SoC de todo o sistema. É usual aplicar um valor de DoD de 20% ou 30%, para maior longevidade das baterias (MARTINS et al., 2019)(MOGHADDAM; CHOWDHURY, 2017).

A concepção prática é vislumbrada no esquema elétrico da Figura 34, onde são detalhados cada componente que integra o sistema de distribuição com suas respectivas variáveis. Computacionalmente, o acionamento do sistema de armazenamento foi viabilizado por uma chave (S_{BAT}), comandada pelo bloco denominado de “Método Acionamento Armazenamento”, representado detalhadamente pelo método exibido no fluxograma da Figura 29.

Figura 34 – Diagrama elétrico dos elementos integrantes da rede elétrica diante do ponto de acoplamento comum.



Fonte: O autor, 2021.

A estrutura implementada no sistema de armazenamento foi efetivada a partir da integração de outras etapas, com diferentes graus de intervenção. Diferentemente das aplicações baseadas em armazenamento elétrico, é possível aplicar o gerenciamento pelo lado da demanda, acionando cargas específicas para um determinado contexto. Exclusivamente para os sistemas a baterias, ao escolher o tipo de aplicação, os diversos fatores operacionais como: profundidade de descarga, capacidade, potência, eficiência e número de ciclos, devem ser cuidadosamente considerados (ALMEIDA, 2017).

4 RESULTADOS E DISCUSSÕES

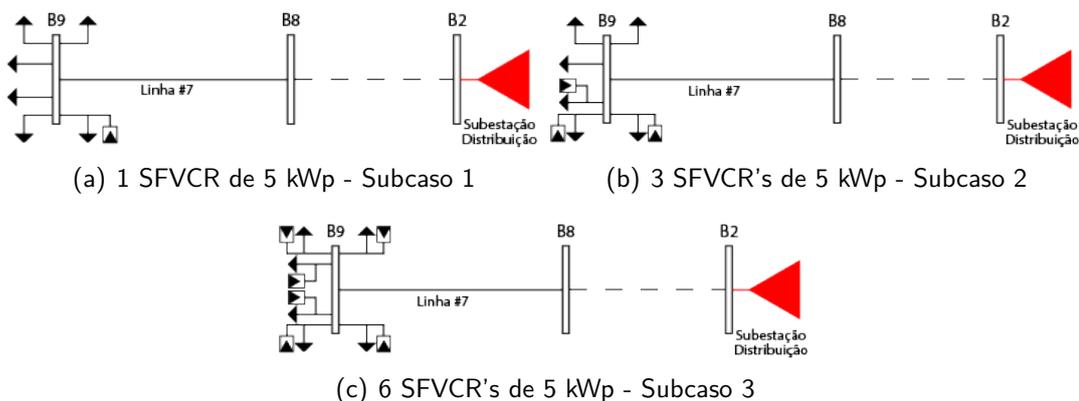
Os resultados do item 4.1 e dos respectivos subitens são exclusivos ao estudo do fluxo de potência desenvolvido no *software OpenDSS*. Uma série de programas podem realizar o estudo do fluxo de carga de forma semelhante, mas o fato da necessidade de uma maior interação com outras fontes, optou-se pelo o uso deste *software*, além do mais, trata-se de um programa *opensource*. Lembra-se que inicialmente, o estado da rede foi determinado em condições mais comportadas, servindo como propriedade para que os resultados fossem alcançados.

4.1 IMPACTOS DO SFVCR NA TENSÃO DE FORNECIMENTO

4.1.1 Resultados do caso 1

Seguindo a orientação metodológica, cada subseção contemplou os resultados de cada caso e seus respectivos subcasos. Onde a análise parte inicialmente de um único sistema fotovoltaico com potência de 5 kWp, até atingir a máxima capacidade de alocação disponível na barra, porém sem exceder o limite de potência admissível. Uma representação dos subcasos, Figura 35, ilustra as simulações.

Figura 35 – Representação dos subcasos simulados pelo caso 1 (5 kWp)

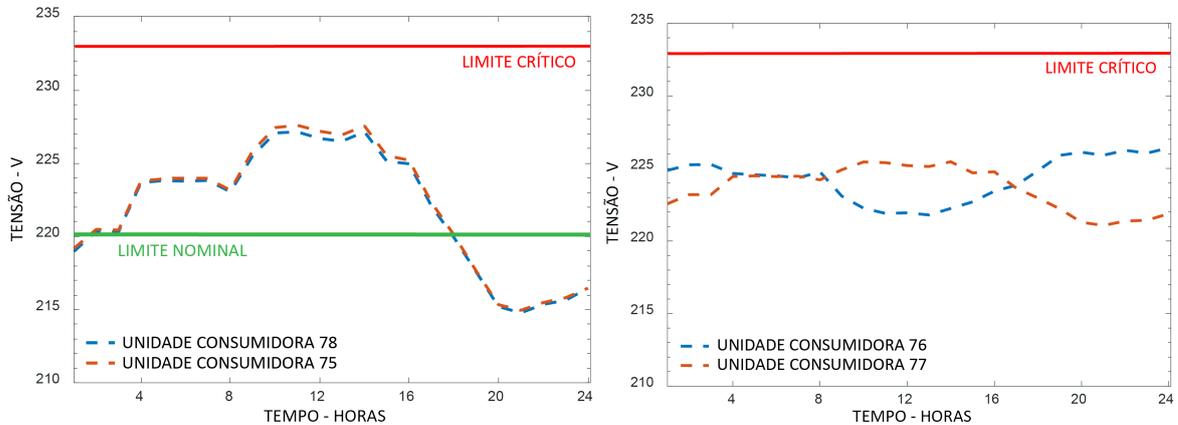


Fonte: O autor, 2021.

Os gráficos a seguir, apresentam a dinâmica da tensão elétrica no ponto de fornecimento das unidades consumidoras conectadas à barra 09, para todos os subcasos ilustrados na Figura 35. Ambos os gráficos são limitados por uma linha vermelha que expressa o limite crítico da

tensão (233 V), a linha contínua na cor verde está presente em alguns gráficos representando a faixa de tensão nominal (220 V).

Figura 36 – Resultados do caso 1 - Subcaso 1.



(a) Perfil de Tensão - UC 75 com SFVCR

(b) Perfil de Tensão - UC sem SFVCR

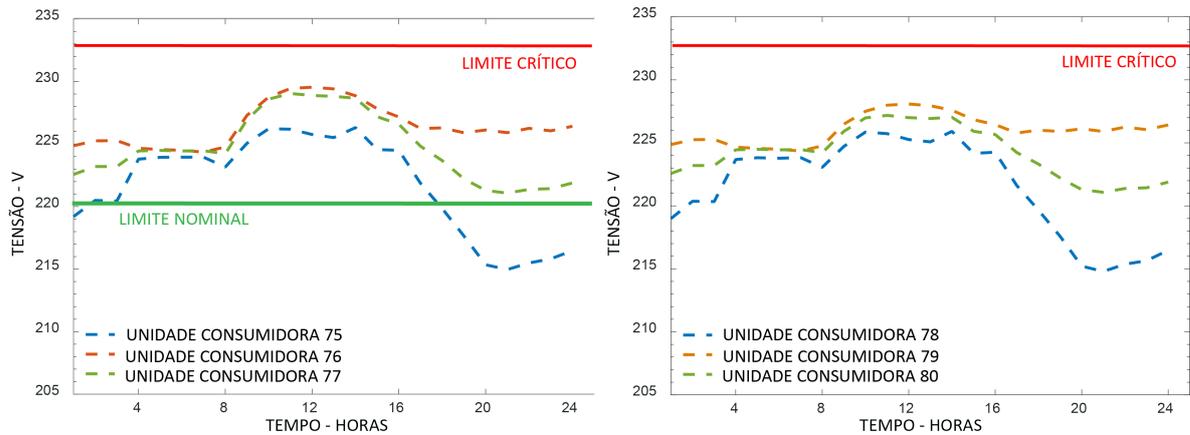
Fonte: O autor, 2021.

Nessa simulação foi inserido apenas um único gerador fotovoltaico na rede, sendo este conectado à UC 75, do ponto de vista da potência instalada, a mesma corresponde à 34% do nível máximo permitido em conexão monofásica. A imagem da Figura 36, traça perfil da tensão da UC 75 com a linha tracejada na cor laranja. A sobretensão é presenciada no momento de forte contribuição da geração fotovoltaica, observada das 8 às 16 horas. Neste mesmo período, a variação da tensão com relação ao limite nominal é próximo de 3%, ainda assim permanecendo abaixo do limite crítico. O fato das UC 75 e 78 estarem submetidas à mesma sequência de fase de alimentação (conectadas na fase A), o perfil da tensão da UC 78 se assemelhou a curva da tensão da UC 75.

A representação das tensões das demais UC no gráfico 36, apresentam-se mais uniformes ao longo do dia, como ambas estão sob ausência de SFVCR, as variações na tensão são promovidas decorrentes das mudanças na curva de carga e do desbalanceamento do circuito.

Preservando a mesma metodologia, o subcaso 2 simulou os impactos considerando a ampliação do quantitativo de geradores fotovoltaicos. Ainda assim, a tensão elétrica permaneceu dentro dos limites permitidos para as respectivas UC equipadas com SFVCR (75, 76 e 77), as UC 76 e 77 apresentaram um valor relativo de sobretensão em 5% referente as demais UC. A Figura 37, exibe a curva das tensões das respectivas UC dotadas de geradores fotovoltaicos.

Figura 37 – Resultados do caso 1 - Subcaso 2.



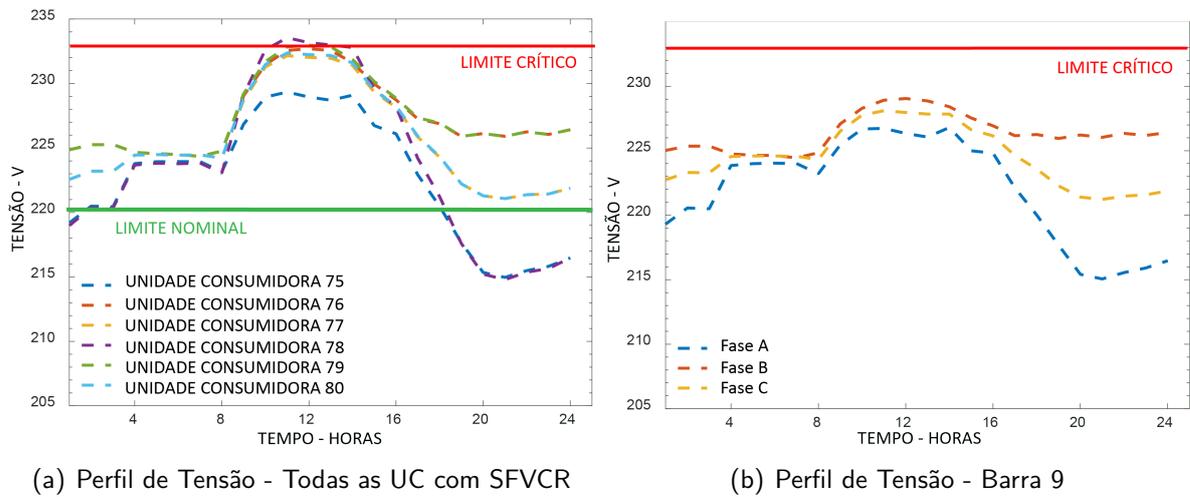
(a) Perfil de Tensão - UC 75, 76 e 77 com SFVCR

(b) Perfil de Tensão - UC sem SFVCR

Fonte: O autor, 2021.

Em virtude do ramal de conexão, mesmo as UC submetidas às mesmas condições da curva de demanda e irradiação solar, bem como, equipadas com o mesmo gerador fotovoltaico, os contornos do perfil de tensão destacaram-se com amplitudes variadas, isso se deu ao fato da distinção do tipo de condutor utilizado e da distância do ramal de conexão entre a UC e a barra 9. Conforme ocorrido ao subcaso 1, as demais UC sem SFVCR sentiram o efeito da propagação da tensão originada pelo fluxo de carga reverso advinda das UC com SFVCR. A análise final para o Caso 1, procedeu com um fator de ocupação de 100% de unidades geradoras, o subcaso 3, equipou todas as UC com SFVCR considerando todas as características de curva de carga e potência de geração constante, salienta ainda, que as características dos ramais são variados e computados de acordo com a situação real levantada em campo. O esboço gráfico a seguir, demonstra o comportamento técnico do perfil da tensão em todas as UC, a partir da Figura 38.

Figura 38 – Resultados caso 1 - Subcaso 3.



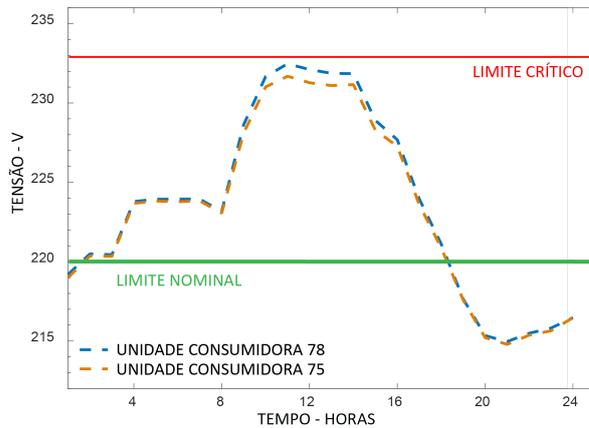
Fonte: O autor, 2021.

Para as curvas dos perfis acima, a UC 78 rompeu o limite crítico da tensão no período de máxima geração fotovoltaica. As demais unidades consumidoras aproximaram-se bastante do limite crítico, mas se mantiveram dentro dos patamares aceitáveis. Na barra que antecede as unidades consumidoras também foram identificadas elevações de tensão para as três fases, mantendo-se porém dentro da faixa operacional.

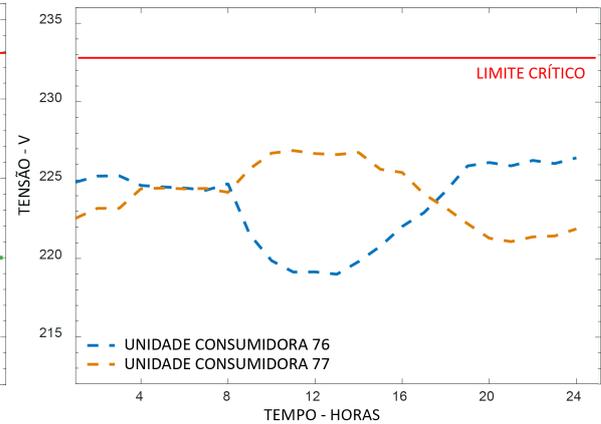
4.1.2 Resultados do caso 2

Com as mesmas premissas da simulação do caso 1, os resultados relatados nessa seção apresentaram os comportamentos da tensão para cada subcaso. Considerando a capacidade dos SFVCR em 10 kWp, todas as simulações do caso foram refeitas e os resultados do perfil de tensão estão esboçados na Figura 39. A tendência de ocorrência da sobretensão foi mais evidente. O gráfico do subcaso 2, Figura 39.c, demonstra que as UC's 76 e 77 ultrapassaram o valor do limite crítico da tensão. A condição de assimetria entre as tensões nas fases foi evidenciada na simulação do subcaso 1, Figura 39.b, como a geração fotovoltaica foi atrelada a uma única UC que está sendo suprida pela fase A, ocorreu um sobrecarregamento na fase A com relação a fase B e C.

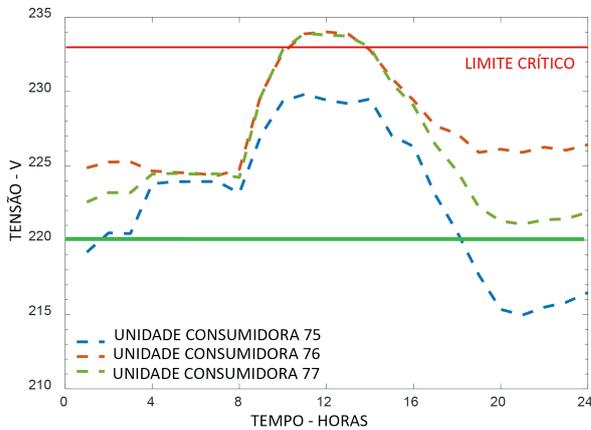
Figura 39 – Resultados caso 2 - Subcaso 1 e 2.



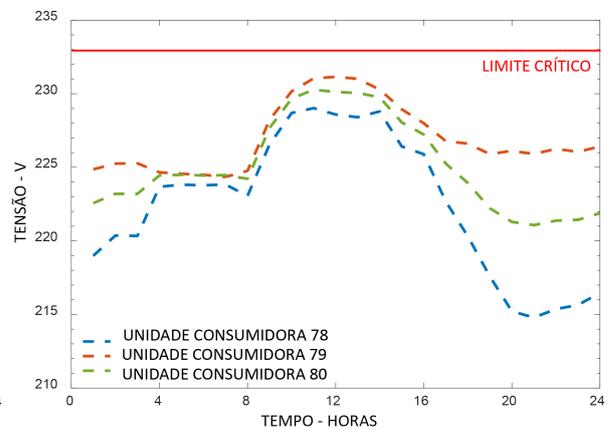
(a) Perfil de Tensão - UC 75 com SFVCR



(b) Perfil de Tensão - UC sem SFVCR



(c) Perfil de Tensão - UC 75, 76 e 77 com SFVCR

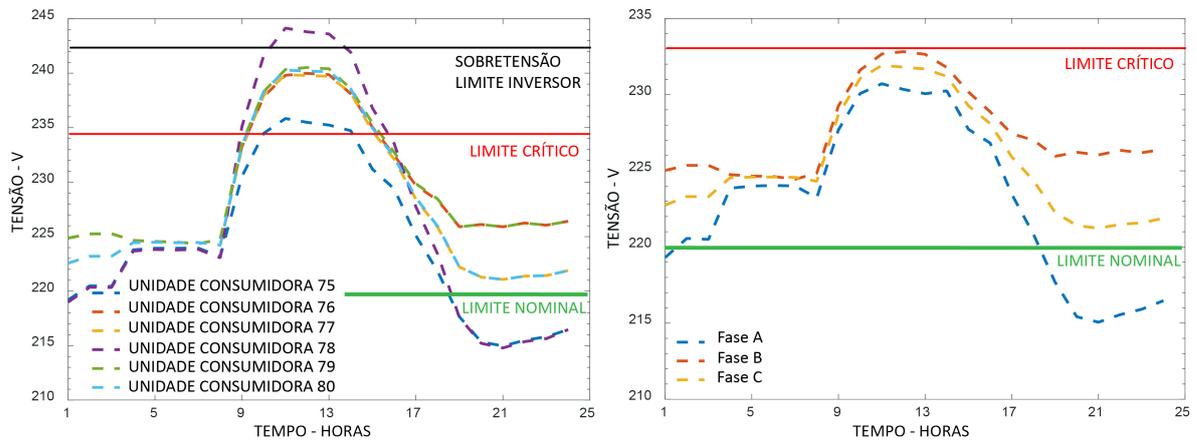


(d) Perfil de Tensão - UC sem SFVCR

Fonte: O autor, 2021.

A situação mais crítica enquadrou-se no subcaso 3, (Figura 40.a) onde praticamente todas as unidades consumidoras ultrapassaram o limite crítico de tensão, a UC 78 atingiu o máximo valor de tensão, rompendo o parâmetro de proteção contra a sobretensão do inversor. A UC 78 ultrapassou 5% do valor da tensão crítica, correspondendo a 11% do valor nominal. Abaixo tem-se a variação relativa percentual da tensão para o limite crítico e nominal citados, 233 V e 220 V, respectivamente.

Figura 40 – Resultados caso 2 - Subcaso 3.



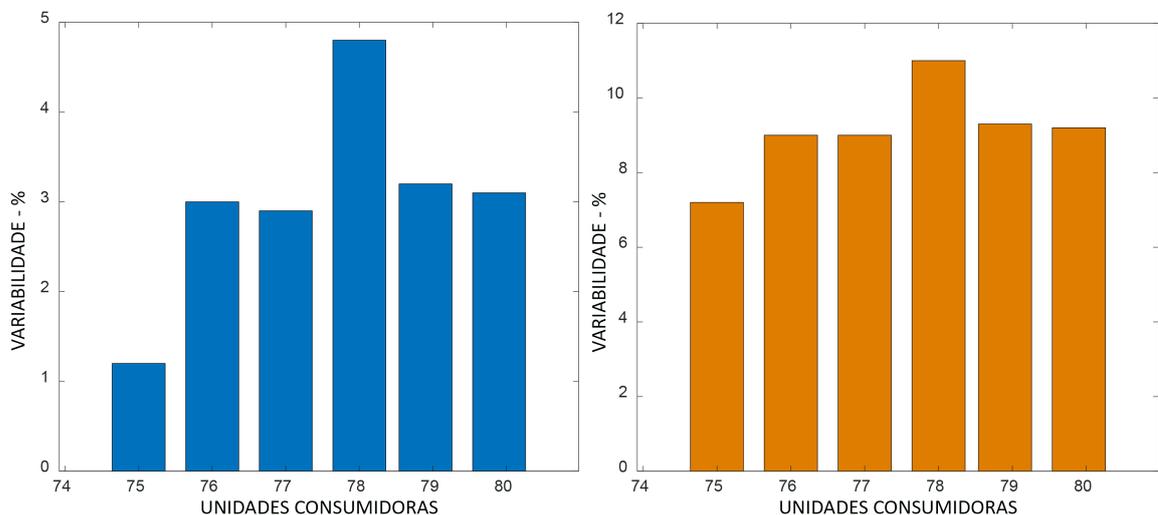
(a) Perfil de Tensão - Todas as UC com SFVCR

(b) Perfil de Tensão - Barra 9

Fonte: O autor, 2021.

O estudo comparativo, obteve o desvio da tensão elétrica relativo ao limite crítico e nominal, 233 V e 220 V, respectivamente, foram mensuradas a fim de medir o quanto cada caso influenciou na dispersão dos valores nominais. A Figura 41, apresenta os resultados da dispersão dos valores de referência.

Figura 41 – Representação das variações de tensão em torno dos valores de referência.



(a) Variação da tensão operacional com relação ao limite crítico.

(b) Variação da tensão operacional com relação ao limite nominal.

Fonte: O autor, 2021.

O gráfico da Figura 41, quantifica a variação da tensão pelo período de geração solar fotovoltaica e sem geração fotovoltaica. A manifestação dos valores constituiu de forma muito clara, a influência da geração solar fotovoltaica no deslocamento da tensão para os níveis limitantes. Os valores de desequilíbrio foram calculados e agrupados para variações de tensão

em UC conectadas na mesma fase e para variações de tensão em UC conectadas em fases distintas.

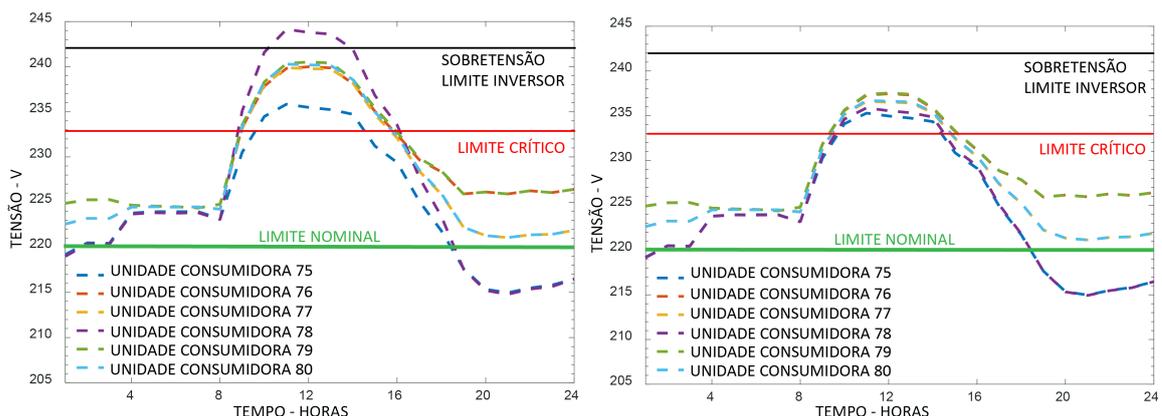
Tabela 8 – Subcasos de simulação.

Caso	Subcaso	Máxima Tensão Volts			Variação Fases Distintas			Variação Fases Iguais		
		V_A	V_B	V_C	V_{AB}	V_{BC}	V_{AC}	V_A	V_B	V_C
Caso 1	1	227,5	226,4	225,4	0,5%	0,4%	0,9%	0,2%	0,0%	0,0%
	2	226,3	229,5	229,0	1,4%	0,2%	1,2%	0,2%	0,6%	0,8%
	3	233,5	232,9	232,3	0,2%	0,3%	0,5%	2,0%	0,1%	0,1%
Caso 2	1	232,4	226,4	226,8	2,6%	0,2%	2,4%	0,3%	0,0%	0,6%
	2	229,8	234,0	233,9	1,8%	0,0%	1,8%	0,3%	1,2%	1,1%
	3	244,0	240,5	240,2	1,5%	0,1%	1,6%	4,0%	0,2%	0,2%

Fonte: O autor, 2021.

O subcaso 3 apresentou a maior taxa de variação entre consumidores conectados na fase A. Diante deste problema, o subcaso 3 do caso 2 foi enquadrado no método de viabilidade técnica proposto, Figura 22, onde foi utilizado o método de redefinição do gerador fotovoltaico, objetivando a diminuição da potência injetada na rede de distribuição. Após a redefinição do SFVCR, foi executada uma nova simulação, onde os resultados do perfil de tensão para UC são constatados no gráfico a seguir:

Figura 42 – Resultado comparativo do subcaso 3 antes e depois da redefinição do SFVCR.



(a) Perfil da tensão antes da redefinição do gerador fotovoltaico (b) Resultado comparativo após a redefinição do gerador fotovoltaico

Fonte: O autor, 2021.

Com a redefinição do SFVCR, a potência do sistema foi distribuída simetricamente para as três fases, em termos prático, isso pode ser realizado utilizando inversores com conexão trifásica ou até mesmo microinversores distribuídos simetricamente. O efeito é verificado

na Figura 42.b, apesar de manter-se acima do limite crítico, as sobretensões máximas que foram localizadas especialmente na UC 78, reduziram-se em 4%. Tabela 9 esboça o quadro comparativo com os valores de assimetria entre as fases.

Tabela 9 – Comparativo da variabilidade da tensão após a mitigação.

Caso	Máxima Tensão Volts			Variação Fases Distintas			Variação Fases Iguais		
	V_A	V_B	V_C	V_{AB}	V_{BC}	V_{AC}	V_A	V_B	V_C
Caso 2	244,00	240,50	240,20	1,5%	0,1%	1,6%	4,0%	0,2%	0,2%
Mitigação	235,80	237,54	236,71	0,7%	0,3%	0,4%	0,3%	0,0%	0,0%

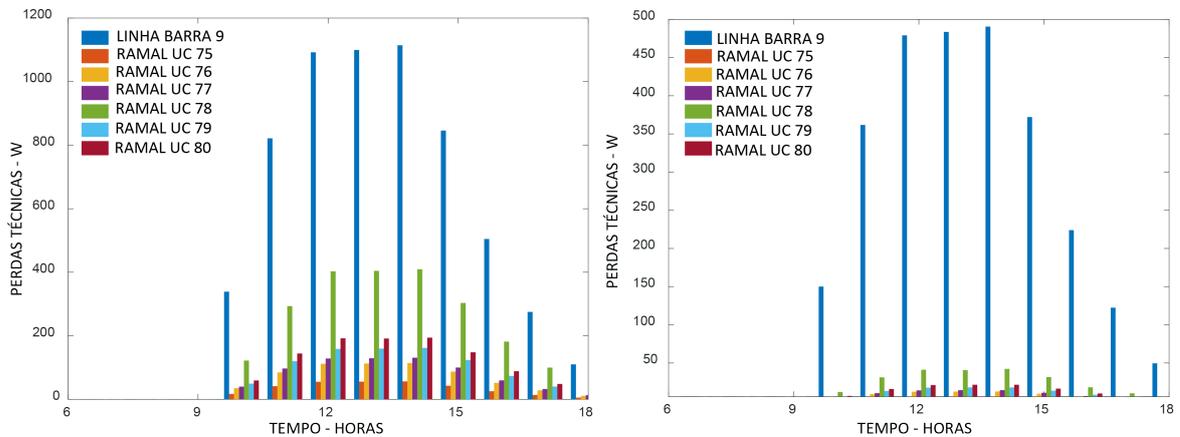
Fonte: O autor, 2021.

O ajuste da conexão dos geradores fotovoltaicos foi eficaz para aumentar a capacidade de hospedagem da GD, mantendo um bom fator de simetria. Existem também algumas medidas mais severas para resolver o problema. Por exemplo, em Tonkoski, Lopes e El-Fouly (2011), foi estudado sobre a medida de diminuição de injeção de potência por corte de módulos fotovoltaicos, devido ao surgimento de sobretensões em residências situadas no fim de rede entre os horários das 9:40h e 14:10h, atingindo 1.06 P.U. (233,2 V), foi relatado também que ocorreu perda de energia em um SFVCR de aproximadamente 3 kWh/dia. Em Wang et al. (2018), o autor evidenciou o sobrecarregamento de transformadores e a manifestação da elevação de tensão nas barras do circuito causadas por SFVCR's, ainda assim, achou um fator ótimo de 40% de penetração FV.

A análise do fluxo de potência incorporou também o estudo localizado das perdas técnicas, ou seja, parcela do fluxo de carga que fluiu diretamente ou reversamente pela linha de distribuição. Mediante a configuração original do circuito, na ausência da geração distribuída e considerando o baixo carregamento em toda a extensão do circuito, as perdas técnicas foram baixas, uma vez que o circuito foi dimensionado para atender as UC sob as condições de demanda.

Em compensação, sabendo que os ramais de interligação estavam sujeitos ao fluxo de potência reverso, e ainda em maior intensidade, divergindo totalmente da curva de demanda, é esperado que as perdas técnicas sejam elevadas, ainda mais que as características dos condutores foram constantes para ambas as situações. Os gráficos a seguir abrangem as perdas horárias ao longo do dia, considerando o caso mais severo de inserção (Subcaso 3 - Caso 2), Figura 43.a, e o resultado posterior à aplicação da técnica de mitigação, Figura 43.b.

Figura 43 – Análise das perdas técnicas nos ramais de conexão das UC e no trecho fim de rede influenciadas pelo gerador fotovoltaico.

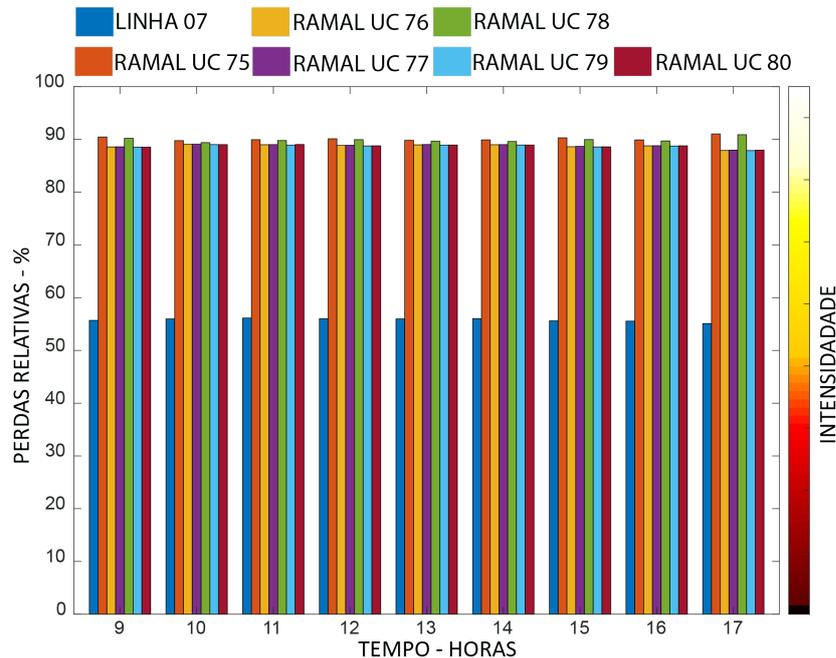


(a) Perdas técnicas sob a inserção massiva da geração fotovoltaica (b) Perdas técnicas diante da estratégia de mitigação

Fonte: O autor, 2021.

O condutor utilizado na extensão de fim de rede, situada a montante da barra 9, foi acometido pelo forte impacto da soma dos fluxos de potência reversos advindos de todas as UC. Ao longo de um dia foram computados 6,21 kWh de energia, dissipados apenas nesse trecho, além desse fato impactar negativamente em aspectos de eficiência energética, graves consequências na questão da qualidade de energia elétrica podem ser notados. Ainda nesse quadro, encontra-se as perdas elétricas calculadas no caso pós mitigação, observando-se uma redução significativa nessas perdas, focando no elemento fim de rede (linha 7), as perdas foram reduzidas em torno de 55,78%. Já nas UC, foi alcançada uma redução média nas perdas de 89,16%. Em termos percentuais, o gráfico da Figura 44 demonstra o percentual de redução com relação aos resultados obtidos pela simulação que obteve os maiores índices.

Figura 44 – Representação das perdas relativas para cada UC, acompanhadas do grau de intensidade de redução em cada ramal condutor.



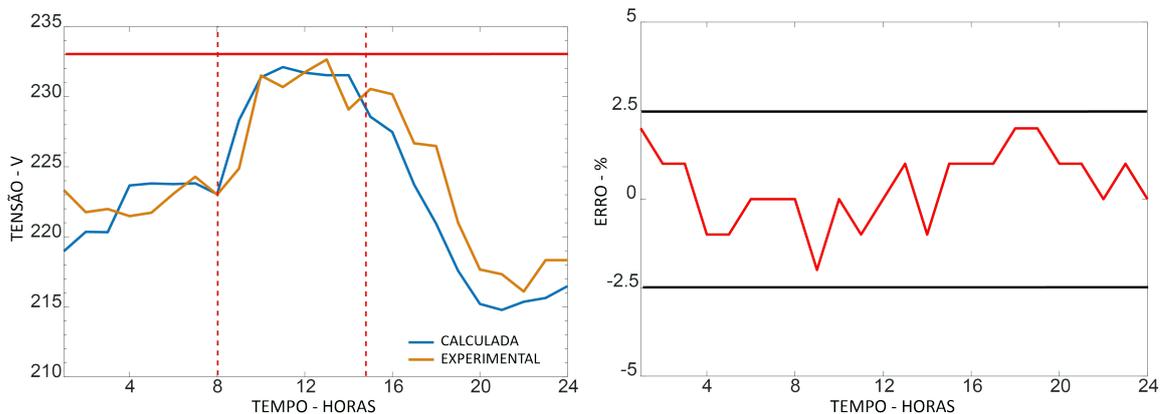
Fonte: O autor, 2021.

O gráfico utiliza uma escala auxiliar no eixo das ordenadas (secundário), lado direito do gráfico da Figura 44, essa escala determina o grau de alívio das perdas em cada condutor, nessa condição um maior fôlego operacional e minimização das perdas elétricas é visivelmente expresso pelo gradiente de cor da barra à direita do gráfico. O estudo das perdas realizado nesse trabalho foi de caráter pontual, cabe ressaltar que o estudo das perdas deve considerar toda a extensão do alimentador.

4.1.3 Estudo comparativo das análises teórica e experimental

Os cenários simulados em cada caso e subcaso foram modelados a partir dos dados extraídos de irradiação solar, temperatura da célula e curvas de carga extraída de um UC real, referenciada no ambiente de simulação pelo código UC 78. Simulando o caso real no *OpenDSS*, preservando as características físicas do circuito, foi possível efetuar uma comparação entre os dados experimentais e simulados. A Figura a seguir é acompanhada de dois gráficos, a Figura 45.a, apresenta o contorno comparativo entre as variáveis, e ao lado, é mostrado o desempenho através do erro relativo aos valores reais da tensão a cada hora.

Figura 45 – Comparação entre os valores de tensão obtidos experimentalmente e computacionalmente.



(a) Perfil da tensão experimental e simulada (b) Erro relativo entre os valores experimental e real

Fonte: O autor, 2021.

Constatou-se a convergência entre os valores de tensão calculado e experimental, principalmente durante o ápice da produção fotovoltaica (8h às 15h). Os resultados expõem que o método de estudo proposto pode ser facilmente incorporado na etapa de análise de projetos e de viabilidade de implantação de SFVCR. Além de estratégias voltadas à redefinição do gerador fotovoltaico, diversos trabalhos na literatura adota ações de reforço da rede de distribuição (KATIRAEI; AGÜERO, 2011). Segundo Wang et al. (2018), ações de reforço da rede foram adotadas como solução convencional para suporte ao excesso do fluxo de potência. Já em Mateo et al. (2017), o autor contestou o uso do reforço de rede, justificando como uma medida paliativa de alto custo e ineficiente, com isso sugere viabilizar outras alternativas.

4.2 MITIGAÇÃO DA TENSÃO DE CURTO PRAZO

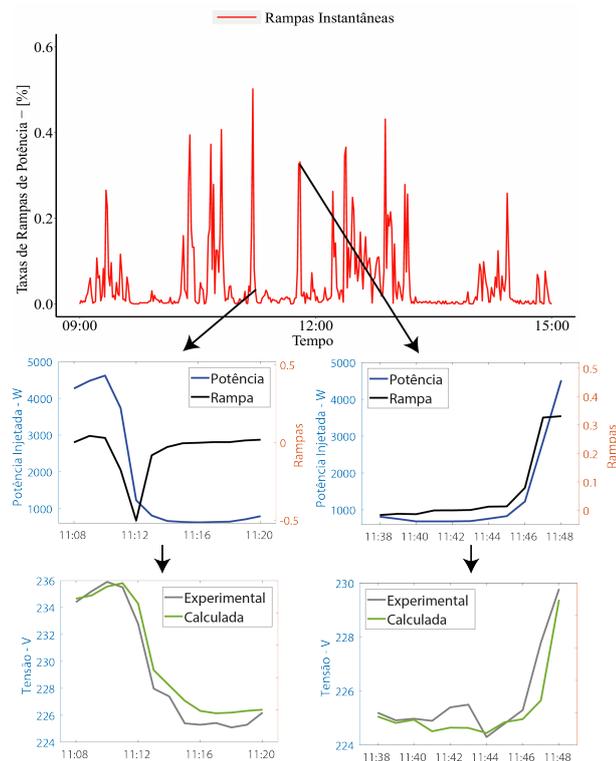
Nesta seção foram apresentados os resultados extraídos da etapa do método de mitigação da tensão de curto prazo, contemplando as etapas de previsão da irradiação solar e temperatura operacional do módulo fotovoltaico, cálculo da potência do gerador fotovoltaico e da tensão elétrica no ponto de acoplamento. No final, foram apresentadas as informações que revelaram a assertividade da estratégia.

4.2.1 Análise das rampas de potência

A primeira etapa dos resultados buscou entender e caracterizar as rampas de potência decorrentes da alta variabilidade da irradiação solar. Os resultados iniciais contemplaram a in-

fluência da irradiação solar na potência do gerador fotovoltaico, interpretando a variabilidade. Para um melhor entendimento, o gráfico das rampas de potência absolutas presentes na Figura 46, demonstram a amplitude de todas as rampas de potência existentes ao longo do dia, esse gráfico foi elaborado a partir dos dados experimentais observados. Logo abaixo do gráfico principal, os subgráficos esboçam isoladamente a reprodução desse efeito na potência produzida pelo gerador fotovoltaico, assim como a resposta da tensão no ponto de fornecimento.

Figura 46 – Ilustração do efeito das rampas de potência na tensão do ponto de acoplamento.



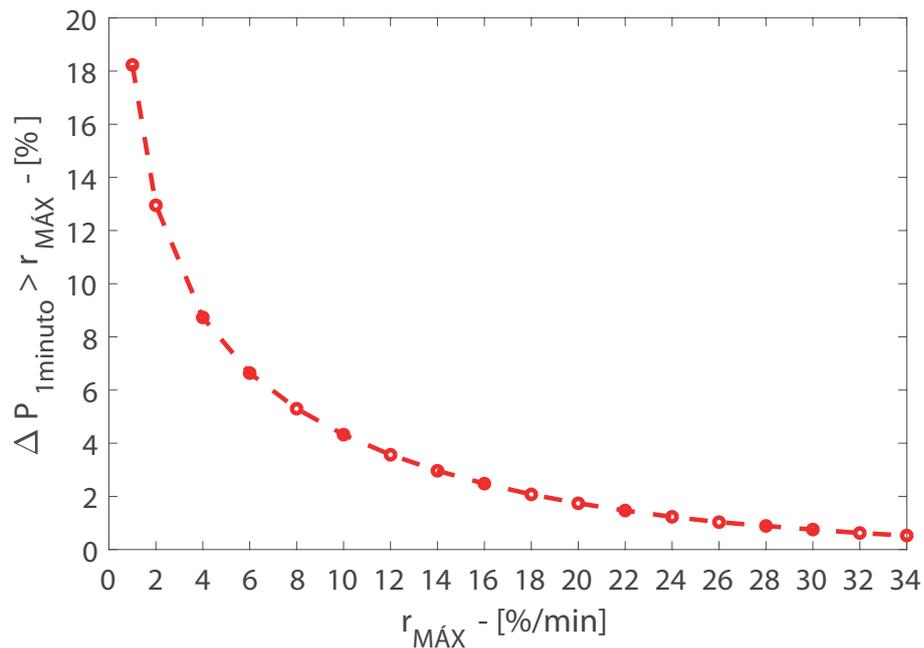
Fonte: O autor, 2021.

No período de tempo analisado, a captura dos subgráficos à esquerda, ilustram a consequência da redução da potência injetada, proveniente de uma rampa negativa de amplitude $\Delta P = 50\%$ da capacidade instalada no SFVCR, no respectivo gráfico abaixo, ocorreu uma rápida redução da tensão. Os subgráficos à direita revelam, para outra fração de tempo e no mesmo dia, o efeito de uma rampa de potência ascendente com amplitude de $\Delta P = 35\%$, carregando o SFVCR e consequentemente elevando a tensão. No instante de flutuação de potência, a tensão decaiu até o nível nominal aceitável. Já para a rampa ascendente, a tensão tendeu a subir para o nível crítico. Não obstante, os sentidos de oscilação das rampas de potência produziram um efeito de volatilidade na tensão, afetando a sua qualidade. O resultado dessa pequena amostra explicou a forte influência direta da intermitência da irradiação solar

na tensão de fornecimento à UC, abrindo um leque para expansão desse estudo.

Pelo simples fato de que no Brasil ainda não possui algo concreto sobre a limitação das rampas de potência, o estudo prosseguiu adotando um coeficiente inicial para restrição de rampas máximas ($r_{MÁX}$) igual a 2%/minuto, sendo este valor incrementado até um limite máximo de 34%/min. Feito isso, o gráfico da Figura 47 sintetiza as ocorrências de rupturas das flutuações de potência baseada nas informações experimentais.

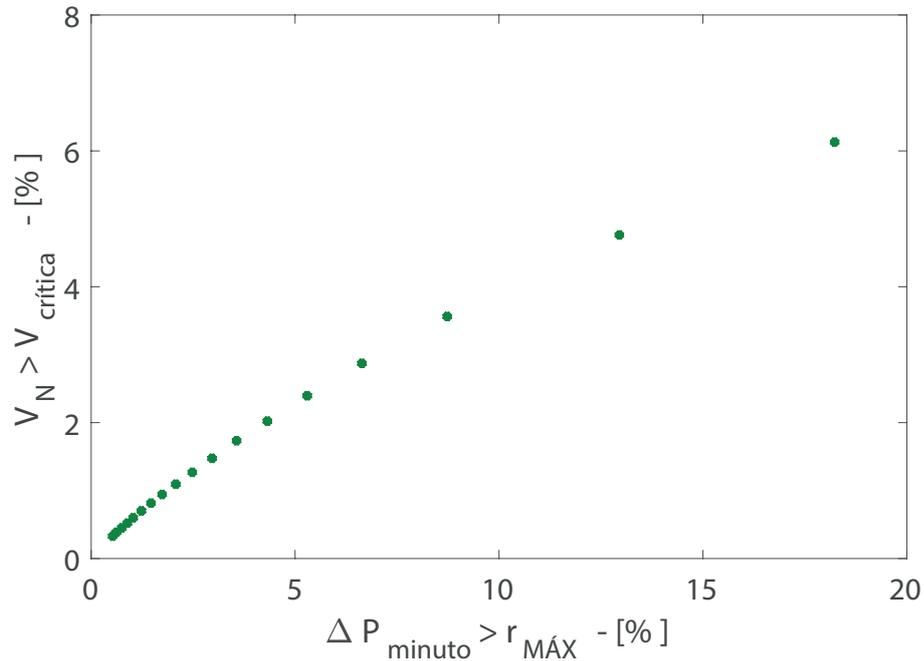
Figura 47 – Frequência de ocorrência das taxas de rampas de potência que excederam a $r_{MÁX}$.



Fonte: O autor, 2021.

A linha do gráfico da Figura 47 pode ser um meio de interpretação para o que aconteceria com a frequência relativa das flutuações de potência que excederam a rampa máxima ($\Delta P > r_{MÁX}$). Tal conceito pode ser exemplificado da seguinte forma, imagina-se que uma concessionária de energia limita o $r_{MÁX}$ à 10%/minuto, de acordo com o gráfico, 4,32% do tempo de operação do sistema excederia o padrão de $r_{MÁX}$ preestabelecido. Para valores de $r_{MÁX}$ mais afastados, o volume de ultrapassagem tendeu a diminuir, supõe-se em vista disso, que a taxa de limitação da $r_{MÁX}$ depende da robustez do sistema elétrico de potência, de forma que as flutuações de potência não interferiram nos parâmetros de qualidade da energia elétrica. Esse aspecto favoreceu a investigação da violação da faixa crítica da tensão, condicionada às flutuações de potência que violaram a $r_{MÁX}$. A Figura 48, esboça a frequência relativa do tempo total das violações de tensão em função das flutuações de potência que romperam a rampa máxima.

Figura 48 – Quantificação das tensões acima do limite crítico em função das flutuações de potência acima de $r_{MÁX}$.

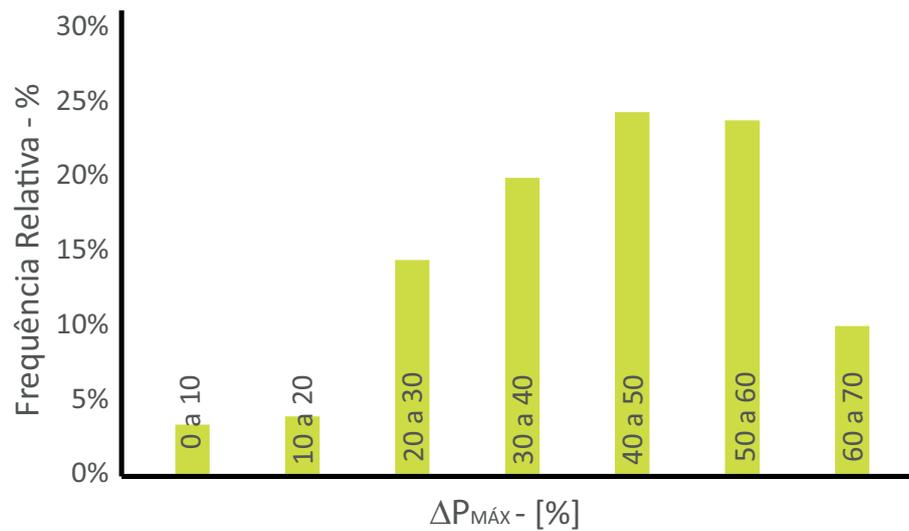


Fonte: O autor, 2021.

A Figura 48 deixa claro que as maiores ocorrências de violação de tensão estão interligadas às menores faixas de $r_{MÁX}$, onde foram encontradas os maiores índices de flutuações de potência. Ainda de acordo com o gráfico, mesmo diante da elevada frequência das flutuações de potência, ocorreram momentos de coincidência ocasionados pela dinâmica operacional intrínseca da rede, explicada pela atividade de algum dispositivo de regulação, e também pelas variações de cargas, interferindo na magnitude da tensão.

A segunda resposta para classificação das rampas mencionou a frequência relativa das ocorrências das flutuações de potência máxima no dia, separadas por classes. O gráfico da Figura 49 distribui todas as ocorrências levando em conta as rampas máximas diárias que foram verificadas ao longo do período analisado (Ano de 2020). A maior faixa percentual situou-se entre os grupos de 40 à 50%/min, obtendo uma representatividade de 25% do período total analisado.

Figura 49 – Frequência relativa da flutuação de potência máxima diária avaliada por um ano.

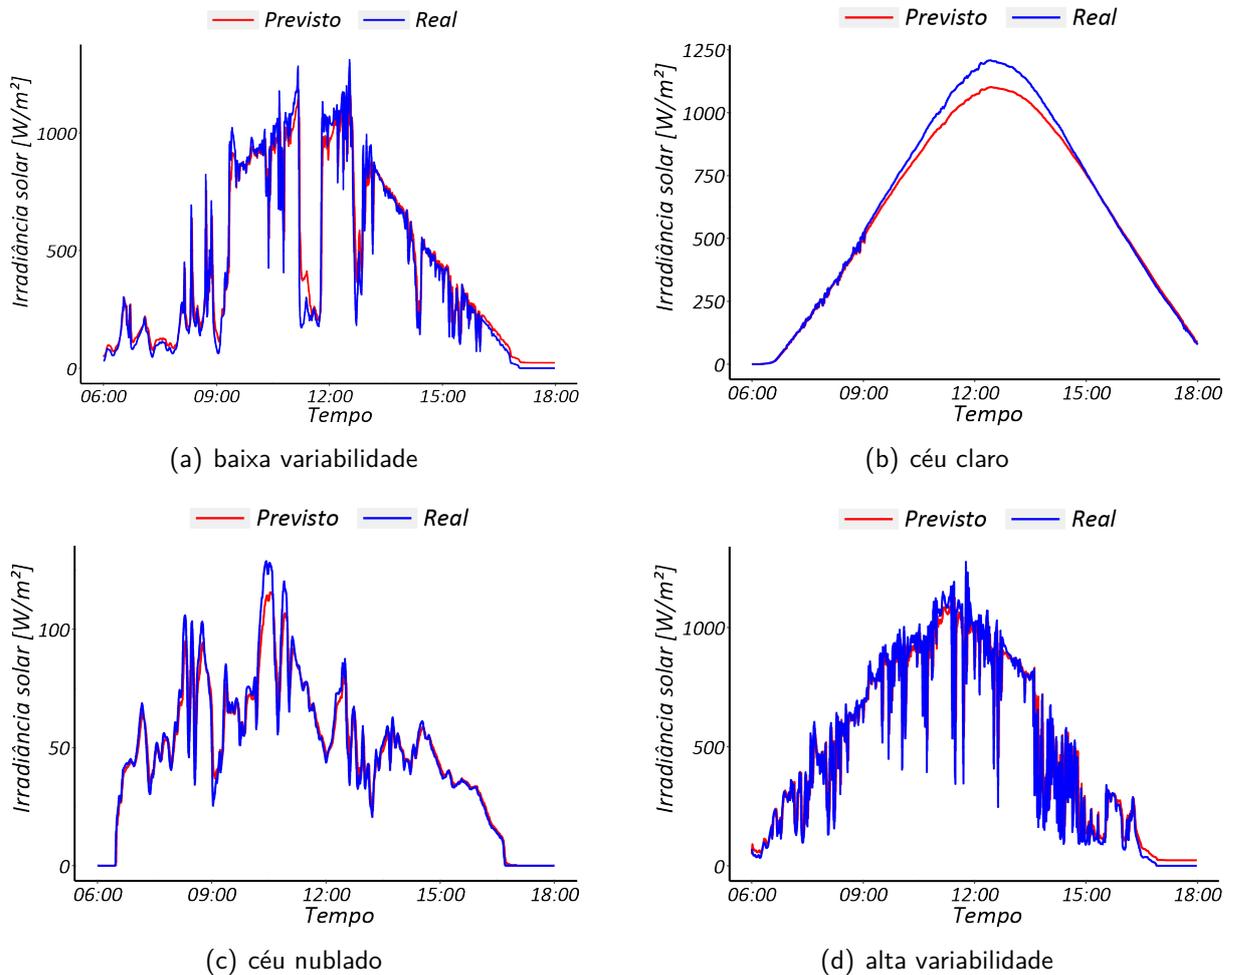


Fonte: O autor, 2021.

4.2.2 Previsão da irradiação solar e temperatura do módulo FV

A estimativa da irradiação solar e temperatura da célula do módulo fotovoltaico compõe a primeira tarefa do método, todos os resultados praticamente derivaram dessa etapa. Como o atributo estocástico da irradiação solar é muito recorrente em um contexto real, foi preciso manter o bom desempenho do sistema predictor, para que os resultados fossem entregues com a maior performance, fazendo com que as próximas etapas também atingissem o êxito. Por conseguinte, essa primeira etapa esclareceu o resultado obtido através da rede neural para os dias com as seguintes peculiaridades climatológicas: céu claro, céu nublado, baixa variabilidade e alta variabilidade. O RMSE calculado para os valores de saída da rede neural LSTM alcançou um valor de 78,52 W/m², junto a um coeficiente de determinação de 96%. Logo a seguir, na Figura 50, apresentam-se os gráficos referentes aos 4 dias típicos.

Figura 50 – Comparação entre a radiação predita e experimental.



Fonte: O autor, 2021.

Visualmente, o comparativo entre irradiação solar predita e a real demonstraram grandes semelhanças em seus comportamentos, que foram ratificadas estatisticamente pelo coeficiente de *Pearson*. A Tabela 10 individualiza os resultados para cada dia. Os parâmetros de desempenho foram comparados com os dados de irradiação solar, medidos na estação climatológica citados na etapa metodológica, Seção 3.1.3, junto ao sistema fotovoltaico em estudo. De forma complementar, a tabela 10 manifesta as informações de desempenho em torno das métricas estatísticas: RMSE, MAE e correlação (R), determinando assim o desempenho do sistema de previsão.

Tabela 10 – Performance da previsão da irradiação solar.

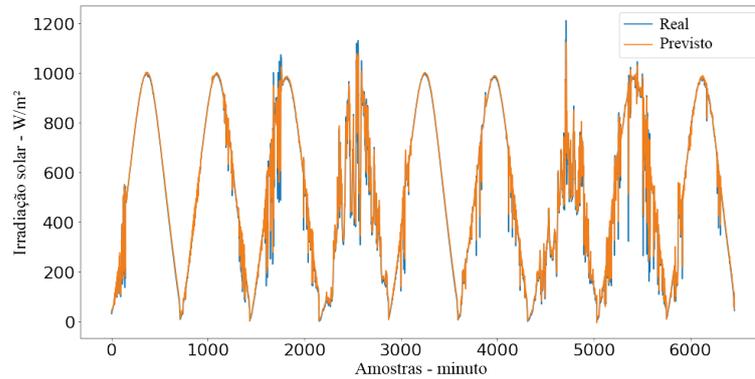
Dia	Classificação do Dia	RMSE (W/m²)	MAE (W/m²)	Pearson (R)
3 junho 2020	Baixa Variabilidade	96,39	58,03	0,96
20 junho 2020	Céu Claro	47,84	33,44	0,99
15 junho 2020	Céu Nublado	5,69	3,56	0,98
10 junho 2020	Alta Variabilidade	121,36	73,47	0,94

Fonte: O autor, 2021.

Face os índices na Tabela acima, o dia de alta variabilidade atestou um RMSE de 121,36 W/m², baixos valores para o RMSE foram atribuídos ao modelo de previsão quando este executou um dia com pouca variabilidade (Figura 50.d), dias de céu claro (Figura 50.b) e totalmente nublado (Figura 50.c). O coeficiente de correlação de *Pearson* se estabeleceu com um grau forte para o dia de céu claro, obtendo um valor de $R = 0,99$, mas com a presença da alta variabilidade, a intensidade do coeficiente de determinação foi reduzida para $R = 0,94$. Os dias típicos, com características mais determinísticas, possuíram no geral as melhores métricas de erro e correlação.

Os resultados encontrados nesse trabalho foram verificados e convergiram quando confrontados com pesquisas recentes advindas da revisão literária. Por exemplo, no trabalho de Campos Filho (2019) o autor encontrou um RMSE de 179,4 W/m² para um conjunto de 267 amostras de dados previstos de 1 minuto, o sistema de previsão utilizado baseou-se em processamento de imagens. No artigo publicado por Alzharani et al. (2017b), verificou-se um RMSE normalizado de 0,078 para uma rede neural LSTM, ressalta-se que o autor utilizou uma base de dados de 4 dias de medição da irradiação solar adquiridas de um sensor LI-200S, numa frequência de 100 HZ, sem especificar o tipo de céu. No artigo de Guariso, Nunnari e Sangiorgio (2020), foi realizado um teste de performance de alguns modelos de previsão, o autor secciona os resultados em um horizonte de curto prazo (5 minutos) para as três primeiras horas do dia, o RMSE obtido pela LSTM apenas com dados diários foi de 121,78 W/m², o fato interessante expõe que esse resultado foi bem próximo do valor encontrado para o dia de alta variabilidade. Nesse trabalho, a base de dados que o autor utilizou foi composta por 60% dos dados enquadrados como nublados e parcialmente nublados. Uma maior sequência de dias foi utilizada para consolidar o desempenho da rede neural na predição da irradiação solar. O erro médio absoluto para o conjunto de amostras esboçados graficamente pela Figura 51 se estabeleceu em 34,83 W/m².

Figura 51 – Amostra representativa entre os valores de predição e experimental da irradiação solar.



Fonte: O autor, 2021.

As técnicas aplicadas neste trabalho obtiveram respostas que enfatizam a importância da utilização de técnicas de inteligência artificial, principalmente as de aprendizado profundo, estimando a irradiação solar com um erro bem abaixo. Antes de adotar uma arquitetura permanente para a rede LSTM, foram efetuados vários testes com relação a janela deslizante de dados retroativos e a capacidade de previsão de dados à frente. Assim, foram utilizados uma variação de 20/60/100 (dados retroativos minuto a minuto da irradiação solar) e uma predição de poucos minutos à frente (1/2/5 minutos), com o isso, foi capaz de prever as variações da irradiação solar e verificar o efeito na componente elétrica entregue pelos painéis fotovoltaicos. A Tabela 11 elenca os valores dos erros, evidenciando a variação dos dados lidos e previstos.

Tabela 11 – Resultados de desempenho da rede neural LSTM em função dos parâmetros de entrada e saída.

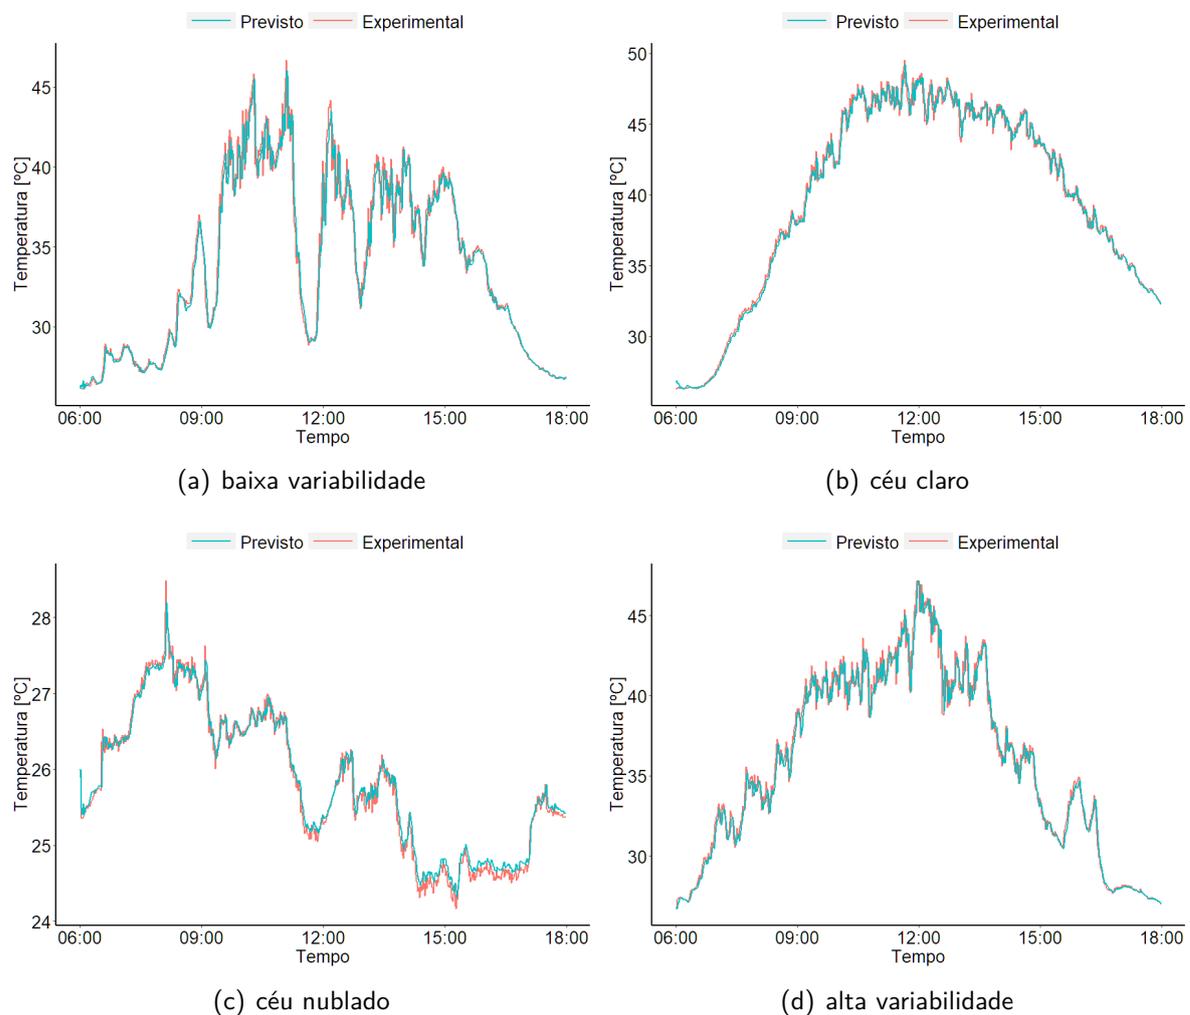
Dados Lidos	Dados Previstos	RMSE	MAE	Tempo (s)
20	1	78,52	34,83	0,78
20	2	92,38	44,74	0,58
60	1	78,84	34,14	1,40
60	2	93,22	45,60	0,60
60	5	113,22	58,10	0,67
100	1	80,96	36,02	3,60
100	2	100,95	53,32	5,25
100	5	114,05	60,58	3,88

Fonte: O autor, 2021.

Concomitantemente à predição da irradiação solar, efetuou-se a previsão da temperatura de operação do módulo FV, as duas informações servem de subsídios para o modelo matemático estimar a potência elétrica gerada. Em termos práticos, a rede neural provê um

conjunto de informações da irradiação solar e temperatura de operação do módulo FV para os respectivos dias de interesse. Similarmente a estratégia de previsão da irradiação solar, utiliza-se uma janela temporal de 20 amostras do tempo antecedente da temperatura para estimar 1 minuto à frente. Na Figura 52, seguem as perspectivas gráficas dos resultados obtidos pelo sistema preditor comparados aos medidos experimentalmente. O formato da análise desempenhada nesta seção obedece a mesma sequência de dias utilizada no estágio de previsão da irradiação solar.

Figura 52 – Resultados da temperatura de operação do módulo fotovoltaico, esboçando o perfil previsto e experimental.



Fonte: O autor, 2021.

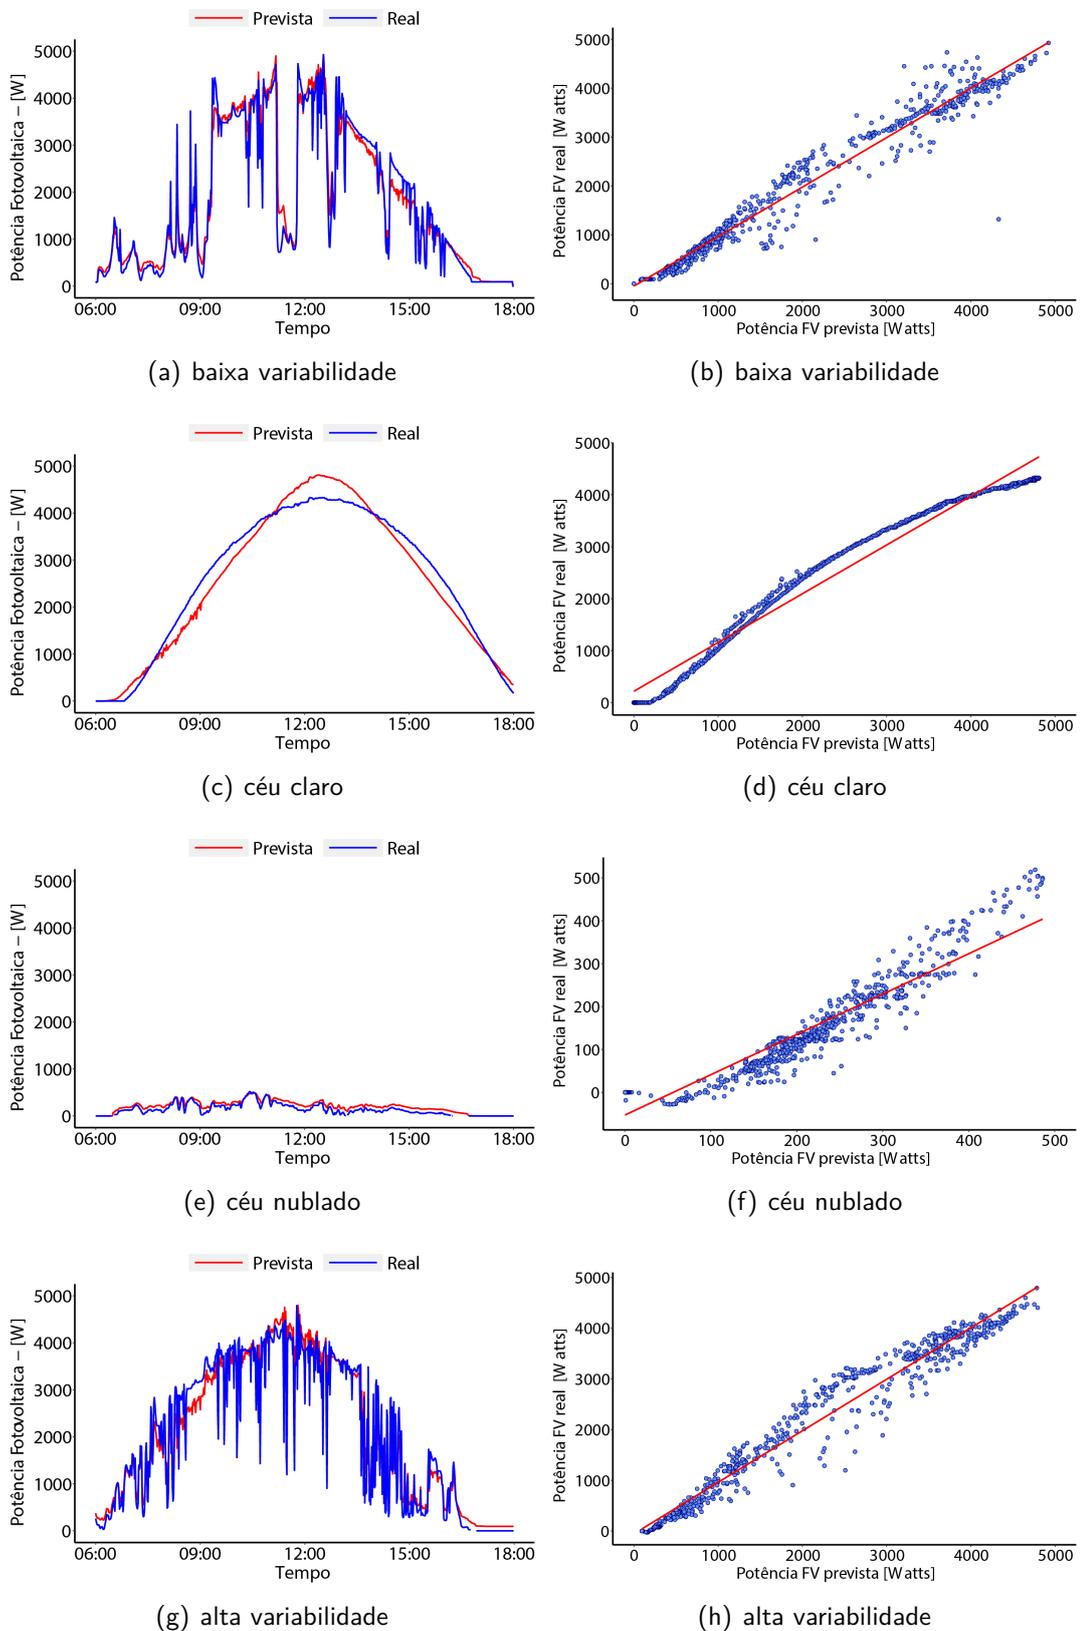
A comparação entre os dados previstos e experimentais também foram confrontados a partir das métricas de performance. Observou-se que em dias com baixa e alta variabilidade da irradiação solar, houve variações na amplitude térmica; portanto, exclusivamente para esses dias, o RMSE entre o valor previsto e experimental, atingiu um valor de 0,80 °C e 0,69

°C, respectivamente. Assim como observado para irradiação solar, no dia de céu claro, o RMSE ficou próximo de 0,41 °C, para o dia de céu nublado o RMSE calculado foi de 0,13 °C, proporcionando melhor desempenho da rede neural, essa particularidade foi atribuída as menores variações na amplitude térmica ao longo dia. O confronto realizado com relatos da literatura buscaram avaliar o desempenho do modelo em função do tamanho da janela de dados observados. Chevalier et al. (2011) obteve uma melhor performance da rede utilizando 24 dados de observações passadas. Assim também, em Smith (2002), o autor validou uma rede neural artificial utilizando a mesma janela de dados baseada no tempo passado. Na Tese de Sabino (2019), o autor encontrou um RMSE entre 0,6 °C à 1,6 °C variando em um horizonte de tempo de 1 hora até 24 horas. No entanto, as métricas estatísticas evidenciadas nesse trabalho estão de acordo com os achados na literatura, viabilizando dessa forma a aplicação desses resultados nas próximas etapas da pesquisa.

4.2.3 Análise da potência fotovoltaica

Nesta etapa do estudo, os valores de potência previstos referente ao gerador fotovoltaico de 5 kWp foram obtidos tomando como base os valores de irradiação e temperatura do módulo estimados pela rede neural. Os respectivos *shapes* de entrada previstos foram submetidos no programa *OpenDSS*, estimando assim a potência instantânea fornecida pelo gerador FV. Os gráficos da Figura 53 realizam a comparação entre os dados reais monitorados por um transdutor de potência ativa na saída do inversor, com a potência estimada em ambiente computacional. Tanto os dados simulados (*Nowcasted*), quanto os medidos, foram exibidos a cada 1 minuto.

Figura 53 – Resultados das simulações dos perfis de potência fotovoltaica comparado com os dados mensurados.



Fonte: O autor, 2021.

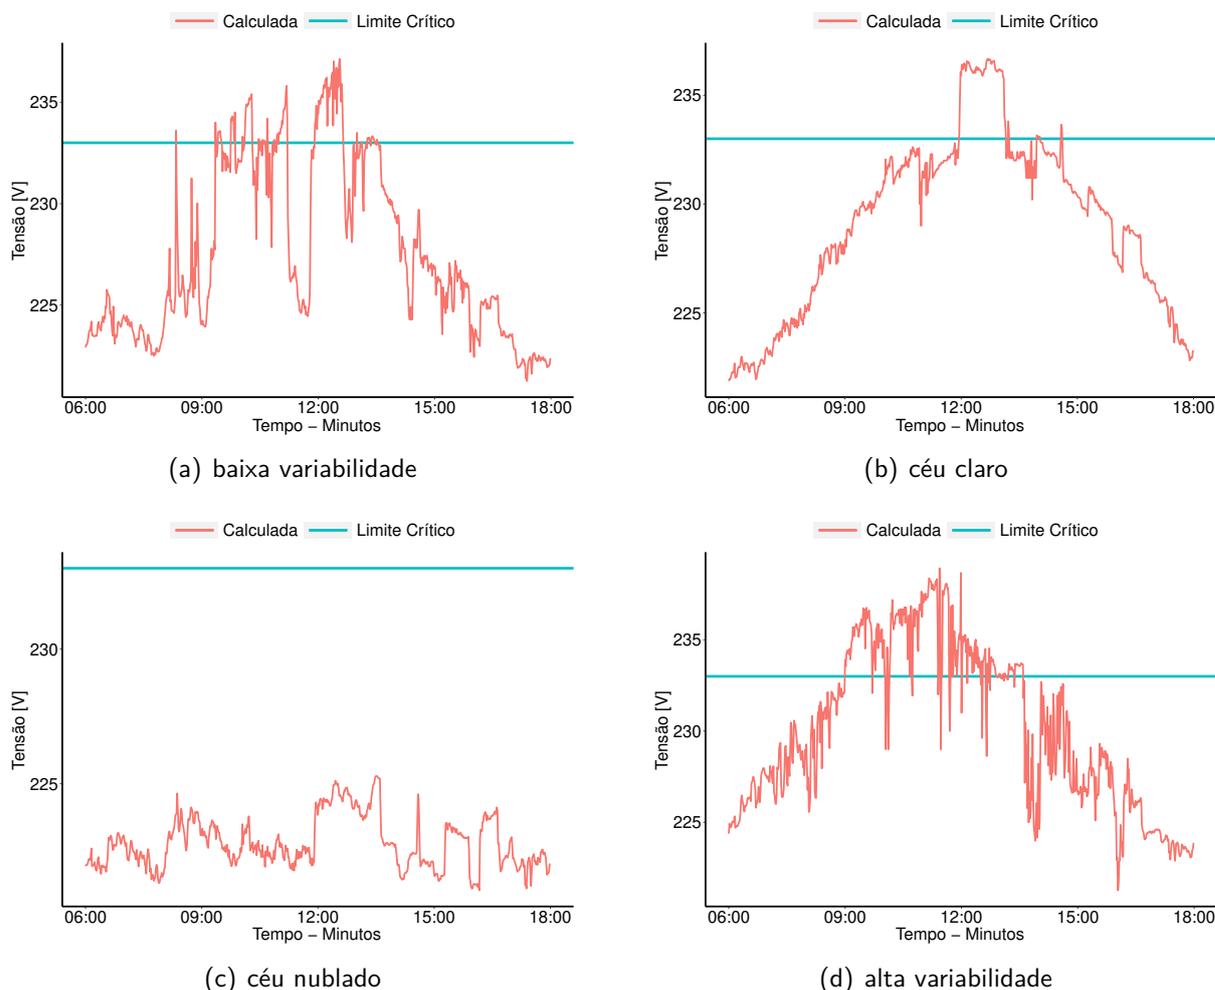
O fluxo de potência apresentado na forma gráfica da Figura 53, esboça à esquerda o comparativo das potências elétricas experimentais (reais) e previstas (*nowcasted*) à direita visualiza-se a linearidade através da correlação de *Pearson* para as variáveis observadas em cada dia. De forma semelhante ao que se deu com a irradiação solar na seção anterior, ao se comparar as curvas de potência real e prevista observou-se um RMSE de 77,29 W em dia de céu nublado, enquanto para o dia de céu claro atingiu um RMSE de 230,91 W. O coeficiente de correlação de *Pearson* para cada dia, resultou em 0,98 e 0,93 em dias de céu claro e nublado, respectivamente. O dia de céu nublado se apresentou com o menor RMSE, mas o baixo valor para o coeficiente de correlação pode estar associado ao transdutor de medição, visto que para baixas condições de carregamento o sensor pode estar registrando os valores abaixo da sua faixa de exatidão.

A potência do gerador fotovoltaico não equivale necessariamente a potência efetivamente injetada na rede elétrica, para discretizar a energia injetada na rede foi necessário conhecer a curva de demanda. Atualmente no Brasil, não há limites para injeção de potência, ressalvado apenas pelas condições de projeto da rede elétrica mediante sua capacidade de suporte ao fluxo de potência. Novas tendências estão em estudo, como é o caso da tecnologia "Grid Zero", servindo para limitar ao máximo a potência injetada na rede elétrica. Nesse trabalho, as curvas de demanda foram monitoradas durante todo o período da campanha de medição, assim, para o intervalo de coleta, os valores da potência injetada quase sempre se aproximaram da potência gerada, isso aconteceu pelo fato da curva de demanda ser relativamente muito baixa durante o período de irradiação solar.

4.2.4 Verificação da tensão e potência injetada

Quando o conceito de estabilidade remete-se ao grande sistema elétrico, um conjunto de dispositivos harmonizam-se coordenadamente para garantir a qualidade de energia elétrica em níveis confiáveis de tensão elétrica. Em redes de distribuição secundárias, exclusivamente no âmbito da baixa tensão, não há dispositivos de intervenção para regular a tensão em todo o percurso do alimentador até o ponto de entrega ao consumidor final. Nesse sentido, a verificação do estado da rede foi verificada mediante a solução do fluxo de potência no software *OpenDSS*. Logo abaixo ilustra-se através do gráfico da Figura 54 o perfil da tensão elétrica sob a influência da intermitência solar, exibindo os resultados com relação ao limite crítico.

Figura 54 – Perfil da tensão de acoplamento para cada tipo característico da irradiação solar.



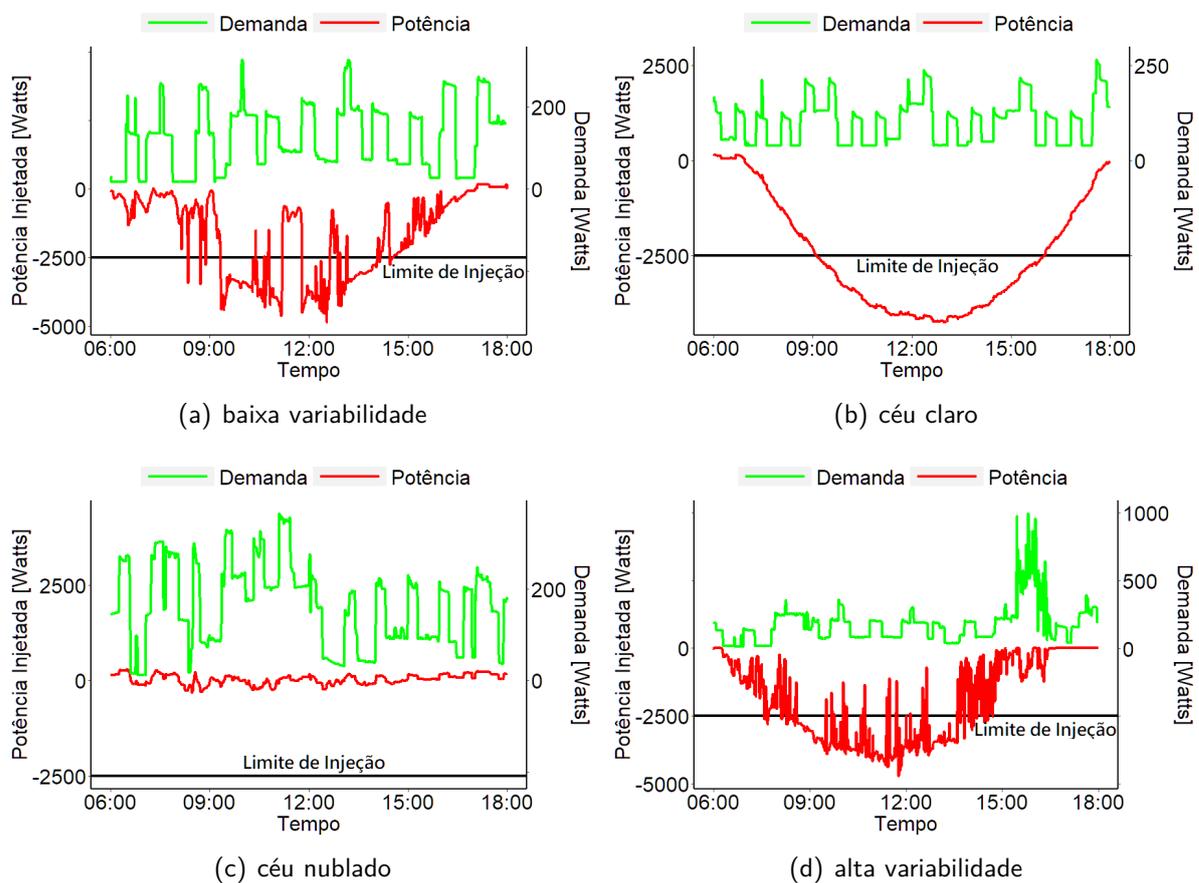
Fonte: O autor, 2021.

Os pontos analisados evidenciaram as ultrapassagens do limite crítico da tensão. Nessa etapa, o método proposto (Figura 29) enquadrou os valores calculados na condicional que verificou se a tensão de operação excedeu a tensão crítica, ao observar cada gráfico na Figura 54, constatou-se que o rompimento do limite crítico da tensão esteve compreendido majoritariamente entre o período horário das 9 às 15 horas, justamente nos momentos em que houve a máxima irradiação solar. Considerando o período do tempo analisado, 33% e 16% do tempo, ocorreram violações da tensão no limite crítico, pra os dias de alta e baixa variabilidade respectivamente. O dia de céu claro manteve-se com 12% do tempo total com valores de tensão acima do permitido. O dia de céu nublado, por vez, operou por todo o período dentro da faixa tolerável. O baixo carregamento das unidades consumidoras durante demasiadas taxas de irradiação solar, favoreceu para o surgimento de sobretensões.

A simulação do fluxo de potência para o estado da rede utilizou como dados de carga

a série temporal da curva da demanda para os respectivos dias. Essa combinação de fatores propiciou a intensificação da potência injetada na rede, entregue na forma do fluxo reverso de potência, sendo este, o outro fator que justificou as ultrapassagens da tensão de operação. Com a confirmação da tensão nominal acima da tensão crítica, a próxima etapa do método realizou o cálculo da potência injetada, condicionando-a ao limite de permissão da potência injetada ($P_{inj-limite} = 2500 \text{ W}$) predefinida anteriormente. Para cada dia, a Figura a seguir mostra o fluxo reverso ($P_{dinamica(t)}$) observando os momentos que tem-se a ultrapassagem do valor de $P_{inj-limite}$.

Figura 55 – Cálculo do fluxo de potência reverso observado pelo rompimento do limite de permissão de potência evidenciando o perfil de demanda.



Fonte: O autor, 2021.

O gráfico revela a informação da demanda para cada dia, a fim de relacionar com a potência injetada instantânea. Em termos práticos, o dia nublado foi o único o qual não observou-se fluxo de potência reversa, sendo proporcional ao baixo índice da irradiação solar, suprindo totalmente a demanda da UC. Estando a potência injetada abaixo do limite de permissão de potência, o processo foi finalizado justamente na etapa condicional de verificação

do limite crítico. Já os dias com maior atividade da irradiação solar, dias com alta variabilidade, obtiveram 30% a mais das ocorrências de ultrapassagem do limite de potência quando comparado ao dia de baixa variabilidade. O dia de céu claro superou o dia de alta variabilidade em ocorrências de ultrapassagem do limite da potência, atingindo 33% a mais de ocorrências que o dia de alta variabilidade. A Tabela 12 abaixo, expõe as métricas de sobretensão e sobre potência em função do período de tempo total analisado.

Tabela 12 – Informações das ocorrências de sobretensão e potência acima do limite de permissão de potência definido.

Dia	Classificação	$V_N > V_{crítica}$	$P_{inj} > P_{inj-limite}$
3	Baixa Variabilidade	16%	33%
10	Alta Variabilidade	33%	43%
15	Nublado	0%	0%
20	Céu Claro	12%	58%

Fonte: O autor, 2021.

Por outro lado, de acordo com os dados da Tabela acima, há um comportamento inverso no dia de céu claro ao se comparar a faixa percentual de $P_{inj} > P_{inj-limite}$ com as informações da classe $V_N > V_{crítica}$, tomando os demais dias. Essa questão está relacionada ao perfil característico da irradiação solar. A literatura enfatiza exaustivamente partindo de uma ótica quantitativa, quando se trata do recurso solar. O cenário ideal considera que os SFVCR operem em pleno carregamento durante todo período de sol, esse fato só é possível caso não haja obstruções momentâneas e transitórias da passagem da luz solar. Fenômenos como passagens de nuvens e composição atmosférica são fatores realísticos para a condição da intermitência da irradiação solar, consequentemente afetando os geradores fotovoltaicos; ressalta-se também que esses aspectos divergem de um local para o outro, podendo ser mais agravado em locais mais específicos. No contexto da qualidade do fornecimento da tensão elétrica, é importante que novos estudos relacionados não somente do ponto de vista quantitativo do recurso solar, mas sim da qualidade deste recurso sejam cada vez mais uma realidade.

Em termos de qualidade da tensão, de acordo com os cenários simulados, verifica-se que a probabilidade de ocorrências de sobretensão aumenta com frequência da intermitência da irradiação solar, tal afirmação pode ser vista ao observar o quantitativo das tensões nominais que ultrapassaram o limite crítico, registrado na Tabela 12, para a classificação de baixa e alta variabilidade. A classificação da alta variabilidade situa-se numa zona criteriosa para formulação da estratégia de mitigação dos problemas associados a alta variabilidade do recurso solar.

4.2.5 Análise do perfil de tensão

Nesta etapa, a potência necessária para atuação direta do sistema de armazenamento no ponto de acoplamento comum, comportou-se semelhante ao acionamento de uma carga. Mediante o fluxograma do método proposto para a mitigação da tensão de curto prazo, o acionamento do banco foi interposto em função das combinações entre o limite crítico da tensão e o limite de injeção de potência, ocorridos simultaneamente, observando a violação dos limites críticos para cada variável. A Tabela 13 dispõe das descrições estatísticas para cada dia, abordando os eventos simultâneos ocorridos para cada classe. A contabilização desses dados levaram em conta um total de 12 horas simuladas, com 720 amostras por minuto para cada dia.

Tabela 13 – Resumo das ocorrências simultâneas.

Dia	$V_N > V_{crítica}$	$V_N < V_{crítica}$	$V_N > V_{crítica}$	$V_N < V_{crítica}$
	$P_{inj} > P_{inj-limite}$	$P_{inj} > P_{inj-limite}$	$P_{inj} < P_{inj-limite}$	$P_{inj} < P_{inj-limite}$
3	15%	18%	0%	67%
10	31%	11%	0%	58%
15	0%	0%	0%	100%
20	11%	46%	0%	43%

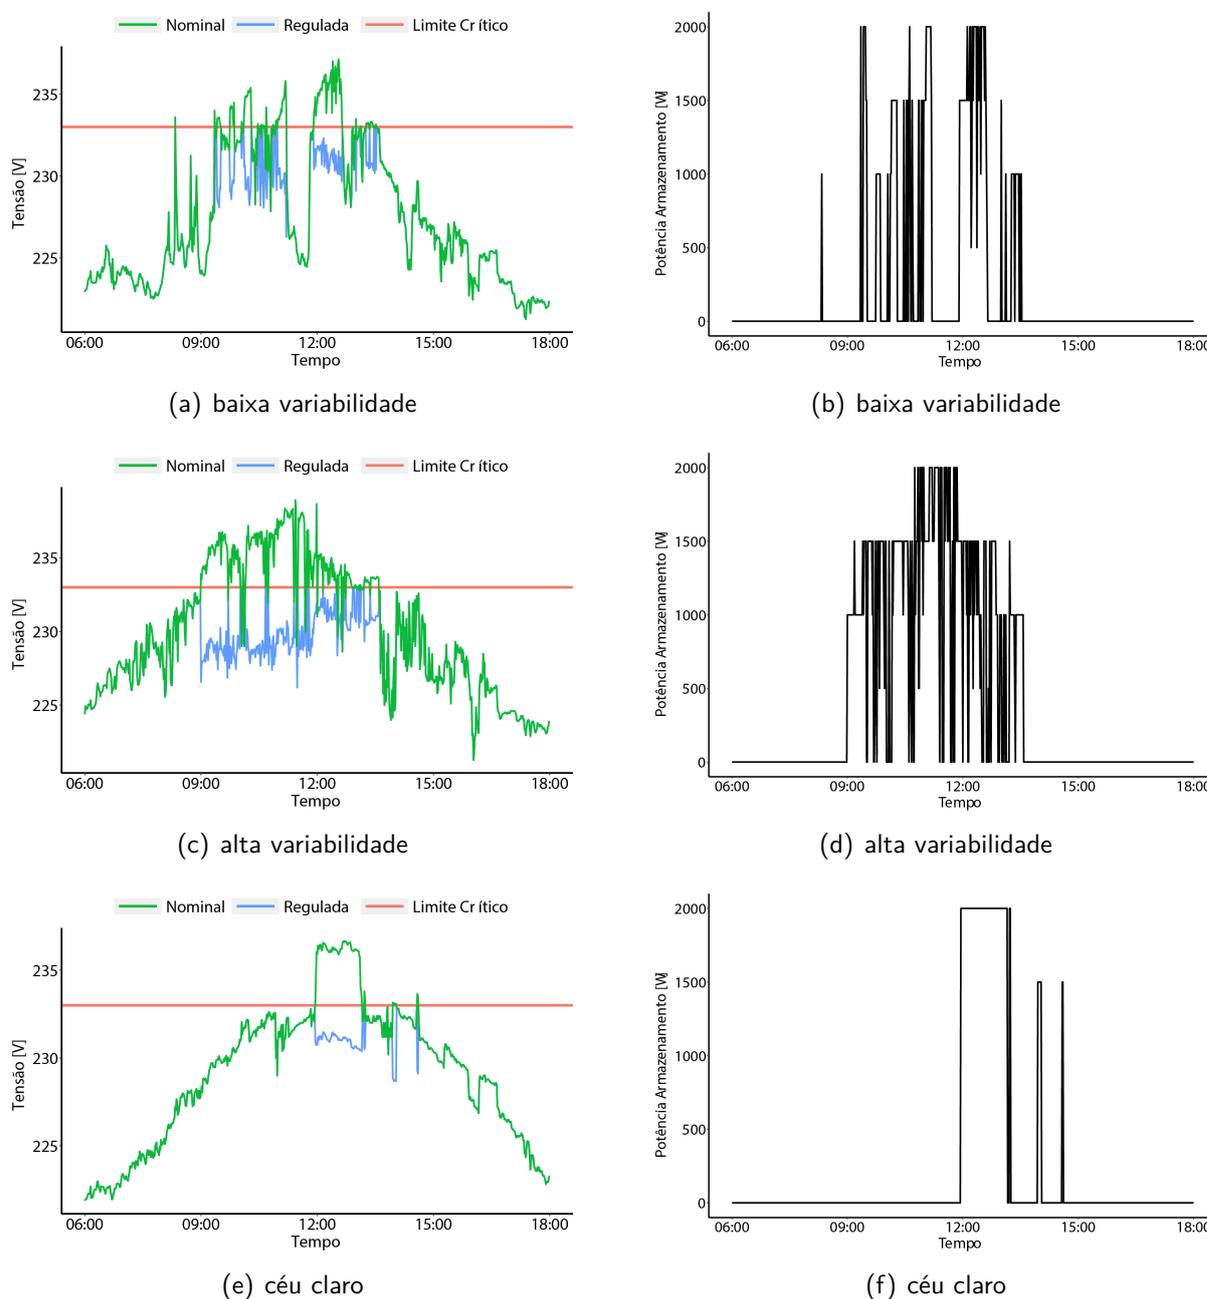
Fonte: O autor, 2021.

A Tabela 13 revela a seguinte situação, tomando o dia 20 (céu claro) como exemplo, o total de eventos onde a potência injetada ultrapassou a potência limite ($P_{inj} > P_{inj-limite}$) e a tensão nominal esteve abaixo do limite de tolerância ($V_N < V_{crítica}$), em condição simultânea foi de 46%. Para o mesmo conjunto de dados, no dia de alta variabilidade o percentual caiu drasticamente. Isso se deu pelo fato de que, para o dia de céu claro, a variabilidade de potência é praticamente zero, assim, estando a potência do gerador fotovoltaico em intensa amplitude, não foram notadas variações bruscas em sua amplitude. Já o dia 10 (alta variabilidade) apresentou maior ocorrência simultânea de sobretensão e de valores de P_{inj} acima do limite permitido; esse aumento é especificamente atribuído a forte presença da variação abrupta da potência na saída do inversor, oriunda da intermitência solar.

Os eventos simultâneos destacados na Tabela 13 são mitigados pelo SAE, ao observar a Figura 56, os gráficos situados à esquerda retratam o efeito dinâmico da inserção do sistema de armazenamento na rede. A curva verde concebe o perfil da tensão nominal apenas sob a influência do sistema fotovoltaico. A curva azul remete ao perfil de tensão atenuado pelo SAE.

A composição das imagens da Figura 56 foi elaborada aos pares, concatenando o gráfico da tensão com o respectivo gráfico de potência drenada para cada dia, realizado pelo SAE.

Figura 56 – Comparação entre a tensão nominal e a tensão regulada após o armazenamento de energia.



Fonte: O autor, 2021.

A forte relação entre a tensão acima do limite crítico no ponto de fornecimento e o fluxo de potência reverso, foi bastante evidente em todos os cenários. Ao tomar como exemplo o dia de alta variabilidade, o sistema de armazenamento drenou aproximadamente 5042 Wh de energia elétrica, esse quantitativo correspondeu à 22,56% da energia útil que seria injetada na rede de distribuição pelo sistema fotovoltaico. O dia de céu claro, destacado por apresentar um

grande volume de produção de eletricidade, conseguiu minimizar o armazenamento de energia elétrica na bateria. A energia total injetada pelo dia de céu claro foi de 29976 Wh, diante da necessidade de se estabilizar a tensão momentaneamente, o sistema de armazenamento absorveu 2733 Wh da eletricidade produzida pelo gerador fotovoltaico, correspondendo à 9,12% do volume da energia total. É normal que se questione o porquê do dia de céu claro minimizar a quantidade de energia, a resposta está atrelada às taxas de rampas de potência na saída do gerador fotovoltaico, o dia de alta variabilidade é responsável por induzir demasiadamente a ocorrência de sobretensões no ponto de fornecimento, em contrapartida, o dia de céu claro, por mais que a potência injetada seja superior ao limite máximo, a injeção acontece similarmente a uma rampa controlada, de forma suave. A Tabela 14 apresenta o custo energético (Wh) estabelecido para cada nível de potência do SAE, cabe ressaltar que os valores explicitados na tabela ainda não representa a capacidade efetiva do SAE.

Tabela 14 – Custo energético efetivo do SAE por nível de potência.

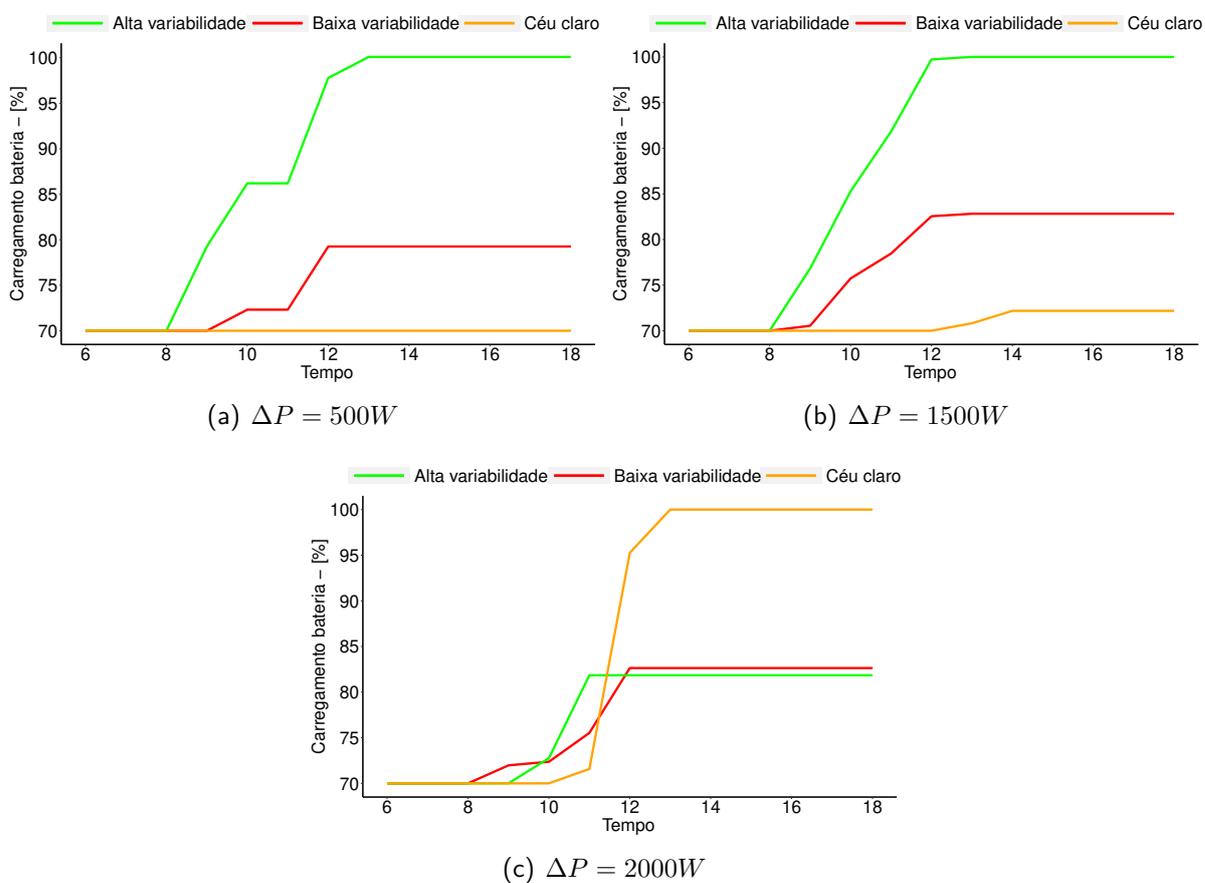
Tipo de Céu	$C_{BAT}(Wh)$	$C_{BAT}(Wh)$	$C_{BAT}(Wh)$	$C_{BAT}(Wh)$
	ΔP_{BAT}	ΔP_{BAT}	ΔP_{BAT}	ΔP_{BAT}
	500W	1000W	1500W	2000W
Baixa Variabilidade	33	483	1175	1066
Alta Variabilidade	108	1183	2750	1000
Céu Claro	0	0	200	2533

Fonte: O autor, 2021.

Como pode ser visto, a quantidade de energia elétrica por nível de potência é bastante dispersa para os perfis da irradiação solar. O dia de alta variabilidade atinge o maior patamar de carregamento nos estágios de 500 W, 1000 W e 1500 W. Para o grupo $\Delta P = 500W$, o dia de alta variabilidade necessitou de 225% de energia a mais, quando comparado ao dia de baixa variabilidade, o dia de céu claro não atuou nesse patamar de potência, permanecendo em modo ocioso. Ainda evidenciando o dia de alta variabilidade, o mesmo se sobressai ao dia de baixa variabilidade, com a necessidade de maior capacidade de armazenamento para os níveis de $\Delta P = 1000W$ e $\Delta P = 1500W$, estabelecendo um percentual de 145% e 134%, respectivamente. De outra forma, o $\Delta P_{BAT} = 2000W$ atingiu o nível máximo de carregamento da bateria para o dia de céu claro. A necessidade de armazenamento de energia foi superior em 153% para o dia de alta variabilidade e 137% para o dia de baixa variabilidade. O prolongamento da vida útil das baterias está atrelado ao controle e monitoramento do estado da carga e profundidade de descarga. A tarefa de estabilização da tensão por desvio do fluxo de

potência leva o sistema de armazenamento a operar passivamente, em modo de carregamento. A cada estágio de carga, o ciclo precisa ser completado com a descarga, sempre preparando a bateria para o dia seguinte e mantendo a mínima capacidade. A Figura 57 ilustra o perfil de carregamento para cada nível de potência a partir do estado de carga de 70% para os demais níveis de potência, o perfil de carregamento de SAE ao longo do dia foi determinado em função dos valores de energia úteis apresentados na Tabela 14.

Figura 57 – Monitoramento do estado da carga do sistema de armazenamento por grupo de baterias, observando as condições de contorno da irradiação solar.



Fonte: O autor, 2021.

Exceto para $\Delta P = 2000W$, o dia de alta variabilidade apresentou o máximo valor do estado da carga para os demais grupos de potência, diante dessa afirmativa a tabela 15 exhibe os valores da capacidade de armazenamento para cada grupo de potência do SAE, restringindo o uso da energia a manutenção do estado de carga mínimo de 70% e 10%.

Tabela 15 – Tamanho do banco de baterias em Wh para cada nível de potência (ΔP) restrita às condições de carga.

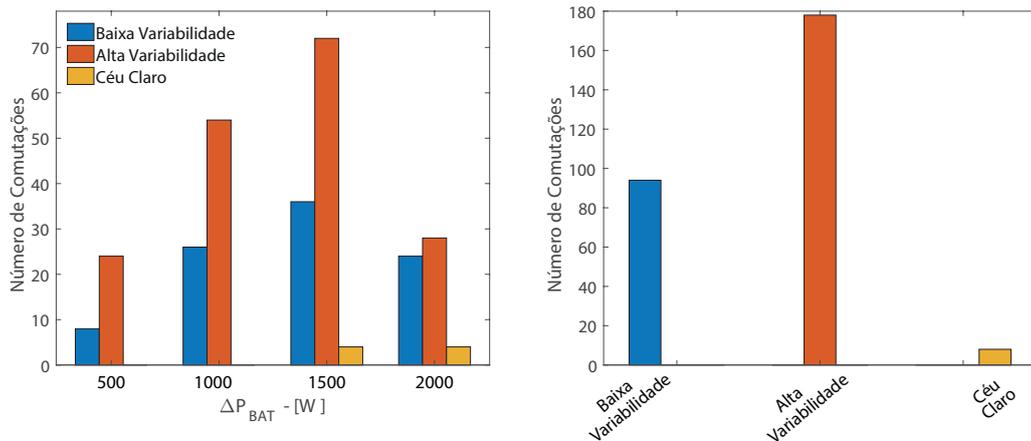
Estado de Carga	$C_{BAT}(Wh)$	$C_{BAT}(Wh)$	$C_{BAT}(Wh)$	$C_{BAT}(Wh)$
	ΔP_{BAT} 500W	ΔP_{BAT} 1000W	ΔP_{BAT} 1500W	ΔP_{BAT} 2000W
Restrição de 70%	361	3944	9167	8444
Restrição de 10%	120	1315	3056	2815

Fonte: O autor, 2021.

Os valores de base utilizados para compor o tamanho do banco de baterias foram extraídos da Tabela 14, evidenciando o maior carregamento para cada nível de potência, a partir disso, admitiu-se diferentes níveis de profundidades de descargas. Para a Tabela 15, visualiza-se que para uma taxa de descarga de 90% a energia disponível para mitigar os efeitos da sobretensão foi relativamente menor quando comparado a uma taxa de descarga de 30%; do ponto de vista econômico esse aspecto foi bastante positivo, porém, relevando os aspectos técnicos no cenário de maior profundidade de descarga, a vida útil da bateria pode ter a expectativa diminuída. Em Paixão (2020), foi recomendado que uma bateria não seja frequentemente utilizada abaixo dos 10% de carga. Nesses moldes, é importante avaliar as particularidades técnicas e financeiras, para obtenção de um sistema de armazenamento que atenda tanto aos requisitos mínimos de manutenção da tensão, preocupando-se também com o prolongamento da vida útil das baterias do SAE.

Um outro aspecto analisado foi o número de comutações necessárias para a integração das baterias ao sistema elétrico. Semelhante ao que acontece com os reguladores de tensão convencional, o excessivo número de comutações pode impactar negativamente na vida útil do equipamento, bem como no seu desempenho operacional. Visto que o SAE trabalha sob comutação de grupos de baterias, a Figura 58 ilustra o quantitativo de comutações desempenhado para cada ΔP_{BAT} utilizado para cada tipo de perfil de variabilidade de potência.

Figura 58 – Quantitativo de disparos efetuados por cada nível de armazenamento.



Fonte: O autor, 2021.

Fixando o dia de alta variabilidade, foi nítido o alto índice de comutações em toda faixa de potência, atingindo o maior número em $\Delta P_{BAT} = 1500W$, nesse mesmo grupo de potência, a quantidade de comutações ultrapassou em 100% o total de comutações referente ao dia de baixa variabilidade. Alguns estudos comprovaram que a alta taxa da intermitência solar, promove a comutação excessiva dos OLTC's (GRANZOTO; FERREIRA; TRINDADE, 2016), diminuindo sua eficiência (MAHMUD; ZAHEDI, 2016), reduzindo também a vida útil do dispositivo (ARI; BAGHZOUZ, 2011).

4.2.6 Desempenho da estratégia de mitigação

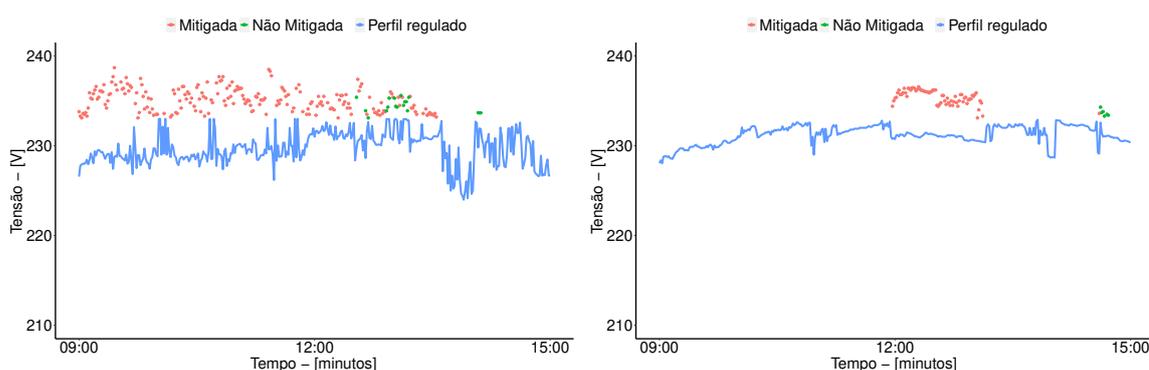
Até o momento, os resultados foram discutidos com base nas respostas das etapas calculadas pelo método proposto. A campanha de medição real das variáveis fornecem subsídios para que se realize comparações entre os dados de tensão real e o calculado, fornecendo informações sobre a acurácia do método proposto. O desempenho do método proposto, baseia-se no parâmetro de acerto para os dados de tensão calculado na simulação do fluxo de potência, os dados foram concatenados com os valores experimentais, aferidos no experimento. O critério de validação comparou os dados da tensão simulada e experimental que superou o limite da tensão crítica.

Como a modelagem do alimentador se restringiu somente ao trecho do circuito de alimentação secundária, grande parte dos efeitos na tensão estão submetidos às condições de carregamento, impedância da rede e dos ramais, tamanho do gerador fotovoltaico e as condições de irradiação solar. Perante essas informações foi possível identificar o momento

que realmente a variabilidade da geração fotovoltaica altera a qualidade da tensão no ponto de entrega de um consumidor, independente de qualquer equipamento, como regulador de tensão ou banco de capacitor.

Diante da análise preliminar no parágrafo anterior, as rampas calculadas foram comparadas com os valores reais, possibilitando dessa forma mensurar o desempenho do método proposto caso estivesse operando em uma situação real. O gráfico da Figura 59 concatena as informações de tensão regulada (curva azul), obtida pelo método proposto, os pontos nas cores vermelha e verde sinalizam os valores da tensão real que foram mitigados pela estratégia proposta e os não mitigados, respectivamente. A análise comparativa absorveu 360 pontos, situados entre a faixa das 9 horas às 15 horas, motivada pela influência da irradiação solar.

Figura 59 – Perfil comparativo entra a tensão real e calculada obtida pelo método proposto para os dias de alta variabilidade e céu claro



(a) Desempenho do método - Dia de alta variabilidade

(b) Desempenho do método - Dia de céu claro

Fonte: O autor, 2021.

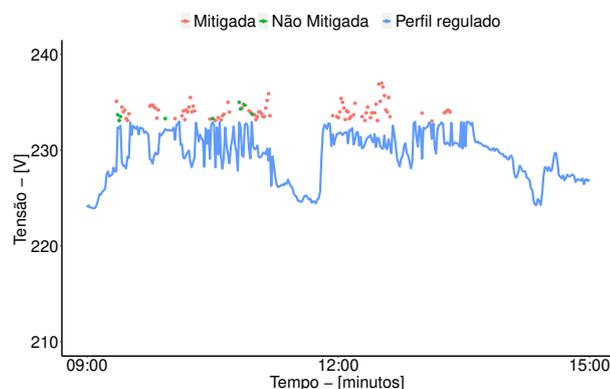
Inicialmente, o desempenho do sistema de armazenamento foi mensurado partindo do parâmetro de acerto, para isso foram computadas as situações onde o sistema de armazenamento disparou, ou então quando esteve em modo ocioso, ou seja, quando o sistema não disparou em consequência dos valores calculados permanecerem abaixo do valor crítico, garantindo a normalidade do sistema. Feito isso, o dia de alta variabilidade conseguiu um índice de acerto de 88,09%. Os disparos referentes ao acerto da tensão calculada podem ser vistos no gráfico da Figura 59.a, para o índice de acerto, 58,73% referiu-se aos disparos efetivos e 29,36% é o percentual de acerto por inatividade, interpreta-se que o sistema ficou em modo de operação ocioso. O percentual do erro global ficou em torno de 11,91%, para esse índice, o método sobrestimou ou subestimou o valor da tensão calculada, desse modo, foi certificado para os valores de tensão subestimados ($V_{Calculada} < V_{Real}$) um percentual de 4,99% da taxa

de erro global, já o erro por sobrestimativa ($V_{Calculada} > V_{Real}$), compreendeu um percentual de 6,93% do erro global.

Procedeu-se da mesma forma para o dia céu claro, onde foi obtida a maior performance do sistema de armazenamento. A taxa de acerto para este dia atingiu um valor de 95,01% do conjunto de dados, para essa condição a taxa de acerto foi performada pelo modo ocioso, responsável por compor 75,35% da taxa total de acertos, os 19,67% complementam a taxa de acerto mediante os disparos efetivos do sistema de armazenamento. O erro para o dia de céu claro foi relativamente inferior quando comparado ao dia de alta variabilidade, pautando-se nas mesmas métricas de sobretensão e subtensão estimadas, a primeira se estabeleceu na menor composição do erro, com valor de 1,66%, os valores subestimados da tensão contemplam 3,32% do erro total.

Relativamente, notou-se o baixo desempenho do método sob as condições de alta variabilidade da irradiação solar. Os pontos denotados nos gráficos da Figura 59 já exprimem visualmente a percepção do erro por ausência de disparos. O fato da simulação não representar completamente todos os eventos que interferem na rede de distribuição, uma perturbação aleatória, mesmo que transitória, pode ter refletido na dinâmica da tensão real, e assim, a simulação divergiu pontualmente do cenário real. Entretanto, houve a forte coerência entre os resultados de desempenho em comparação aos estudos que utilizaram outras técnicas e que avaliaram os impactos na tensão de uma rede de distribuição. Ao citar o dia de céu claro e alta variabilidade, A Figura 60 estabelece a comparação entre a tensão regulada pelo sistema de armazenamento e o perfil da tensão que ultrapassaram o limite crítico para o dia de baixa variabilidade.

Figura 60 – Perfil comparativo entra a tensão real e calculada obtida pelo método proposto para o dia de baixa variabilidade.



Fonte: O autor, 2021.

Os índices de desempenho para este dia comprovaram o efeito da influência do perfil da irradiação solar, constatado pelos índices de acerto e erro. Os dois índices se estabeleceram em 91,41% e 8,58%, para o critério de acerto e erro, respectivamente. Ao comparar o dia de baixa variabilidade com os dois últimos dias analisados, dentre uma faixa de ranqueamento, o dia de baixa variabilidade posicionou-se como o segundo dia com maior taxa de acertos, permanecendo atrás do dia de céu claro. Ao refletir essa discussão com alguns estudos presentes na literatura, há um consenso no objetivo em mitigar o problema da sobretensão causado pela variabilidade da geração fotovoltaica ou da elevada intensidade do fluxo reverso de potência.

5 CONCLUSÕES

Preliminarmente, esse trabalho avaliou o estado da rede de energia quando um SFVCR operou sob a condição de céu claro e a baixo patamar de carregamento. O método de estudo proposto foi personalizado com as ações específicas para cada rotina, após a entrega dos resultados, foram sugeridas as técnicas que possibilitaram a tomada de decisão em função do cenário mais adequado. Ao final, foi testado a partir de dois cenários de simulação, respeitando os requisitos técnicos da concessionária local, para conexão de SFVCR monofásicos e trifásicos.

O primeiro caso de teste empregou os SFVCR's de 5kWp, onde para um número máximo de 6 conexões à barra, foram inseridos 33%, 66% e 100% de geradores fotovoltaicos, diante disso, foram extraídos os perfis de tensão para cada subcaso, confrontando-os com os limites críticos da norma. Para o caso 1, a inserção de 100% de unidades geradoras na barra levou ao surgimento de tensões acima do limite crítico (233V) na UC 78. O segundo caso de simulação também considerou a mesma metodologia, porém com o dobro de potência para os SFVCR's (10kWp), nesse contexto, para o mesmo nível de inserção, 100% de inserção da geração fotovoltaica, foram encontrados problemas associados com sobretensões em todas as UC's, a UC 78 atingiu o limite de corte do inversor por exceder o nível de tensão máxima de 242 V estabelecido pela norma 482/2012 ANEEL. O efeito da sobretensão também foi propagado para pontos distintos de onde foram inseridos os SFVCR. Os problemas com o grau de desequilíbrio entre as fases foram notados nas simulações do subcaso 1 do caso 2, onde foi quantificado uma variação de 2,6% entre as fases V_A e V_B e de 2,4% entre as fases V_A e V_c , certamente decorrente do efeito de alta injeção de potência em uma única fase. Já a assimetria entre as UC's que estavam conectadas na mesma fase, surgiram decorrentes do subcaso 3 do caso 2, apesar de todas as UC's proporcionarem a mesma injeção de potência, os ramais de interligação eram de diferentes características, nesse aspecto, a impedância do ramal varia tanto em função do tamanho do trecho como da seção transversal do condutor, dessa forma o perfil de tensão assume variados perfis com relação a sua amplitude.

A extrapolação dos resultados observados no subcaso 3, pertencente ao caso 2, foram novamente simulados, adotando a estratégia de repotencialização da rede, parametrizando a topologia de conexão dos sistemas fotovoltaicos. Nesses moldes, os novos resultados realmente provaram que a sobretensão ocorrida na UC 78 foi rebaixada em 4% do valor crítico antes da mitigação. Concomitantemente, o desequilíbrio entre as fases também foram fortemente

reduzidos, situando-se abaixo de 0.7%. Finalmente, a primeira etapa foi encerrada demonstrando um estudo comparativo entre os dados experimentais e calculados, a fim de apresentar a tendência dos resultados obtidos pela simulação, enfim, o erro ao longo do perfil de tensão foi estabelecido numa faixa de $\pm 2,5\%$ com relação ao valor experimental.

O método empregado para avaliar o impacto dos geradores fotovoltaicos na rede foi favorecido mediante os resultados obtidos até aqui, ainda que, na validação não foram considerados os efeitos de equipamentos elétricos ao redor do sistema que pudessem introduzir alguma perturbação, assim como a adoção do contorno de céu claro para a irradiação solar. Quanto a avaliação do impacto da intermitência solar, foi realizada a modelagem e simulação da rede de um sistema de armazenamento composto por um grupo de baterias. Esse método compôs a segunda etapa do estudo.

A validação dos dados estimados foi realizada tomando como base os dados medidos pela estação solarimétrica instalada juntos ao SFVCR, assim para os perfis típicos da irradiação, o erro médio quadrático da raiz (RMSE) foi de $96,39 \text{ W/m}^2$, $121,36 \text{ W/m}^2$, $47,84 \text{ W/m}^2$ e $5,69 \text{ W/m}^2$, respectivamente. A métrica do coeficiente de correlação atingiu o grau mais intenso para os dias de céu claro (0,99) e céu nublado (0,97), a menor correlação foi para o dia de alta variabilidade (0,89). Estando os resultados validados, o algoritmo do fluxo de potência estimou as tensões nodais sob os 4 perfis típicos da irradiação solar, com as respectivas curvas de demanda monitoradas especificamente para cada dia validado, verificando as tensões nodais durante o período horário das 6 às 18 horas e classificando os valores de tensão que excederam o limite crítico ($V_N > V_{crítica}$) em função da potência limite de injeção predefinida. Para essa classificação, o dia de alta variabilidade apresentou-se com o maior percentual das ocorrências do tempo total das tensões que excederam o limite crítico (31%), apesar do dia de céu claro ter detido uma alta taxa de injeção de potência, as ocorrências de tensão acima do limite crítico foram relativamente inferiores ao dia de alta variabilidade (11%), graças à ausência de flutuação de potência.

O SAE foi selecionado para intencionalmente desviar o fluxo de potência reverso na ocorrência de sobretensão, integrando-se ao sistema de distribuição de forma passiva, para isso o sistema de armazenamento foi projetado em 4 grupos de potência e capacidades distintas. O maior número de comutações ocorreu para o dia de alta variabilidade, referente ao nível de $\Delta P = 1500 \text{ W}$, quando comparado ao dia de baixa variabilidade o sistema de armazenamento teve o dobro do número de comutações, esse fato é facilmente justificado pelo número de ocorrências de ultrapassagem do limite crítico. A preservação da vida útil da bateria foi monitorada

pelo estado da carga de cada grupo de potência do sistema de armazenamento, fixando o uso em 30% da capacidade energética total. Mais uma vez, o dia de alta variabilidade destaca-se por ser o responsável por carregar completamente os 3 níveis de potência iniciais do sistema de armazenamento. O dia de baixa variabilidade, complementa a carga da bateria em pouco mais de 80% da carga total para os grupos de potência $\Delta P = 1000W$ e $\Delta P = 1500W$. O dia de céu claro praticamente atuou significativamente no nível $\Delta P = 2000W$, atingindo os 100% da carga plena da bateria.

Mediante o cenário computacional foram comparados os dados reais dos respectivos dias típicos utilizados nas simulações, com os obtidos pelo método proposto. Nesse contexto, foi possível mensurar a faixa de acertos do método, caso a simulação estivesse sido executada na realidade para os respectivos dias. As análises para a condição de alta variabilidade e céu claro, foram validadas considerando o índice de acertos e erros. O parâmetro de acerto é contabilizado quando a tensão, experimental e real, estão acima do valor do limite crítico, implicando na atuação do armazenamento, ainda, quando ambas as tensões também estão simultaneamente abaixo do limite crítico, o armazenamento permanece em modo ocioso e contabiliza-se como índice de acerto. Diante dessa consideração, o dia de céu claro atingiu o maior percentual de acertos, alcançando a faixa de 95,01%, o dia de alta variabilidade atingiu 88,09%, ficando atrás do dia de baixa variabilidade. O desempenho do método foi ligeiramente afetado pelo grau da variabilidade da potência injetada na rede elétrica, o parâmetro de erro foi particionado em valores sobrestimados e subestimados da tensão, pois dessa forma possibilitou interpretar se o método errou por sobrestimativa ou subestimativa da tensão, em termos práticos, foram estabelecidas as hipóteses que o armazenamento atuou indesejadamente, ou permaneceu ocioso quando deveria ter se conectado na rede.

Finalmente, esse estudo buscou contribuir com ferramentas e informações capazes de aprimorar rotinas específicas no contexto operacional de empresas distribuidoras de energia elétrica. Negligenciar esses aspectos, além de implicar em sérios problemas técnicos tanto no local de interesse como nos ramais adjacentes, agravam-se também para problemas jurídicos, induzindo a maiores ônus. Reproduzir todo esse estudo considerando os efeitos do chaveamento causados pelos reguladores de tensão, bancos de capacitores e mudança abrupta de grandes blocos de cargas em alimentadores paralelos, provavelmente levaria ao aumento do desempenho do sistema de armazenamento, aumentando a convergência entre a tensão calculada e a experimental, além do mais, a dinâmica estabelecida pelo SAE impulsiona a adoção de tarifação variável por parte das unidades consumidoras, reduzindo o custo com energia principalmente

no horário de ponta. Essas ideias motivam a perspectiva futura, a fim de prospectar novos resultados.

6 PERSPECTIVAS FUTURAS

- Simular o sistema de armazenamento considerando um maior número sistemas fotovoltaicos;
- Avaliar o desempenho do método proposto para regulação da tensão de curto prazo, utilizando outras técnicas de previsão;
- Otimizar o tamanho do banco de baterias a partir de outros limites de injeção de potência, visando garantir a melhor vida útil;
- Definir estratégias de monitoramento e controle dos bancos de baterias para otimização da vida útil;
- Operacionalizar a estratégia de mitigação por baterias em um controlador programável.

REFERÊNCIAS

- ABDEL-NASSER, M.; MAHMOUD, K. Accurate photovoltaic power forecasting models using deep lstm-rnn. *Neural Comput. Appl.*, Multidisciplinary Digital Publishing Institute, v. 31, p. 2727–2740, 2019.
- ABOBOREIRA, F. L.; CRUZ, A. F. S. A importância do smart grid na rede elétrica de distribuição do Brasil. In: *XV SEPA Seminário Estudantil de Produção Acadêmica*. Salvador, Brasil: XV SEPA Seminário Estudantil de Produção Acadêmica, 2016.
- ABSOLAR. *Infográfico ABSOLAR. Geração Distribuída*. 2021. Associação Brasileira de Energia Solar Fotovoltaica. Disponível em: <<http://www.absolar.org.br/infografico-absolar.html>>. Acesso em: 20 jan. 2021.
- ALAM, E. J. M.; MUTTTAQUI, M. K.; SUTANO, D. Mitigation of rooftop solar pv impacts and evening peak support by managing available capacity of distributed energy storage systems. *Transactions on Power Systems*, IEEE, v. 28, p. 3874 – 3884, 2013.
- ALAM, M. J. E.; MUTTAQI, K. M.; SUTANTO, D. Community energy storage for neutral voltage rise mitigation in four-wire multigrounded lv feeders with unbalanced solar pv allocation. *Transactions on Smart Grid*, IEEE, v. 6, p. 2845–2855, 2015.
- ALMEIDA, M. P. Implicações técnicas da inserção em grande escala da geração solar fotovoltaica na matriz elétrica. 2017. Universidade de Sao Paulo, Sao Paulo, Brasil.
- ALVES, M. R. F. O papel de geradores fotovoltaicos na regulação de tensão em redes de baixa tensão residenciais: estudo comparativo de normas e padrões sob a ótica da mitigação da elevação de tensão. Universidade Federal de Minas Gerais, Minas Gerais, Brasil, 2017.
- ALZHARANI, A.; FERDOWSI, M.; SHAMSI, P.; DAGLI, C. Modeling and simulation of microgrid. *Procedia Computer Science*, Elsevier, v. 114, p. 392–400, 2017.
- ALZHARANI, A.; FERDOWSI, M.; SHAMSI, P.; DAGLI, C. Solar irradiance forecasting using deep neural networks. *Procedia Computer Science*, Elsevier, v. 114, p. 304–313, 2017.
- ANEEL. *RESOLUÇÃO NORMATIVA Nº 482, DE 17 DE ABRIL DE 2012*. 2012. Agência Nacional de Energia Elétrica. Disponível em: <<https://www2.aneel.gov.br/cedoc/bren2012482.pdf>>. Acesso em: 11 out. 2017.
- ANEEL. *Resolução Normativa no 733, de 06 de setembro de 2016*. 2016. Agência Nacional de Energia Elétrica. Disponível em: <https://www.in.gov.br/materia/-/asset_publisher/Kujrw0TZC2Mb/content/id/23532512/do1-2016-09-12-resolucao-normativa-n-733-de-6-de-setembro-de-2016-23532390>. Acesso em: 25 junho 2021.
- ANEEL. *Sala de Imprensa. Brasil alcança 170 mil megawatts de capacidade instalada em 2019*. Agência Nacional de Energia Elétrica (ANEEL). 2020. Agência Nacional de Energia Elétrica. Disponível em: <https://www.aneel.gov.br/web/guest/sala-de-imprensa-exibicao-2/-/asset_publisher/zXQREz8EVIZ6/content/id/19646860>. Acesso em: 17 nov. 2020.
- ANEEL. *Informações técnicas. Geração Distribuída. Micro e Minigeração Distribuídas*. 2021. Agência Nacional de Energia Elétrica. Disponível em: <<https://www.aneel.gov.br/web/guest/>>

sala-de-imprensa-exibicao-2/-/asset_publisher/zXQREz8EVIZ6/content/id/19646860>.
Acesso em: 20 jan. 2021.

ANEEL. *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – Prodist, Módulo 8 – Qualidade de Energia Elétrica*. v. 12. Agência Nacional de Energia Elétrica (ANEEL). 2021. Agência Nacional de Energia Elétrica. Disponível em: <https://www.aneel.gov.br/documents/656827/14866914/M%C3%B3dulo_8-Revis%C3%A3o_12/342ff02a-8eab-2480-a135-e31ed2d7db47> Acesso em: 25 Jan. 2021.

ARI, G. K.; BAGHZOUZ, Y. Impact of high pv penetration on voltage regulation in electrical distribution systems. In: *International Conference on Clean Electrical Power (ICCEP)*. Ishcia, Itália: IEEE, 2011.

ASENSIO, M.; QUEVEDO, P. M. de; MUÑOZ-DELGADO, G.; CONTRERAS, J. Joint distribution network and renewable energy expansion planning considering demand response and energy storage—part i: Stochastic programming model. *Transactions on Smart Grid*, IEEE, v. 9, p. 655–666, 2015.

ASSAS, O.; BOUZGOU, H.; FETAH, S.; SALMI, M.; BOURSAS, A. Use the artificial neural network and meteorological data for predicting daily global solar radiation in djelfa. In: *International Conference on Composite Materials & Renewable Energy Applications (ICCMREA)*. Sousse, Tunisia: IEEE, 2014.

BARATA, A. H. Impacto de redes de distribuição com massiva conexão de geradores fotovoltaicos na estabilidade de tensão de longo-prazo em sistemas de potência. Dissertação de Mestrado. Universidade Federal do Pará, Belém, Brasil., 2017.

BAYER, B.; MATSCHOSS, P.; THOMAS, H.; MARIAN, A. The german experience with integrating photovoltaic systems into the low-voltage grids. *Renewable Energy*, v. 119, p. 129–141, 2018.

BDEW. *Generating plants connected to the medium-voltage network: Guideline for generating plants' connection to and parallel operation with the medium-voltage network*. [S.l.], 2008. Bundesverband der Energie und Wasserwirtschaft. Disponível em: <<https://erranet.org/download/generating-plants-connected-to-medium-voltage-network/>>. Acesso em: 2 feb. 2021.

BOKHARI, A.; RAZA, A.; DIAZ-AGUILÓ, M.; LEÓN, F. de; CZARKOWSKI, D.; UOSEF, R. E.; WANG, D. Combined effect of cvr and dg penetration in the voltage profile of low-voltage secondary distribution networks. *Transactions on Power Delivery*, IEEE, v. 31, p. 286–293, 2016.

BORGES, R. T. Desenvolvimento de metodologias de análise sistêmica de sistemas de distribuição de energia elétrica com geração ultra-dispersa. Universidade Estadual de Campinas, Campinas, São Paulo, 2014.

BRAGA, N. B. Gerenciamento pelo lado da demanda em áreas residenciais. Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil, 2014.

BRAZ, H. D. M. Algoritmos genéticos para configuração Ótima de redes de distribuição de energia elétrica. Universidade Federal de Campina Grande, Paraíba, Brasil, 2003.

CAMPOS FILHO, M. H. S. Modelagem e predição de flutuações da irradiação solar de curta duração. Tese de Doutorado. Universidade Federal do Pernambuco. Recife, 2019.

CAPO, P. I. M. Desenvolvimento de uma ferramenta para previsão de curto prazo da radiação solar utilizando redes neurais artificiais. Universidade Federal de Santa Catarina., Santa Catarina, Brasil, 2018.

CHEN, B.; SUN, P.; LIU, C.; CHEN, C.-L.; LAI, J.-S.; YU, W. High efficiency transformerless photovoltaic inverter with wide-range power factor capability. In: *in Applied Power Electronics Conference and Exposition (APEC)*. Orlando, FL, USA: IEEE, 2012.

CHEVALIER, R. F.; HOOGENBOOM, G.; MCCLENDON, R. W.; PAZ, J. A. Support vector regression with reduced training sets for air temperature prediction: a comparison with artificial neural networks. *Neural Computing and Applications*, Neural Computing and Applications, v. 20, p. 151–159, 2011.

COELHO, L. D. N. Modelos de estimativa das componentes de radiação solar a partir de dados meteorológicos. Universidade de Brasília, Brasília, Brasil, 2016.

DAZA, E. F. B.; SPERANDIO, M. *Sistemas de Armazenamento de Energia: Desafios Regulatórios e Econômicos para sua inserção em Sistemas de Potência*. [S.l.]: Simplíssimo Livros Ltda, 2018. 1 ed. Porto Alegre.

DE LA PARRA, I.; MARCOS, J.; GARCÍA, M.; MARROYO, L. Dealing with the implementation of ramp-rate control strategies – challenges and solutions to enable pv plants with energy storage systems to operate correctly. *Solar Energy*, Elsevier, v. 169, p. 242–248, 2018.

DEB, C.; ZHANG, F.; YANG, J.; LEE, S. E.; SHAH, K. W. A review on time series forecasting techniques for building energy consumption. *Renew. Sustain. Energy Rev*, Elsevier, v. 74, p. 902–924, 2017.

DEVLIN, J.; LI, K.; HIGGINS, P.; FOLEY, A. System flexibility provision using short term grid scale storage. *IET Gener. Transm. Distrib.*, The Institution of Engineering and Technology, v. 10, p. 697–703, 2016.

DIAZ, V. N. Avaliação do desempenho das estratégias de controle para suavização da potência ativa de sistemas fotovoltaicos com armazenamento de energia. Universidade Estadual do Oeste do Paraná, Foz do Iguaçu, Brasil, 2019.

DUGAN, R. C.; TAYLOR, J. A.; MONTENEGRO, D. Energy storage modeling for distribution planning. *IEEE, Transactions On Industry Applications*, v. 53, p. 954–962, 2017.

ED-AL. *Norma técnica de fornecimento de energia elétrica em baixa tensão (Edificações Individuais)*. [S.l.], 2014. Disponível em: <http://seguranca.al.gov.br/wp-content/uploads/2016/10/Anexo-E_1-de-2-Norma-T%C3%A9cnica-de-Fornecimento-de-Energia-El%C3%A9trica-em-Baixa-Tens%C3%A3o.pdf>.

ENERGINET. *Technical Regulation 3.2.1 for a PV Power Plants above 11 kW*. 2016. Disponível em: <[Disponível em: https://en.energinet.dk/Electricity/Rules-and-Regulations/Regulations-for-grid-connection](https://en.energinet.dk/Electricity/Rules-and-Regulations/Regulations-for-grid-connection)>. Acesso em: 30 jan. 2021.

- EQUATORIAL. *Padrão de estruturas de redes de distribuição aérea de energia elétrica para 15kV*. [S.l.], 2019. Disponível em: <<https://al.equatorialenergia.com.br/wp-content/uploads/2020/12/NT-006-EQTL-Normas-e- Padr%C3%B5es- Padr%C3%A3o-de-Estruturas-de-Redes-de-Distribui%C3%A7%C3%A3o-15kV.pdf>>.
- FARHADI, M.; MOHAMMED, O. Energy storage technologies for high-power applications. *Transactions On Industry Applications*, IEEE, v. 52, p. 1953–1961, 2016.
- FARROKHABADI, M.; SOLANKI, V. B.; CÁNIZARES, A. C.; BHATTACHARYA, K.; KONIG, S.; SAUTER, S. P.; LEIBFRIED, T.; HOHMANN, S. Energy storage in microgrids: Compensating for generation and demand fluctuations while providing ancillary services. *Power and Energy Magazine*, IEEE, v. 15, p. 81–91, 2017.
- FINOTTI, A. S.; ALMEIDA, M. P.; ZILLES, R. Simulação do uso de baterias adotando a tarifa branca para microgeração fotovoltaica de classe residencial. In: *Mercado, Economia, Política, aspectos sociais - Estratégias e Políticas para as Energias Renováveis*. Gramado, Brasil: VII Congresso Brasileiro de Energia Solar – Gramado, 2018.
- FOSTER, S.; WALKER, I.; BARY, R. F.; BOYD, E. *Barriers and Benefits of Home Energy Controller Integration*. 2016. Department for Business, Energy & Industrial Strategy. Disponível em: <https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/545262/DECC_Barriers_and_Benefits_of_Home_Energy_Controllers_-_Final_report__1_.pdf>. Acesso em: 19 september 2021.
- GEVORGIAN, V.; BOOTH, S. *National Renewable Energy Laboratory - Technical Requirements for Interconnecting Wind and Solar Generation*. 2013. National Renewable Energy Laboratory. Disponível em: <<https://www.nrel.gov/docs/fy14osti/57089.pdf>>. Acesso em: 17 dec. 2020.
- GHANBARZADEH, A.; NOGHREHABADI, A. R.; ASSAREH, E.; BEHRANG, M. A. Solar radiation forecasting based on meteorological data using artificial neural networks. In: *7th IEEE International Conference on Industrial Informatics*. Cardiff, Wales: Institute of Electrical and Electronic Engineers, 2009.
- GOMES, A. E. Modelagem de sistemas de armazenamento a baterias com aplicação em estudos de estabilidade de frequência em redes com geração fotovoltaica. Dissertação de Mestrado. Universidade Federal do Rio de Janeiro. Rio de Janeiro, Brasil, 2019.
- GRANZOTO, L. M.; FERREIRA, S. D. T.; TRINDADE, F. C. L. Análise dos transitórios causados pela passagem de nuvens sobre painéis fotovoltaicos no número de atuações de reguladores de tensão. In: *Simpósio Brasileiro de Sistemas Elétricos (SBSE)*. Natal, Brasil: SBSE, 2016.
- GUARISO, G.; NUNNARI, G.; SANGIORGIO, M. Multi-step solar irradiance forecasting and domain adaptation of deep neural networks. *Energies*, Multidisciplinary Digital Publishing Institute, v. 13, n. 24, p. 3987, 2020.
- HARPER, J. P. Statistical analysis of solar irradiation in a distributed microgrid. Dissertação de Mestrado. Universidade da Califórnia, San Diego, 2010.
- HILL, C. A.; SUCH, M. C.; CHEN, D.; GONZALEZ, J.; GRADY, W. M. Energy storage in microgrids: Compensating for generation and demand fluctuations while providing ancillary services. *Transactions on Smart Grid*, IEEE, v. 3, p. 850–857, 2012.

- HIPPERT, H. S.; PEDREIRA, C. E.; SOUZA, R. C. Neural networks for short-term load forecasting: A review and evaluation. *IEEE, Transactions on Power Systems*, v. 16, 2001.
- KATIRAEI, F.; AGÜERO, J. Solar pv integration challenges. *Power and Energy Magazine, IEEE*, v. 9, p. 62–71, 2011.
- KHANNA, S.; BECERRA, V.; ALLAHHAM, A.; GIAOURIS, D.; FOSTER, J. M.; ROBERTS, K.; HUTCHINSON, D.; FAWCETT, J. Demand response model development for smart households using time of use tariffs and optimal control—the isle of wight energy autonomous community case study. *Energies, Multidisciplinary Digital Publishing Institute*, v. 13, n. 3, p. 541, 2020.
- KIM, S.-G.; JUNG, J.-Y.; SIM, M. K. A two-step approach to solar power generation prediction based on weather data using machine learning. *Sustainability, Multidisciplinary Digital Publishing Institute*, v. 11, n. 5, p. 1501, 2019.
- KOW, K. W.; WONG, Y. W.; RAJKUMAR, R.; RAJKUMAR, R. K. A review on performance of artificial intelligence and conventional method in mitigating pv grid-tied related power quality events. *Renew. Sustain. Energy Rev, Elsevier*, v. 56, p. 334–346, 2016.
- KUSAKANA, K. Energy management of a grid-connected hydrokinetic system under time of use tariff. *Renewable Energy, Elsevier*, v. 101, p. 1325–1333, 2017.
- LEE, S. S.; HENG, Y. E. A voltage level based predictive direct power control for modular multilevel converter. *Electric Power System Research, Elsevier*, v. 148, p. 97–107, 2017.
- LEHOLO, S.; OWOLAWI, P.; AKINDEJI, K. Solar energy potencial forecasting and optimization using artificial neural network: South africa case study. In: *Amity International Conference on Artificial Intelligence (AICAI)*. Dubai, United Arab Emirates: IEEE, 2019.
- LI, X.; YAO, L.; HUI, D. Optimal control and management of a large-scale battery energy storage system to mitigate fluctuation and intermittence of renewable generations. *Springer, J. Mod. Power Syst. Clean Energy*, v. 4, p. 593–603, 2016.
- LIMA, R. H.; BERNARDON, P. D.; OLIVEIRA, P. H. E. Método de monte carlo para análise de sobreensão m redes secundárias com elevada conexão de sistemas fv. In: *XVII Encontro Regional IBEROAMERICANO de Cigré (ERAC)*. Natal, Rio Grande do Norte, Brasil: 12° SEPOC, 2017.
- MA, W.; WANG, W.; WU, X.; HU, R.; TANG, F.; ZHANG, W.; HAN, X.; DING, L. Optimal allocation of hybrid energy storage systems for smoothing photovoltaic power fluctuations considering the active power curtailment of photovoltaic. *IEEE Access, IEEE*, v. 7, p. 74787–74799, 2019.
- MAHMUD, N.; ZAHEDI, A. Review of control strategies for voltage regulation of the smart distribution network with high penetration of renewable distributed generation. *Renew. Sustain. Energy Rev, Elsevier*, v. 64, p. 582–595, 2016.
- MARCOS, J.; FERNÁNDEZ, L. N.; BERAZALUCE, I.; GONZÁLEZ, R.; SAMUEL, J. Attenuation of power fluctuations in large pv power plants: The use of prediction to optimize the storage system. In: *28th European Photovoltaic Solar Energy Conference and Exhibition*. Paris, França: EU PVSEC Conference Proceedings, 2013.

- MARCOS, J.; PARRA, I. de la; GARCÍA, M.; MARROYO, L. Control strategies to smooth shortterm power fluctuations in large photovoltaic plants using battery storage systems. *Energies*, Multidisciplinary Digital Publishing Institute, v. 7, p. 6593–6619, 2014.
- MARTINS, J.; SPATARU, S.; SERA, D.; STROE, I.-D.; LASHAB, A. Comparative study of ramp-rate control algorithms for pv with energy storage systems. *Energies*, Multidisciplinary Digital Publishing Institute, v. 12, n. 7, p. 1342, 2019.
- MATEO, C.; FRÍAS, P.; COSENT, R.; SONVILLA, P.; BARTH, B. Overcoming the barriers that hamper a large-scale integration of solar photovoltaic power generation in european distribution grids. *Solar Energy*, Elsevier, v. 153, p. 574–583, 2017.
- MOGHADDAM, I.; CHOWDHURY, B. Battery energy storage sizing with respect to pv-induced power ramping concerns in distribution networks. In: *Power & Energy Society General Meeting*. Chicago, IL, USA: IEEE, 2017.
- MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. *Introduction to time series analysis and forecasting*. [S.l.]: John Wiley & Sons, 2015. New York.
- MURTHY, R. S. P. Power system analysis. BS Publication, 2007.
- OLAH, C. *Understanding lstm networks*. [S.l.], 2015. Disponível em: <<https://colah.github.io/posts/2015-08-Understanding-LSTMs/>>. Acesso em: 9 de janeiro de 2021.
- OLIVEIRA, R. C. Metodologia para o cálculo de perdas técnicas e não técnicas de aalimentadores de distribuição via estudos de fluxo de carga pelo método somatório de potência modificado. Universidade Federal do Pará, Belém, Pará, Brasil, 2017.
- PAIXÃO, B. A. L. Comparação de vida útil entre bancos de baterias de íon-lítio e chumbo-ácido no contexto da compensação de energia com geração distribuída fotovoltaica e tarifa branca. Dissertação de Mestrado. Universidade Federal de Minas Gerais. Minas Gerais, Brasil, 2020.
- PARRA, I. De la; MARCOS, J.; GARCÍA, M.; MARROYO, L. Improvement of a control strategy for pv power ramp-rate limitation using the inverters: Reduction of the associated energy losses. *Solar Energy*, Elsevier, v. 127, p. 262–268, 2016.
- PELLAND, S.; GALANIS, G.; KALLOS, G. Solar and photovoltaic forecasting through post-processing of the global environmental multiscale numerical weather prediction model. *Research and Applications*, Progress in Photovoltaics:, v. 21, n. 3, p. 284–296, 2013.
- PELLAND, S.; REMUND, J.; KLEISSL, J.; OOZEKI, T.; BRABANDERE, K. D. Photovoltaic and solar forecasting: state of the art. *IEA PVPS, Task*, Progress in Photovoltaics:, v. 14, p. 1–36, 2013.
- PROCEL. *Manual de Tarifação da Energia Elétrica*. 2011. Programa Nacional de Conservação da Energia Elétrica. Disponível em: <http://www.eletrica.ufpr.br/sebastiao/wa_files/te344/%20aula%2009%20-%20manual%20de%20tarif%20en%20el%20-%20procel_epp%20-%20agosto-2011.pdf>. Acesso em: 25 junho 2021.
- QUEVEDO, J. O. Emprego de um comutador eletrônico de taps para regulação de tensão em redes elétricas a partir do modelo de carga. Universidade Federal de Santa Maria, Santa Maria, Rio Grande do Sul, Brasil, 2018.

- RABL, A. *Active solar collectors and their applications*. [S.l.]: Oxford University Press, 1985. New York.
- RADATZ, P. R. R. F. Modelos avançados de análise de redes elétricas inteligentes utilizando o software openss. Universidade de São Paulo, São Paulo, Brasil, 2015.
- RADATZ, P. R. R. F.; ROCHA, C. *Algoritmo do fluxo de potência do OpenDSS*. [S.l.], 2018. Disponível em: <<http://www.etla.fi/wp-content/uploads/ETLA-Raportit-Reports-71.pdf>>.
- REN21. *Renewables 2020 Global Status Report*. 2021. Disponível em: <https://www.ren21.net/wp-content/uploads/2019/05/GSR2021_Full_Report.pdf>. Acesso em: 13 september 2021.
- ROGERS, D. J.; GREEN, T. C. An active-shunt diverter for on-load tap changers. *Transactions on Power Delivery*, IEEE, v. 28, p. 649–657, 2013.
- SABINO, E. R. C. Previsão de radiação solar e temperatura ambiente voltada para auxiliar a operação de usina fotovoltaicas. Tese de Doutorado. Universidade Federal do Pernambuco. Recife, 2019.
- SABOORI, H.; HEMMATI, R.; GHIASI, S. M. S.; DEGHAN, S. Energy storage planning in electric power distribution networks – a state-of-the-art review. *Solar Energy*, Elsevier, v. 79, p. 1108–1121, 2017.
- SFETSOS, A.; COONICK, A. Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques. *Solar Energy*, Elsevier, v. 68, p. 169–178, 2000.
- SHARMA, A. A.; KAKKAR, A. Forecasting daily global solar irradiance generation using machine learning. *Renewable and Sustainable Energy*, Elsevier, v. 82, p. 2254–2269, 2018.
- SILVA JÚNIOR, S. B. Análise de operação de sistemas de distribuição utilizando o openss. Trabalho de Conclusão de Curso. Universidade de São Paulo. São Carlos, 2010.
- SMITH, L. I. *A tutorial on principal components analysis*. [S.l.]: Cornell University, 2002.
- SORKUN, M. C.; INCEL, O. D.; PAOLI, C. Time series forecasting on multivariate solar radiation data using deep learning (lstm). *Turkish Journal of Electrical Engineering & Computer Sciences*, Turk J Elec Eng & Comp Sci, v. 28, p. 211–233, 2020.
- SRIVASTAVA, S.; LESSMANN, S. A comparative study of lstm neural networks in forecasting day-ahead global horizontal irradiance with satellite data. *Solar Energy*, Elsevier, v. 162, p. 232–247, 2018.
- TONKOSKI, R.; LOPES, L.; EL-FOULY, T. Coordinated active power curtailment of grid connected pv inverters for overvoltage prevention. *Transactions on Sustainable Energy*, IEEE, v. 2, p. 139–147, 2011.
- TORRES, I. C.; FARIAS, D. M.; AQUINO, A. L. L. de; TIBA, C. Voltage regulation for residential prosumers using a set of scalable power storage. *Energies*, Multidisciplinary Digital Publishing Institute, v. 14, p. 3288, 2021.
- TORRES, I. C.; NEGREIROS, G. F.; TIBA, C. Theoretical and experimental study to determine voltage violation, reverse electric current and losses in prosumers connected to low-voltage power grid. *Energies*, Multidisciplinary Digital Publishing Institute, v. 12, n. 23, p. 4568, 2019.

-
- VASSALLI, L. C. Aplicação de redes neurais lstm para a previsão de curto prazo de vazão do rio paraíba do sul. 2018. Universidade Federal de Juiz de Fora, Minas Gerais, Brasil.
- VOYANT, C.; NOTTON, G.; KALOGIROU, S.; NIVET, M. L.; PAOLI, C.; MOTTE, F.; FOUILLOY, A. Quantifying pv power output variability. *Renewable Energy*, Elsevier, v. 105, p. 569–582, 2017.
- WANG, F.; YU, Y.; ZHANG, Z.; LI, J.; ZHEN, Z.; LI, K. Wavelet decomposition and convolutional lstm networks based improved deep learning model for solar irradiance forecasting. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 8, n. 8, p. 1286, 2018.
- WANG, P.; LIANG, D. H.; YI, J.; LYONS, P. F.; DAVISON, P. J.; TAYLOR, P. C. Integrating electrical energy storage into coordinated voltage control schemes for distribution networks. *Transactions On Smart Grid*, IEEE, v. 5, p. 1018 – 1032, 2014.
- WENCKOW, K.; WANWONG, Y.; KUMARRAJKUMAR, R.; KUMARRAJKUMAR, R. A review on performance of artificial intelligence and conventional method in mitigating pv grid-tied related power quality events. *Elsevier, Renew. Sustain. Energy Rev.*, v. 56, p. 334–346, 2016.
- XIE, Q.; SHENTU, X.; WU, X.; DING, Y.; HUA, Y.; CUI, J. Coordinated voltage regulation by on-load tap changer operation and demand response based on voltage ranking search algorithm. *Energies*, Multidisciplinary Digital Publishing Institute, v. 12, n. 23, p. 1902, 2019.
- ZHAO, P.; HERNANDO-GIL, I.; WU, H. Optimal energy operation and scalability assessment of microgrids for residential services. In: *2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*. Palermo, Italy: IEEE, 2018.

APÊNDICE A – SCRIPT REDE NEURAL

```
#####
                        INÍCIO DA IMPORTAÇÃO DOS ARQUIVOS
#####
def ler_dados():
    import os

    import numpy as np

    import pandas as pd

    import matplotlib.pyplot as plt

# ERROS

    from sklearn.metrics import explained_variance_score

    from sklearn.metrics import max_error

    from sklearn.metrics import mean_absolute_error

    from sklearn.metrics import mean_squared_error

    from sklearn.metrics import mean_squared_log_error

    from sklearn.metrics import median_absolute_error

    from sklearn.metrics import r2_score

    from sklearn.metrics import scorer

    dados = [] # Onde serao armazenados os dados

    path = ('/Users/danielfarias/Python/P&D_Ufal/Dados/Dados_Igor')

    #path = 'C:\\Users\\Daniel Mello\\Documents\\Python\\P&D CELESC\\Dados\\Dados_Igor'

    arquivos = []

    dados = []

# r=root, d=directories, f = files

    for dirpath, dirnames, filenames in os.walk(path):

        for file in filenames:

            if '.dat' in file:

                arquivos.append(os.path.join(dirpath, file))

    arquivos = arquivos [1:]

    count = 0

    dias_com_erro =[]
```

```

for i in arquivos:
    df = pd.read_table (i , sep="," , header=3)
    df = df.iloc[:1440]
    df_limitador = df.iloc[360:1080,:] # BASE DE DADOS SECUNDÁRIA COM VALORES ENTRE 6
E 18 HORAS
# ARRUMA 1: COLUNA RECORD (QUE SÓ TEM EM ALGUNS DADOS)
    array_aux = np.array(df)
    if (array_aux.shape[1] == 15):
        df = df.drop(df.columns[[1]], axis=1) # DELETA A COLUNA 1 QUE É DO RECORD
        df_limitador = df_limitador.drop(df_limitador.columns[[1]], axis=1) # DELETA A COLUNA
1 QUE É DO RECORD
# ARRUMA 2: QUANDO NAO TEM TODOS OS DADOS DO DIA (EXCLUI O DIA)
    if (array_aux.shape[0] != 1440):
        dias_com_erro.append(array_aux[0,0][0:10]) # MOSTRA OS DIAS QUE TIVERAM ERRO
(FORAM EXCLUIDOS)
        elif (array_aux[300:1080,1].mean() < 250):
            dias_com_erro.append(array_aux[0,0][0:10]) # MOSTRA OS DIAS QUE TIVERAM ERRO -
MÉDIA DIARIA ABAIXO DE 250 (FORAM EXCLUIDOS)
    else:
        #print (array_aux.shape)
        if count ==0:
            tabela_2d = np.array(df)
            tabela_3d = np.array(df)
            tabela_2d_limitador = np.array(df_limitador)
            tabela_3d_limitador = np.array(df_limitador)
            print ("Processo : " ,round (count/len(arquivos)*100, 2), " % ") # MOSTRA O
PROCESSAMENTO DOS DADOS COM 2 CASAS DECIMAIS
        if count > 0:
            tabela_3d = np.dstack((tabela_3d, np.array(df))) # DEIXA EM 3D
            tabela_2d = np.concatenate((tabela_2d, np.array(df))) # JUNTA TUDO EM 2D
            tabelatabela_3d_limitadora_3d = np.dstack((tabela_3d_limitador,
np.array(df_limitador))) # DEIXA EM 3D
            tabela_2d_limitador = np.concatenate((tabela_2d_limitador, np.array(df_limitador)))
# JUNTA TUDO EM 2D

```

```
count = count+1

# TRANSFORMA OS DADOS EM UM DATAFRAME PANDAS

tabela = pd.DataFrame(data=tabela_2d, columns=['Horario', 'Radiacao_Avg',
'Temp_Cel_Avg', 'Temp_Amb_Avg', 'Tensao_S1_Avg', 'Corrente_S1_Avg', 'Potencia_S1_Avg',
'Tensao_S2_Avg', 'Corrente_S2_Avg', 'Potencia_S2_Avg', 'Potencia_FV_Avg',
'Demanda_Avg', 'FP_FV_Avg', 'Tensao_Rede_Avg'])

tabela_limitador = pd.DataFrame(data=tabela_2d_limitador, columns=['Horario',
'Radiacao_Avg', 'Temp_Cel_Avg', 'Temp_Amb_Avg', 'Tensao_S1_Avg', 'Corrente_S1_Avg',
'Potencia_S1_Avg', 'Tensao_S2_Avg', 'Corrente_S2_Avg', 'Potencia_S2_Avg',
'Potencia_FV_Avg', 'Demanda_Avg', 'FP_FV_Avg', 'Tensao_Rede_Avg'])

# RETIRA OS DADOS ENTRE 28/02 E 06/03 QUE ESTÃO COM RADIACAO_AVG SEMPRE 0

indices = []

for i in range (77760 - 67680):

    indices.append(i+67680)

indices_limitador = []

for i in range (42120 - 36660):

    indices_limitador.append(i+36660)

#####

                CRIA FUNCAO QUE SEPARA OS DADOS DE TREINO E TESTE

#####

def split_sequence(sequence, n_steps, forecast):

    X, y = list(), list()

    for i in range(len(sequence)):

        end_ix = i + n_steps

        if end_ix + forecast > len(sequence):

            break

        seq_x, seq_y = sequence[i:end_ix], sequence[end_ix:end_ix+forecast]

        X.append(seq_x)

        y.append(seq_y)

    return np.array(X), np.array(y)
```

```
#####  
FUNCAO PARA SEPARAR OS DADOS EM TREINO E TESTE DA LSTM  
#####  
def separar_dados_lstm (dados, dados_lidos, dados_predito, porcentagem_test):  
    test_size = int (len (dados)*porcentagem_test)  
    train_size = int (len(dados) - test_size)  
    train, test = dados[0:train_size], dados[train_size:len(dados)]  
    X_train, y_train = split_sequence(train, dados_lidos, dados_predito)  
    X_test, y_test = split_sequence(test, dados_lidos, dados_predito)  
    X_train = X_train.reshape (X_train.shape[0], X_train.shape[1], 1)  
    y_train = y_train.reshape (y_train.shape[0], y_train.shape[1], 1)  
    X_test = X_test.reshape (X_test.shape[0], X_test.shape[1], 1)  
    y_test = y_test.reshape (y_test.shape[0], y_test.shape[1], 1)  
    return (X_train, y_train, X_test, y_test)  
  
def separar_dados_cnn (dados, dados_lidos, dados_predito, porcentagem_test):  
    test_size = int (len (dados)*porcentagem_test)  
    train_size = int (len(dados) - test_size)  
    train, test = dados[0:train_size], dados[train_size:len(dados)]  
    n_features = 1  
    n_steps_sub = 2  
    n_seq_sub = int (dados_lidos/n_steps_sub)  
    X_train, y_train = split_sequence(train, dados_lidos, dados_predito)  
    X_test, y_test = split_sequence(test, dados_lidos, dados_predito)  
    X_train = X_train.reshape((X_train.shape[0], n_seq_sub,1, n_steps_sub, n_features))  
    X_test = X_test.reshape((X_test.shape[0], n_seq_sub,1, n_steps_sub, n_features))  
    y_train = y_train.reshape(y_train.shape[0],-1)  
    y_test = y_test.reshape(y_test.shape[0], -1)  
    return (X_train, y_train, X_test, y_test)
```

```
#####  
                                CRIA A FUNÇÃO DE TREINAR A REDE  
#####  
def treinar_rede_bidirecional (X_train, y_train, dados_lidos,dados_predito):  
    from tensorflow.keras.layers import Conv2D, BatchNormalization, Activation, Flatten,  
Dense, Dropout, LSTM, Input, TimeDistributed, Embedding, Bidirectional  
    from tensorflow.keras import initializers, Model, optimizers, callbacks  
    from tensorflow.keras.models import load_model, Sequential  
    from tensorflow.keras.callbacks import Callback  
    from sklearn.metrics import confusion_matrix, f1_score, precision_score, recall_score  
    from tensorflow.keras.models import Sequential  
    from tensorflow.keras.layers import LSTM, Dense, Flatten, ConvLSTM2D, Conv1D, Conv2D,  
BatchNormalization, Activation, Dropout, TimeDistributed, Embedding, MaxPooling1D  
    model = Sequential()  
    model.add(Bidirectional(LSTM(100, return_sequences=True),  
input_shape=(X_train.shape[1], X_train.shape[2])))  
    model.add(Dropout(0.2))  
    model.add(Bidirectional(LSTM(50, return_sequences=True)))  
    model.add(Dropout(0.2))  
    model.add(Bidirectional(LSTM(30, return_sequences=True)))  
    model.add(Dropout(0.2))  
    model.add(Bidirectional(LSTM(10)))  
    model.add(Dropout(0.2))  
    model.add(Dense(y_train.shape[1]))  
    model.compile(optimizer='adam', loss='mse')  
    print (model.summary())  
    print ('STEPS: ', dados_lidos)  
    print ('FORECAST: ', dados_predito)  
    epocas = 1  
    model.fit(X_train, y_train, epochs=epocas, verbose=1)  
    return (model)
```

```

def treinar_rede_cnn (X_train, y_train, dados_lidos,dados_predito, n_features):

    from tensorflow.keras.models import Sequential

    from tensorflow.keras.layers import LSTM, Dense, Flatten, ConvLSTM2D, Conv1D, Conv2D,
    BatchNormalization, Activation, Dropout, TimeDistributed, Embedding, MaxPooling1D

    n_steps_sub = 2

    n_seq_sub = int (dados_lidos/n_steps_sub)

    model = Sequential()

    model.add(ConvLSTM2D(filters=64, kernel_size=(2,n_steps_sub), activation='relu',
input_shape=(n_seq_sub, 1, n_steps_sub, n_features)))

    model.add(MaxPooling2D(pool_size= (2,2)))

    model.add(Flatten())

    model.add(Dense(dados_predito))

    model.compile(optimizer='adam', loss='mse')

    model.summary()

    print ('STEPS: ', dados_lidos)

    print ('FORECAST: ', dados_predito)

    # TREINO DA REDE

    epocas = 10

    model.fit(X_train, y_train, epochs=epocas, verbose=1)

    return (model)

#####

                        CRIA A FUNÇÃO QUE CALCULA O ERRO

#####

def mean_absolute_percentage_error(y_true, y_pred):

    y_true, y_pred = np.array(y_true), np.array(y_pred)

    return np.mean(np.abs((y_true - y_pred) / y_true)) * 100

def calcular_erros (test,predictions):

    from sklearn.metrics import explained_variance_score

    from sklearn.metrics import max_error

    from sklearn.metrics import mean_absolute_error

    from sklearn.metrics import mean_squared_error

```

```
from sklearn.metrics import mean_squared_log_error
from sklearn.metrics import median_absolute_error
from sklearn.metrics import r2_score
from sklearn.metrics import scorer

import math

score_variance = explained_variance_score(test, predictions)# Explained variance regression
score function

erro_absoluto_medio = mean_absolute_error(test, predictions) #Mean absolute error
regression loss

erro_medio_quadratico = mean_squared_error(test, predictions) #Mean squared error
regression loss

rmse = math.sqrt(erro_medio_quadratico) # Calculo do RMSE

mape = mean_absolute_percentage_error(test, predictions) # Calcula o MAPE (já é a %)

erro_mediana = median_absolute_error(test, predictions)# Median absolute error
regression loss

erro_r2 = r2_score(test, predictions) #R^2 (coefficient of determination) regression score
function.

# Cria a lista com os erros

lista_erros = []

lista_erros.append(score_variance)

lista_erros.append(erro_absoluto_medio)

lista_erros.append(erro_medio_quadratico)

lista_erros.append(rmse)

lista_erros.append(mape)

lista_erros.append(erro_mediana)

lista_erros.append(erro_r2)

print('\nERROS:\nScore Variance: %.3f' % score_variance,

      '\nErro Absoluto Médio: %.3f' %erro_absoluto_medio, '\nErro Médio Quadrático: %.3f'
%erro_medio_quadratico,

      '\nMAPE: %.3f' %mape, '\nRMSE: %.3f' %rmse, '\nErro Mediano Absoluto: %.3f'
%erro_mediana,

      '\nErro R2: %.3f' %erro_r2)

return (lista_erros)
```

```
#####  
                                CRIA A FUNÇÃO QUE SALVA OS MODELOS  
#####  
def salvar_modelo(nome_modelo, modelo):  
    #nome_modelo =  
'Modelos/modelo_bidirecional_10_radiacao_'+nova_tabela_pandas.columns[1]+'_' +  
str(n_steps) + '_' + str(forecast)  
    model_json = modelo.to_json()  
    with open(nome_modelo, "w") as json_file:  
        json_file.write(model_json)  
    modelo.save_weights(nome_modelo+'.h5')  
    print('MODELO SALVO\nNome do Modelo: ', nome_modelo)  
#####  
                                CRIA A FUNÇÃO QUE CARREGA O MODELO TREINADO  
#####  
dados_lidos = 20  
dados_predito = 1  
arquivo_modelo = 'Modelos/modelo_bidirecional_multivariado_camada_3_lendo_'+str  
(dados_lidos)+'_predicao_'+str (dados_predito)  
def carregar_modelo (arquivo_modelo, dados_lidos, dados_predito):  
    from tensorflow.keras.models import model_from_json  
    json_file = open(arquivo_modelo, 'r')  
    loaded_model_json = json_file.read()  
    json_file.close()  
    loaded_model = model_from_json(loaded_model_json)  
    loaded_model.summary()  
    loaded_model.load_weights(arquivo_modelo+'.h5')  
    print('REDE CARREGADA COM SUCESSO: ', arquivo_modelo , '\n\n')  
    return (loaded_model)
```

```
#####  
INÍCIO DO PROGRAMA – PREVISÃO DA IRRADIAÇÃO SOLAR E TEMPERATURA DA CÉLULA  
FOTOVOLTAICA  
#####  
# Importa Bibliotecas  
import os  
import numpy as np  
import pandas as pd  
import matplotlib.pyplot as plt  
# Lendo os dados  
dados = ler_dados()  
  
from sklearn.preprocessing import MinMaxScaler  
dados_radiacao = dados.iloc[:,1:2] # Pega a Radiação  
dados_temp_celula = dados.iloc[:,2:3] # Pega a Temperatura da Celula  
#dados_temp_Amb = dados.iloc[:,3:4] # Pega a Temperatura Ambiente (Muitos dados com  
erro)  
dados_radiacao_normalizados, scaler_radiacao = normalizar (dados_radiacao) # Pega a  
Radiação normalizada e o scaler dela  
dados_temp_celula_normalizados, scaler_temp_celula = normalizar (dados_temp_celula) #  
Pega a Temperatura da Celula normalizada e o scaler dela  
  
#####  
ESTIMATIVA DA IRRADIAÇÃO E TEMPERATURA DA CÉLULA FV COM A REDE NEURAL  
RECORRENTE LSTM – 1 VARIÁVEL  
#####  
# CARREGA OS DADOS DE TREINO / TESTE PARA CADA VARIÁVEL  
# RADIAÇÃO / TEMPERATURA CELULA  
# SEPARA OS 75% PARA TREINO E 25% PARA TESTE  
porcentagem_test = 0.25 # ESCOLHE QUANTOS % DOS DADOS FICAM PARA TREINO  
dados_lidos_lista = [20]  
#dados_lidos = 10  
dados_predito = 1
```

```
lista_dados_entrada=[]
lista_resultados_erros = []
for dados_lidos in dados_lidos_lista:
# COLETA OS DADOS DE TREINO E TESTE DE CADA VARIÁVEL
    X_train_radiacao,y_train_radiacao,X_test_radiacao,y_test_radiacao = separar_dados_lstm
(dados_radiacao_normalizados, dados_lidos, dados_predito, porcentagem_test)
    X_train_temp_celula,y_train_temp_celula,X_test_temp_celula,y_test_temp_celula =
separar_dados_lstm (dados_temp_celula_normalizados, dados_lidos, dados_predito,
porcentagem_test)
# NESSE CASO PEGOU COMO ENTRADA APENAS A TENSÃO DA REDE
# MUDAR O RESHAPE DA ENTRADA DA LSTM PARA - [samples (amostras), timesteps(dados
lidos), features(dados_usados)]
X_train = X_train_temp_celula.reshape (X_train_temp_celula.shape[0],
X_train_temp_celula.shape[1], 1)
X_test = X_test_temp_celula.reshape (X_test_temp_celula.shape[0],
X_test_temp_celula.shape[1], 1)
y_train = y_train_temp_celula
y_test = y_test_temp_celula
    print ("\n\nFormato dos dados:")
    print ("X Treino: ", X_train.shape)
    print ("X Teste: ", X_test.shape)
    print ("Y Treino: ", y_train.shape)
    print ("Y Teste: ", y_test.shape)
# TREINA O MODELO
    modelo_treinado = treinar_rede_bidirecional (X_train, y_train, dados_lidos,dados_predito)
# SALVA OS DADOS COM O NOME ABAIXO
    nome_modelo = 'Modelos/modelo_bidirecional_temperatura_camada_3_lendo_'+str
(dados_lidos)+'_predicao_'+str (dados_predito)
    salvar_modelo (nome_modelo, modelo_treinado)
# TRANSFORMA O TESTE PARA COMPRAR (VALOR REAL)
    test = scaler_temp_celula.inverse_transform(y_test.reshape (-1,1))
# APLICA O MODELO PARA DEPOIS DESNORMALIZAR (VALOR PREDITO)
    test_predict = modelo_treinado.predict(X_test, verbose=1)
    predictions = scaler_temp_celula.inverse_transform(test_predict)
```

```
# CALCULA OS ERROS DE VALOR REAL X VALOR PREDITO
    erros = calcular_erros (test,predictions)

# SALVA OS ERROS NUMA LISTA DADOS_LIDOS, DADOS_PREDITO E ERROS
    lista_dados_entrada.append (dados_lidos)

    lista_dados_entrada.append (dados_predito)

    lista_resultados_erros.append (erros)

# SALVA TUDO NO MODELO PANDAS PARA DEPOIS SER POSSÍVEL SALVAR EM EXCEL

erros_panda = pd.DataFrame(np.array (lista_resultados_erros).reshape (-1,7),
    columns=('score_variance', 'erro_absoluto_medio', 'erro_medio_quadratico', 'RMSE', 'MAPE',
    'erro_mediana', 'erro_r2'))

erros_panda['Dados_lidos'] = np.array (lista_dados_entrada).reshape (-1,2)[:,:0] # Salva a
quantidade de dados para leitura

erros_panda['Dados_predito'] = np.array (lista_dados_entrada).reshape (-1,2)[:,:1] # Salva a
quantidade de dados para predição

erros_panda['Modelo'] = 'LSTM Bidirecional'

# SALVA O ARQUIVO EM CSV
erros_panda.to_csv('erros_temp.csv',na_rep='Unkown') # missing value save as Unknown

valores_excel = pd.DataFrame (test.reshape (-1,1))

valores_excel = valores_excel.rename(columns={0: 'Teste'})

valores_excel['Predicao'] = predictions

valores_excel = valores_excel.iloc [:2880]

valores_excel.to_csv('predicao_temperatura_celula.csv',na_rep='Unkown') # MISSING VALUE
SAVE AS UNKNOWN

X_train_temp_celula_dia,y_train_temp_celula_dia,X_test_temp_celula_dia
,y_test_temp_celula_dia = separar_dados_lstm (temperatura_dia20, dados_lidos,
dados_predito, 0.95)

X_train_dia = X_train_temp_celula_dia.reshape (X_train_temp_celula_dia.shape[0],
X_train_temp_celula_dia.shape[1], 1)

X_test_dia = X_test_temp_celula_dia.reshape (X_test_temp_celula_dia.shape[0],
X_test_temp_celula_dia.shape[1], 1)

y_train_dia = y_train_temp_celula_dia

y_test_dia = y_test_temp_celula_dia

print ("\n\nFormato dos dados:")
```

```
print ("X Treino: ", X_train_dia.shape)
print ("X Teste: ", X_test_dia.shape)
print ("Y Treino: ", y_train_dia.shape)
print ("Y Teste: ", y_test_dia.shape)
plt.plot(X_test_dia[:,0,0])
test = scaler_temp_celula.inverse_transform(y_test.reshape(-1,1))
predictions = scaler_temp_celula.inverse_transform(test_predict)
erros = calcular_erros (test,predictions)
plt.figure(figsize=(16,8))
plt.title ("Temperatura da Celula")
plt.plot (test, label = 'Valor Real')
plt.plot(predictions, label = 'Valor Predito')
plt.legend()
```