

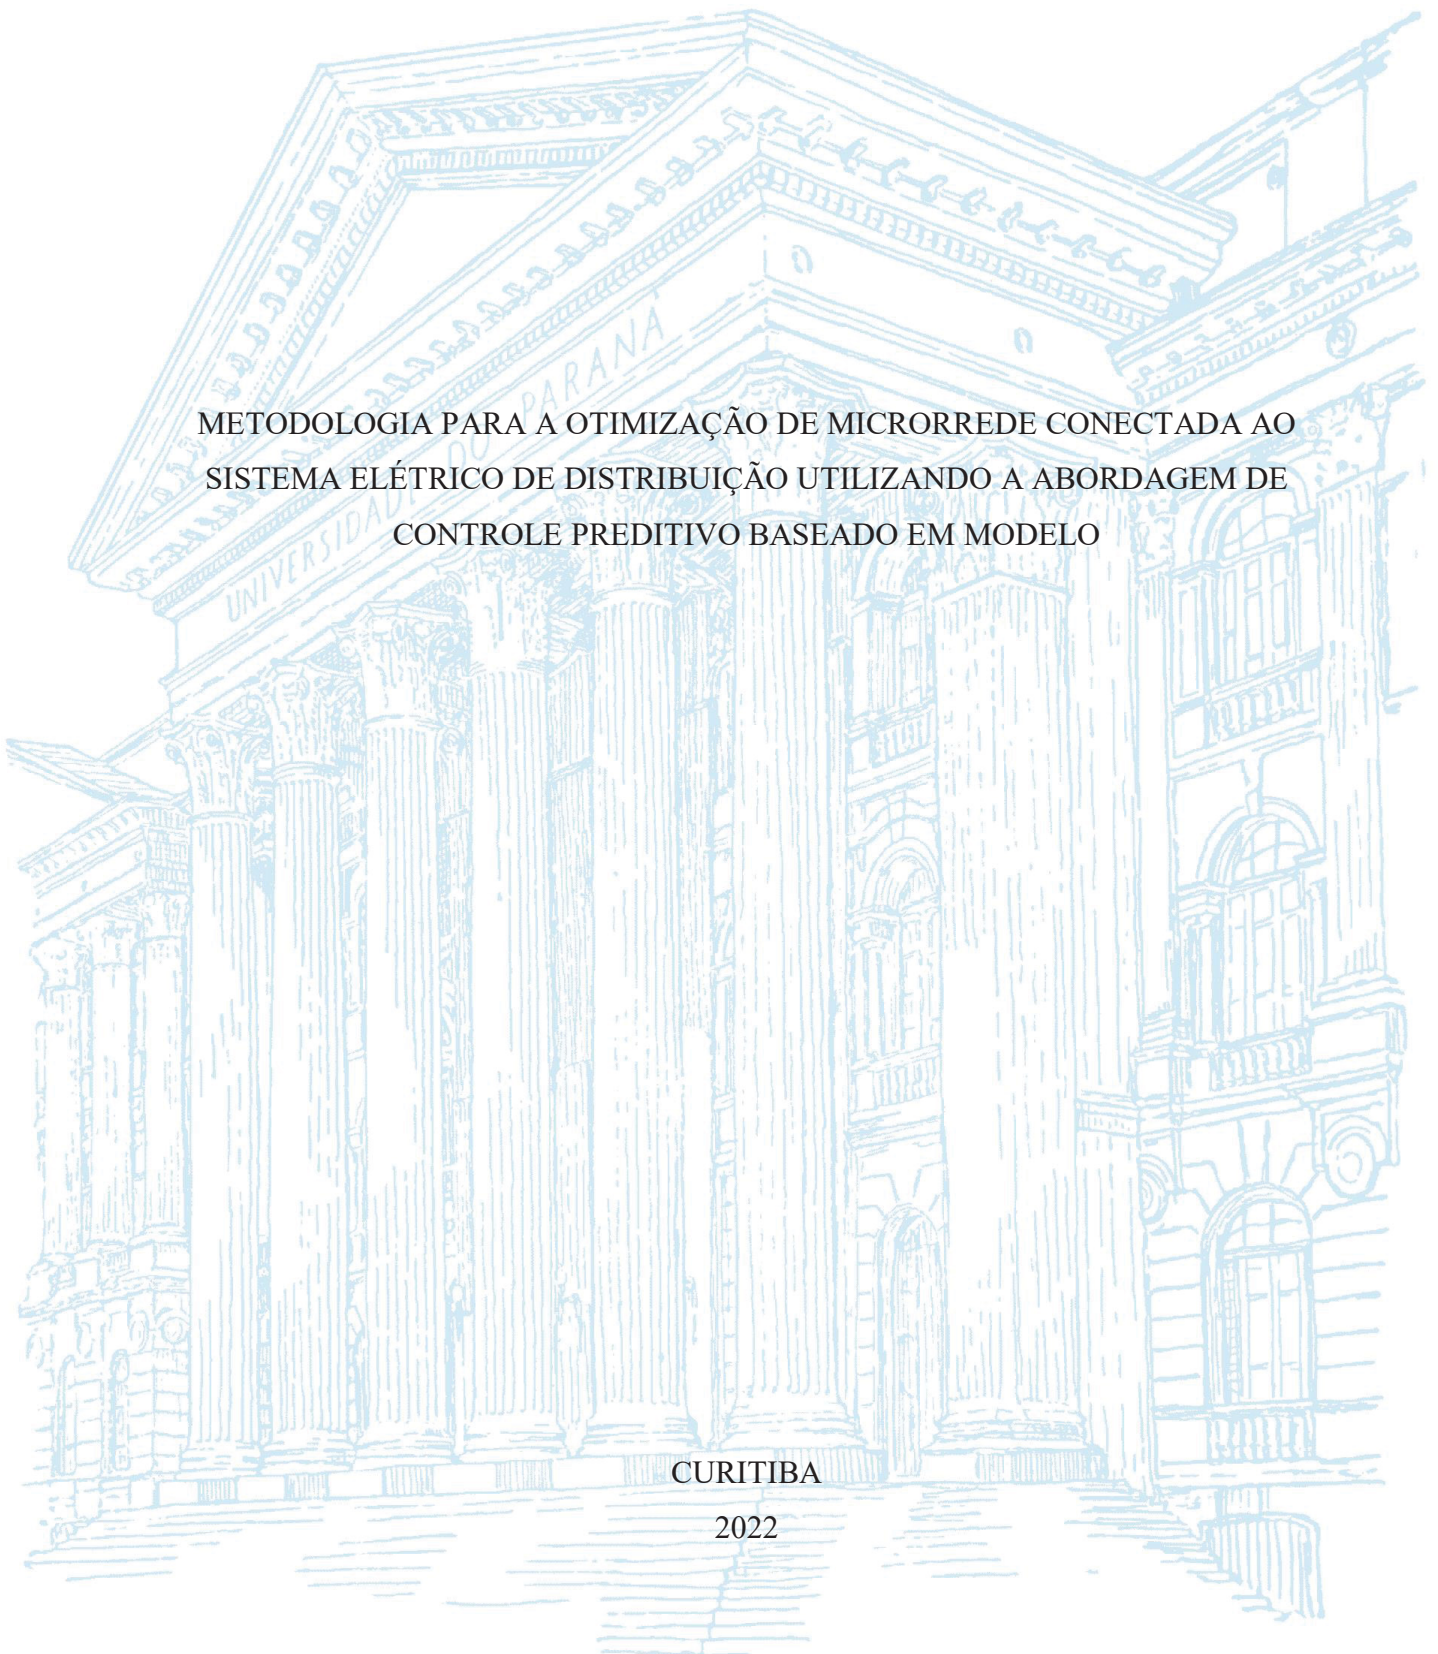
UNIVERSIDADE FEDERAL DO PARANÁ

LEONARDO FUCHS

METODOLOGIA PARA A OTIMIZAÇÃO DE MICRORREDE CONECTADA AO
SISTEMA ELÉTRICO DE DISTRIBUIÇÃO UTILIZANDO A ABORDAGEM DE
CONTROLE PREDITIVO BASEADO EM MODELO

CURITIBA

2022



LEONARDO FUCHS

METODOLOGIA PARA A OTIMIZAÇÃO DE MICRORREDE CONECTADA AO
SISTEMA ELÉTRICO DE DISTRIBUIÇÃO UTILIZANDO A ABORDAGEM DE
CONTROLE PREDITIVO BASEADO EM MODELO

Dissertação apresentada ao curso de Pós-Graduação em Engenharia Elétrica, Área de Sistemas de Energia, Departamento de Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná, como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Odilon Luís Tortelli

Coorientador: Dr. Filipe Perez

CURITIBA

2022

F951m Fuchs, Leonardo

Metodologia para a otimização de microrrede conectada ao sistema elétrico de distribuição utilizando a abordagem de controle preditivo baseado em modelo [recurso eletrônico] / Leonardo Fuchs - Curitiba, 2022.

Dissertação (mestrado) - Programa de Pós-Graduação em Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná.

Orientador: Prof. Dr. Odilon Luís Tortelli
Coorientador: Prof. Dr. Filipe Perez

1. Engenharia elétrica. 2. Redes elétricas. 3. Programação linear. I. Universidade Federal do Paraná. II. Tortelli, Odilon Luís. III. Perez, Filipe. IV. Título.

CDD 621.3104



MINISTÉRIO DA EDUCAÇÃO
SETOR DE TECNOLOGIA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA
ELÉTRICA - 40001016043P4

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA ELÉTRICA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **LEONARDO FUCHS** intitulada: **METODOLOGIA PARA A OTIMIZAÇÃO DE MICRORREDE CONECTADA AO SISTEMA ELÉTRICO DE DISTRIBUIÇÃO UTILIZANDO A ABORDAGEM DE CONTROLE PREDITIVO BASEADO EM MODELO**, sob orientação do Prof.

Dr. ODILON LUIS TORTELLI, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua **APROVAÇÃO** no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 21 de Fevereiro de 2022.

Assinatura Eletrônica
22/02/2022 10:49:49.0
ODILON LUIS TORTELLI
Presidente da Banca Examinadora

Assinatura Eletrônica
22/02/2022 10:54:03.0
ROMAN KUJAWA
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica
22/02/2022 11:09:44.0
ANDRE EUGENIO LAZZARETTI
Avaliador Externo (UNIVERSIDADE TECNOLÓGICA FEDERAL DO
PARANÁ)

Assinatura Eletrônica
22/02/2022 11:46:02.0
THELMA SOLANGE PIAZZA FERNANDES
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

AGRADECIMENTOS

Agradeço primeiramente a Deus, por tudo o que sou e tenho.

Agradeço aos meus pais e irmão, pelo amor e incentivo ao estudo.

Agradeço ao meu orientador, Prof. Dr. Odilon Luís Tortelli, por toda a paciência e pelo tempo dedicado a correções e orientação durante todo o mestrado.

Agradeço ao meu coorientador, Dr. Filipe Perez, pelo suporte oferecido, pela paciência e pela oportunidade em trabalhar com o projeto que gerou o tema da dissertação.

Agradeço aos meus colegas de trabalho do Lactec, em especial ao Eduardo Kazumi Yamakawa, Lucio de Medeiros, Henry Leonardo Lopez Salamanca e Pedro Henrique Roesler por todo o companheirismo e apoio.

Agradeço ao Lactec pelo suporte ao projeto de mestrado e auxílio financeiro.

Este trabalho foi apoiado pelo programa de pesquisa e desenvolvimento tecnológico da Companhia Paranaense de Energia - COPEL, por intermédio do projeto PD-02866-0442/2016, regulado pela ANEEL.

RESUMO

Considerando a operação do sistema elétrico de potência moderno, muitos desafios têm surgido para permitir uma boa integração dos recursos renováveis, além da melhoria da qualidade da energia do sistema de distribuição e sua eficiência. Neste contexto, as microrredes conectadas surgem como uma solução robusta permitindo o gerenciamento ótimo da energia do sistema, melhorando índices de qualidade e trazendo benefícios operativos para rede. Os principais problemas de operação relatados em sistemas de distribuição estão diretamente relacionados com a grande penetração de fontes renováveis, que possuem característica intermitente, além dos picos de demanda de carga, que ocorre principalmente no horário de ponta, resultando em maiores perdas durante a operação do sistema e os problemas de tensão, que trazem impactos nos índices de qualidade da rede elétrica. Assim, este trabalho apresenta um estudo para a aplicação de controle preditivo baseado em modelo (*Model Predictive Control* - MPC) para a operação otimizada de uma microrrede conectada à rede elétrica de distribuição. A microrrede considerada para esse estudo é composta por um conjunto de cargas alimentadas por uma rede de distribuição de média tensão, um sistema de geração fotovoltaico de 200 kWp e um sistema de armazenamento de energia com baterias íon-lítio com capacidade total de 560 kWh. Tanto o sistema fotovoltaico quanto o sistema de armazenamento estão conectados na saída da subestação que abastece a cidade onde a microrrede está implementada. Para orientar o processo de implementação dos algoritmos de controle são considerados três modos de operação da microrrede, sendo eles a Redução do Pico de Demanda, a Suavização da Geração Fotovoltaica e Regulação de Tensão. Dessa forma, são formulados problemas de otimização para cada uma das operações da microrrede utilizando programação linear inteira mista (*Mixed Integer Linear Programming* - MILP). O controle preditivo determina os níveis de potência de carga ou descarga do sistema de armazenamento com base na minimização da função objetivo. Dessa forma, considerando a estratégia de horizonte deslizante, o controle MPC realiza um novo cálculo de otimização a cada dez minutos, ou seja, a cada intervalo de tempo são determinadas novas ações de controle com base nos valores atuais e previstos de geração fotovoltaica e demanda da carga da microrrede. A partir dos resultados obtidos com o controle preditivo são realizadas simulações computacionais utilizando o software *GridLab-D* que avaliam o impacto da operação de Redução de Pico, Suavização da Geração e Regulação de Tensão em um sistema teste sendo possível observar as melhorias em relação à redução do pico de demanda, flutuações de potência e magnitude de tensão no sistema com a aplicação da metodologia de controle preditivo desenvolvida.

Palavras-chave: Microrredes. Controle Preditivo Baseado em Modelo. Programação Linear Inteira Mista.

ABSTRACT

Considering the operation of the modern electric power system, many challenges have arisen to allow a good integration of renewable resources, in addition to improving the energy quality and efficiency of the distribution system. In this context, connected microgrids emerge as a robust solution allowing optimal management of the power system, improving quality indices and bringing operational benefits to the grid. The main operating problems reported in distribution systems are directly related to the high penetration of renewable sources, which have an intermittent characteristic, in addition to peak load demand, which occurs mainly at peak hours, resulting in greater losses during the operation of the system and voltage problems, which impact the quality indices of the grid. The present work presents a study for the application of model-based predictive control for the optimized operation of a microgrid connected to the medium voltage distribution grid. The microgrid considered for this study consists of a set of loads, a 200 kWp photovoltaic generation system and a 560 kWh Lithium-ion battery energy storage. Both the photovoltaic system and the storage system are connected at the substation that supplies the city where the microgrid is implemented. To guide the process of implementation of control algorithms are considered three modes of operation of the microgrid: Peak Shaving, Photovoltaic Generation Smoothing and Voltage Regulation. The optimization problems are formulated for each of the microgrid operations using mixed integer linear programming method. Predictive control determines the charge or discharge power levels of the storage system based on objective function minimization. Thus, considering the rolling horizon strategy, the MPC control performs a new optimization calculation every ten minutes, that is, at each time interval, new control actions are determined based on the current and predicted values of photovoltaic generation and load demand of the microgrid. From the results obtained with predictive control, computer simulations were performed using GridLab-D software to evaluate the impact of Peak Shaving, Generation Smoothing and Voltage Regulation on the test feeder being possible to observe the coherence of results and the improvements in the system with the application of the predictive control methodology developed.

Keywords: Microgrids. Model-Based Predictive Control. Mixed Integer Linear Programming.

LISTA DE FIGURAS

FIGURA 1 - PROJEÇÃO DO CONSUMO DE ENERGIA ELÉTRICA	20
FIGURA 2 - CRESCIMENTO DA MICROGERAÇÃO SOLAR NO BRASIL	21
FIGURA 3 - POTÊNCIA INSTALADA POR FONTE GERADORA	22
FIGURA 4 - CAPACIDADE MUNDIAL DE POTÊNCIA INSTALADA DE BATERIAS .	22
FIGURA 5 - ESTRUTURA TÍPICA DE UMA MICRORREDE.....	28
FIGURA 6 - TOPOLOGIAS E SEGMENTOS DE APLICAÇÕES DE MICRORREDES ...	28
FIGURA 7 - (a) MICRORREDE CA; (b) MICRORREDE CC	30
FIGURA 8 - CONTROLE PRIMÁRIO, SECUNDÁRIO E TERCIÁRIO EM MICRORREDES.....	32
FIGURA 9 - INTERVALO DE TEMPO TÍPICOS DE ATUAÇÃO DE CONTROLE EM MICRORREDES.....	34
FIGURA 10 - ESTRUTURA DA MICRORREDE CONSIDERADA NESTE TRABALHO	40
FIGURA 11 - ESTRATÉGIA DE CONTROLE MPC.....	41
FIGURA 12 - ESTRATÉGIA MPC PARA A MICRORREDE ESTUDADA	42
FIGURA 13 - CURVA DE DEMANDA MÉDIA, MÉDIA SOMADA DE TRÊS DESVIOS PADRÕES (CURVA 1) E MÉDIA SUBTRAÍDA DE TRÊS DESVIOS PADRÕES (CURVA 2).....	47
FIGURA 14 - OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO FOTOVOLTAICA	48
FIGURA 15 - APLICAÇÃO DA MÉDIA MÓVEL PARA DUAS CURVAS DE GERAÇÃO SOLAR NA PRESENÇA DE INTERMITÊNCIAS	50
FIGURA 16 - DIFERENÇA ENTRE A CURVA DE REFERÊNCIA E A CURVA RESULTANTE PV + SAE	51
FIGURA 17 - ESQUEMÁTICO SIMPLIFICADO DA MICRORREDE.....	53
FIGURA 18 - RELAÇÕES DE <i>DROOP</i> CONSIDERANDO A POTÊNCIA ATIVA E REATIVA DA REDE PRINCIPAL, A POTÊNCIA ATIVA E REATIVA DO SAE E A TENSÃO NO PAC	55
FIGURA 19 - BALANÇO DE POTÊNCIA NA MICRORREDE.....	59
FIGURA 20 - FLUXOGRAMA PARA A IMPLEMENTAÇÃO DOS MODELOS DE PREVISÃO.....	65
FIGURA 21 - REDE DE DISTRIBUIÇÃO DE FAXINAL DO CÉU - PR.....	67

FIGURA 22 - ESTRUTURAS DOS POSTES UTILIZADOS NA MODELAGEM DA REDE DE DISTRIBUIÇÃO NO <i>GRIDLAB-D</i>	68
FIGURA 23 - EXEMPLO DA MODELAGEM DE UM CONJUNTO DE CARGAS UTILIZADO NO <i>GRIDLAB-D</i>	69
FIGURA 24 - OBTENÇÃO DAS CURVAS DE CARGA PARA CADA TRANSFORMADOR DA REDE DE DISTRIBUIÇÃO	70
FIGURA 25 - ESQUEMÁTICO SIMPLIFICADO DA CONEXÃO ENTRE A REDE DE SUBTRANSMISSÃO, SUBESTAÇÃO E ALIMENTADORES DE FAXINAL DO CÉU	71
FIGURA 26 - MODELAGEM DO SISTEMA FOTOVOLTAICO NO <i>GRIDLAB-D</i>	73
FIGURA 27 - ESQUEMÁTICO SIMPLIFICADO DA REDE DE FAXINAL DO CÉU COM A INSERÇÃO DO SAE + PV.....	74
FIGURA 28 - REDE DE DISTRIBUIÇÃO 13,8 KV DE FAXINAL DO CÉU	75
FIGURA 29 - CURVA DE DEMANDA MÉDIA DE POTÊNCIA ATIVA E REATIVA DO SISTEMA DE FAXINAL DO CÉU.....	75
FIGURA 30 - TENSÃO NO PAC COM A COMPENSAÇÃO ATIVA DO SAE.....	76
FIGURA 31 - TENSÃO NO PAC COM A COMPENSAÇÃO REATIVA DO SAE.....	77
FIGURA 32 - PONTOS DE OPERAÇÃO CONSIDERADOS PARA A ANÁLISE DA RELAÇÃO DE DROOP NO SISTEMA DE FAXINAL DO CÉU	78
FIGURA 33 - CURVA DE POTÊNCIA REATIVA DO SAE	79
FIGURA 34 - TENSÃO NO PAC COM A VARIAÇÃO DA POTÊNCIA REATIVA PARA O PONTO DE OPERAÇÃO 1	79
FIGURA 35 - TENSÃO NO PAC COM A VARIAÇÃO DA POTÊNCIA REATIVA PARA O PONTO DE OPERAÇÃO 2	80
FIGURA 36 - TENSÃO NO PAC COM A VARIAÇÃO DA POTÊNCIA REATIVA PARA O PONTO DE OPERAÇÃO 3	80
FIGURA 37 - DECAIMENTO DO EQM DURANTE O TREINAMENTO E VALIDAÇÃO DA REDE LSTM PARA A PREVISÃO DE POTÊNCIA ATIVA.....	83
FIGURA 38 - DECAIMENTO DO EQM DURANTE O TREINAMENTO E VALIDAÇÃO DA REDE LSTM PARA A PREVISÃO DE POTÊNCIA REATIVA.....	84
FIGURA 39 - VALORES MEDIDOS E PREVISTOS DE POTÊNCIA ATIVA UTILIZANDO O MODELO DE PREVISÃO IMPLEMENTADO	85

FIGURA 40 - VALORES MEDIDOS E PREVISTOS UTILIZANDO O MODELO DE PREVISÃO PARA POTÊNCIA REATIVA IMPLEMENTADO	85
FIGURA 41 - DECAIMENTO DO EQM DURANTE O TREINAMENTO E VALIDAÇÃO DA REDE LSTM PARA A PREVISÃO DE GERAÇÃO FOTOVOLTAICA	86
FIGURA 42 - VALORES MEDIDOS E PREVISTOS UTILIZANDO O MODELO DE PREVISÃO DE GERAÇÃO FOTOVOLTAICA IMPLEMENTADO.....	87
FIGURA 43 - PROCESSO DE SIMULAÇÃO E OBTENÇÃO DOS RESULTADOS	88
FIGURA 44 - CURVAS DE GERAÇÃO SOLAR COM CARACTERÍSTICA DE DIA ENSOLARADO E NUBLADO	89
FIGURA 45 - CURVA DE CARGA UTILIZADA PARA AS SIMULAÇÕES DA OPERAÇÃO DE PEAK SHAVING	90
FIGURA 46 - RESULTADO PARA A OPERAÇÃO DE PEAK SHAVING CONSIDERANDO AS CONDIÇÕES DO CENÁRIO 1.....	90
FIGURA 47 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING PARA O CENÁRIO 1	91
FIGURA 48 - RESULTADO PARA A OPERAÇÃO DE PEAK SHAVING CONSIDERANDO AS CONDIÇÕES DO CENÁRIO 2.....	92
FIGURA 49 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING PARA O CENÁRIO 2	93
FIGURA 50 - RESULTADO PARA A OPERAÇÃO DE PEAK SHAVING CONSIDERANDO AS CONDIÇÕES DO CENÁRIO 3.....	94
FIGURA 51 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING PARA O CENÁRIO 3	95
FIGURA 52 - RESULTADO PARA A OPERAÇÃO DE PEAK SHAVING CONSIDERANDO AS CONDIÇÕES DO CENÁRIO 4.....	96
FIGURA 53 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING PARA O CENÁRIO 4	97
FIGURA 54 - VALORES DA FUNÇÃO OBJETIVO PARA A OPERAÇÃO DE <i>PEAK SHAVING</i>	99
FIGURA 55 - RESULTADO PARA A OPERAÇÃO DE PEAK SHAVING NO PERÍODO DE UMA SEMANA	100

FIGURA 56 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING NO PERÍODO DE UMA SEMANA.....	100
FIGURA 57 - CURVAS DE GERAÇÃO SOLAR UTILIZADAS NAS SIMULAÇÕES DA OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO FOTOVOLTAICA....	102
FIGURA 58 - OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO CONSIDERANDO A CURVA 1 DE GERAÇÃO FOTOVOLTAICA.....	102
FIGURA 59 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO PARA A CURVA 1 DE GERAÇÃO FOTOVOLTAICA.....	103
FIGURA 60 - TENSÃO NO PAC COM A OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO FOTOVOLTAICA PARA A CURVA 1 DE GERAÇÃO FOTOVOLTAICA.....	104
FIGURA 61 - OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO CONSIDERANDO A CURVA 2 DE GERAÇÃO FOTOVOLTAICA.....	105
FIGURA 62 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO PARA A CURVA 2 DE GERAÇÃO FOTOVOLTAICA.....	105
FIGURA 63 - TENSÃO NO PAC COM A OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO FOTOVOLTAICA PARA A CURVA 2 DE GERAÇÃO FOTOVOLTAICA.....	106
FIGURA 64 - OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO DURANTE O PERÍODO DE QUATRO DIAS	107
FIGURA 65 - ESTADO DE CARGA DO SAE PARA A OPERAÇÃO DE SUAVIZAÇÃO DURANTE O PERÍODO DE QUATRO DIAS.....	107
FIGURA 66 - CURVAS DE POTÊNCIA ATIVA E REATIVA DA CARGA E GERAÇÃO FOTOVOLTAICA UTILIZADAS NAS SIMULAÇÕES DA OPERAÇÃO DE REGULAÇÃO DE TENSÃO	108
FIGURA 67 - CURVAS DE CAPABILIDADE DO SAE	109
FIGURA 68 - TENSÃO DO PAC E POTÊNCIA REATIVA FORNECIDA PELO SAE PARA A OPERAÇÃO DE REGULAÇÃO DE TENSÃO.....	109
FIGURA 69 - FATOR DE POTÊNCIA NA REDE PRINCIPAL COM A ATUAÇÃO DO MPC DURANTE A OPERAÇÃO DE REGULAÇÃO DE TENSÃO	111

FIGURA 70 - PERFIL DE TENSÃO NO HORÁRIO DE 21h. (a) CURVA DE CAPABILIDADE 1. (b) CURVA DE CAPABILIDADE 2.....	112
FIGURA 71 - OPERAÇÃO HÍBRIDA: <i>PEAK SHAVING</i> + SUAVIZAÇÃO DA GERAÇÃO + REGULAÇÃO DE TENSÃO	113
FIGURA 72 - SOC DURANTE A OPERAÇÃO HÍBRIDA DO MPC	114
FIGURA 73 – TENSÃO NO PAC COM O MPC PARA A OPERAÇÃO HÍBRIDA	115
FIGURA 74 - FATOR DE POTÊNCIA COM O MPC NA OPERAÇÃO CONJUNTA	116
FIGURA 75 - OPERAÇÃO HÍBRIDA DO MPC DURANTE UMA SEMANA	117
FIGURA 76 - TENSÃO NO PAC DURANTE A OPERAÇÃO HÍBRIDA DO MPC DURANTE UMA SEMANA.....	117

LISTA DE TABELAS

TABELA 1 - CUSTO DA ENERGIA ELÉTRICA.....	44
TABELA 2 - VALORES DOS PARÂMETROS PARA O CÁLCULO DO COEFICIENTE DE CUSTO DE DEGRADAÇÃO DA BATERIA LINEARIZADO	45
TABELA 3 - CABOS UTILIZADOS NA REDE DE FAXINAL DO CÉU - PR.....	67
TABELA 4 - PARÂMETROS UTILIZADOS NA MODELAGEM DO SAE NO GRIDLAB- D.....	73
TABELA 5 - PARÂMETROS UTILIZADOS NA MODELAGEM DO INVERSOR DO SAE	74
TABELA 6 - VALORES MÉDIOS DE K_A	76
TABELA 7 - VALORES MÉDIOS DE K_R	77
TABELA 8 - VALORES DE A (COEF. ANGULAR), B (COEF. LINEAR) E K_R PARA OS PONTOS DE OPERAÇÃO CONSIDERADOS.....	81
TABELA 9 - MÉDIAS DE A, B E K_R	81
TABELA 10 - DIVISÃO DOS HISTÓRICOS DE DADOS ENTRE TREINO, VALIDAÇÃO E TESTE PARA A IMPLEMENTAÇÃO DOS MODELOS DE PREVISÃO	83
TABELA 11 - PARÂMETROS DAS REDES LSTM PARA A IMPLEMENTAÇÃO DOS MODELOS DE PREVISÃO DE POTÊNCIA ATIVA E REATIVA DA CARGA DA MICRORREDE	84
TABELA 12 - RMSE E R^2 PARA O CONJUNTO DE DADOS DE TESTE DOS MODELOS DE PREVISÃO DE POTÊNCIA ATIVA E REATIVA DA CARGA DA MICRORREDE	84
TABELA 13 - DIVISÃO DO HISTÓRICO DE DADOS ENTRE TREINO, VALIDAÇÃO E TESTE PARA A IMPLEMENTAÇÃO DO MODELO DE PREVISÃO DE GERAÇÃO FOTOVOLTAICA	86
TABELA 14 - PARÂMETROS DA REDE LSTM PARA A IMPLEMENTAÇÃO DO MODELO DE PREVISÃO DE GERAÇÃO FOTOVOLTAICA.....	87
TABELA 15 - RMSE E R^2 PARA O CONJUNTO DE TESTE DO MODELO DE PREVISÃO DE GERAÇÃO FOTOVOLTAICA	87
TABELA 16 - CENÁRIOS CONSIDERADOS PARA AS SIMULAÇÕES DA OPERAÇÃO DE PEAK SHAVING.....	89

TABELA 17 - PICO MÁXIMO E FATOR DE CARGA PARA O CENÁRIO 1 DA OPERAÇÃO DE PEAK SHAVING	91
TABELA 18 - PARÂMETROS DA ATUAÇÃO DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING NAS CONDIÇÕES DO CENÁRIO 1	92
TABELA 19 - PICO MÁXIMO E FATOR DE CARGA PARA O CENÁRIO 2 DA OPERAÇÃO DE PEAK SHAVING	93
TABELA 20 - PARÂMETROS DA ATUAÇÃO DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING NAS CONDIÇÕES DO CENÁRIO 2	94
TABELA 21 - PICO MÁXIMO E FATOR DE CARGA PARA O CENÁRIO 3 DA OPERAÇÃO DE PEAK SHAVING	95
TABELA 22 - PARÂMETROS DA ATUAÇÃO DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING NAS CONDIÇÕES DO CENÁRIO 3	96
TABELA 23 - PICO MÁXIMO E FATOR DE CARGA PARA O CENÁRIO 4 DA OPERAÇÃO DE PEAK SHAVING	97
TABELA 24 - PARÂMETROS DA ATUAÇÃO DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING NAS CONDIÇÕES DO CENÁRIO 4	98
TABELA 25 - PICO MÁXIMO E FATOR DE CARGA PARA O CENÁRIO 5 DA OPERAÇÃO DE PEAK SHAVING	101
TABELA 26 - PARÂMETROS DA ATUAÇÃO DO SAE DURANTE A OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO	103
TABELA 27 - PARÂMETROS DA ATUAÇÃO DO SAE DURANTE A OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO	106
TABELA 28 - VALORES MÍNIMOS DE MAGNITUDE DE TENSÃO NO PAC COM A ATUAÇÃO DO MPC	110
TABELA 29 - VALORES MÍNIMOS DE FATOR DE POTÊNCIA DA REDE PRINCIPAL COM A ATUAÇÃO DO MPC	111
TABELA 30 - VALORES MÍNIMOS DE MAGNITUDE DE TENSÃO NA BARRA 36 .	113
TABELA 31 - PICO MÁXIMO E FATOR DE CARGA PARA A OPERAÇÃO HÍBRIDA DO MPC.....	114
TABELA 32 – VALORES MÍNIMOS DE MAGNITUDE DE TENSÃO NO PAC COM A ATUAÇÃO DO MPC PARA A OPERAÇÃO HÍBRIDA.	115
TABELA 33 - VALORES MÍNIMOS DE FATOR DE POTÊNCIA DA REDE PRINCIPAL COM A ATUAÇÃO DO MPC PARA A OPERAÇÃO HÍBRIDA.	116

TABELA 34 – REDUÇÃO DO PICO DE DEMANDA E FATOR DE CARGA DO SISTEMA COM A OPERAÇÃO DO MPC DURANTE 168 HORAS	118
TABELA 35 – VALORES MÍNIMOS DE MAGNITUDE DE TENSÃO NO PAC COM A ATUAÇÃO DO MPC PARA A OPERAÇÃO HÍBRIDA DURANTE 168 HORAS.	118

LISTAS DE ABREVIATURAS, SIGLAS E ACRÔNIMOS

EPE	-	Empresa de Pesquisa Energética
RED	-	Recursos de Geração Distribuída
MME	-	Ministério de Minas e Energia
ANEEL	-	Agência Nacional de Energia Elétrica
IRENA	-	International Renewable Energy Agency
CGEE	-	Centro de Gestão e Estudos Estratégicos
BMS	-	<i>Battery Management Systems</i>
IEEE	-	<i>Institute of Electrical and Electronics Engineers</i>
CA	-	Corrente alternada
CC	-	Corrente contínua
MPC	-	<i>Model Predictive Control</i>
MILP	-	<i>Mixed Integer Linear Programming</i>
LSTM	-	<i>Long Short-Term Memory</i>
MAPE	-	<i>Mean Absolute Percentage Error</i>
RMSE	-	<i>Root Mean Square Error</i>
SAE	-	Sistema de Armazenamento de Energia
PV	-	Painéis Fotovoltaicos
PAC	-	Ponto de Acoplamento Comum

LISTAS DE SÍMBOLOS

PARÂMETROS

- λ_E - Preço da energia ($R\$/kWh$)
- t_s - Intervalo de tempo (h)
- T - Total de instantes de tempo
- λ_b - coeficiente de custo de degradação da bateria linearizado ($R\$/kWh$)
- λ_{cell} - custo da célula de bateria ($R\$/kWh$)
- N - Número de ciclos que a bateria pode operar durante a vida útil
- SOC_{max} - Estado de carga máximo do SAE (%)
- SOC_{min} - Estado de carga mínimo do SAE (%)
- σ - Desvio padrão
- SOC^{REF} - Valor do estado de carga de referência (%)
- K_A - Fator de sensibilidade da tensão com relação a potência ativa (kW/pu)
- ΔP_{SAE} - Variação de potência ativa do SAE (kW);
- ΔV_{PAC} - Variação de tensão no PAC (pu);
- K_R - Fator de sensibilidade da tensão com relação a potência reativa ($kvar/pu$)
- ΔQ_{SAE} - Variação de potência reativa do SAE ($kvar$)
- V_{REF}^{PAC} - Tensão nominal do PAC (pu);
- P_{max} - Potência ativa máxima que pode ser fornecida ou absorvida pelo SAE (kW)
- Q_{MAX}^{SAE} - Potência Reativa máxima do SAE ($kvar$);
- $Q_{MÍN}^{SAE}$ - Potência Reativa mínima do SAE ($kvar$);
- E - Capacidade total do SAE (kWh);
- η_{SAE} - Rendimento do SAE (%);

VARIÁVEIS CONTÍNUAS

- P_i^{Rede} - Potência ativa demandada da rede principal pela microrrede no instante i (kW)
- $P_i^{SAE\ dc}$ - Potência descarregada pelo SAE no instante i (kW)
- $P_i^{SAE\ ch}$ - Potência carregada pelo SAE no instante i (kW)
- SOC_i - Estado de carga do SAE no instante atual (%)
- PV_i^{ref} - Curva de referência da planta solar no instante i (kW)
- P_i^{PV} - Potência gerada pelo PV no instante i (kW)
- V_i^{PAC} - Tensão no PAC no instante i (pu)
- P_i^{carga} - Potência demandada pela carga e perdas no instante i (kW)

- Q_i^{Rede} - Potência reativa na rede principal no instante i ($kvar$)
 Q_i^{SAE} - Potência reativa do SAE no instante i ($kvar$)
 Q_i^{Carga} - Potência ativa da carga no instante i ($kvar$)

VARIÁVEIS BINÁRIAS

- $\delta_i^{SAE\ ch}$ - Variável binária de decisão de carga do SAE no instante i
 $\delta_i^{SAE\ dc}$ - Variável binária de decisão de descarga do SAE no instante i

SUMÁRIO

1	INTRODUÇÃO	20
1.1	MOTIVAÇÃO	20
1.2	OBJETIVO GERAL	24
1.3	OBJETIVOS ESPECÍFICOS	25
2	CONCEITOS BÁSICOS E REVISÃO DE LITERATURA.....	26
2.1	GERAÇÃO DISTRIBUÍDA	26
2.2	MICRORREDES.....	27
2.2.1	Microrredes CA	29
2.2.2	Microrredes CC	29
2.2.3	Microrredes Híbridas	30
2.2.4	Controle de Microrredes	31
2.2.5	Hierarquia de controle em microrredes.....	32
2.2.5.1	Controle primário	32
2.2.5.2	Controle Secundário	33
2.2.5.3	Controle Terciário	33
2.3	REVISÃO DA LITERATURA.....	34
3	METODOLOGIA.....	40
3.1	ESTRUTURA DA MICRORREDE.....	40
3.2	ABORDAGEM MPC	41
3.3	MODELOS DE OTIMIZAÇÃO	43
3.3.1	Operação <i>Peak Shaving</i>	43
3.3.1.1	Função Objetivo	43
3.3.2	Operação Suavização da Geração.....	48
3.3.2.1	Função objetivo	50
3.3.3	Operação Regulação de Tensão	51
3.3.3.1	Função objetivo	51
3.3.3.2	Compensação ativa e reativa	52
3.3.4	Operação Híbrida: <i>Peak Shaving</i> + Suavização da Geração + Regulação de Tensão	57
3.3.4.1	Função Objetivo	57
3.3.5	Restrições	58
3.4	MODELOS DE PREVISÃO.....	63
3.4.1	Previsão de Carga e Geração Fotovoltaica.....	63
4	CASO ESTUDADO	66
4.1	MODELAGEM DO SISTEMA DE FAXINAL DO CÉU	66


4.1.1	Rede de Distribuição de Faxinal do Céu.....	66
4.1.2	Modelagem do Sistema no <i>GridLAB-D</i>	66
4.1.2.1	Segmentos de Linha.....	67
4.1.2.2	Transformadores.....	68
4.1.2.3	Cargas.....	68
4.1.2.4	Linha de Subtransmissão e Subestação.....	71
4.1.2.5	Sistema de Geração Fotovoltaica.....	71
4.1.2.6	Sistema de Armazenamento de Energia.....	73
4.1.2.7	Compensação ativa e reativa para o caso estudado.....	74
4.1.2.8	Modelos de previsão de carga e geração fotovoltaica para o caso estudado.....	82
4.1.2.9	Previsão de Carga para o caso estudado.....	82
4.1.2.10	Previsão de Geração Fotovoltaica para o caso estudado.....	85
5	SIMULAÇÕES E RESULTADOS.....	88
5.1	OPERAÇÃO DE <i>PEAK SHAVING</i>	88
5.2	OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO.....	101
5.3	OPERAÇÃO DE REGULAÇÃO DE TENSÃO.....	108
5.4	OPERAÇÃO HÍBRIDA: <i>PEAK SHAVING</i> + SUAVIZAÇÃO DA GERAÇÃO + REGULAÇÃO DE TENSÃO.....	113
6	CONCLUSÃO.....	119
6.1	TRABALHOS FUTUROS.....	119
	REFERÊNCIAS.....	121

1 INTRODUÇÃO

1.1 MOTIVAÇÃO

A demanda de energia elétrica no Brasil caracteriza-se pela tendência de contínuo crescimento. Conforme o Caderno de Demanda de Eletricidade divulgado pelo EPE (2018) o consumo de energia para o ano de 2017 foi de 465,0 TWh e, de acordo com as projeções, deve atingir a marca de 787,5 TWh em 2032, representando um aumento anual de 3,6% no consumo de energia elétrica, conforme apresentado na FIGURA 1.

FIGURA 1 - PROJEÇÃO DO CONSUMO DE ENERGIA ELÉTRICA



FONTE: EPE (2018)

Neste cenário de crescimento na demanda por energia elétrica surgem os chamados recursos de geração distribuídos (RED), que consistem em tecnologias de geração de energia, normalmente renováveis, e sistemas de armazenamento de energia localizados próximos às unidades consumidoras (EPE, 2019).


Segundo o Plano Nacional de Energia (PNE) 2050 (EPE & MME, 2020) a inserção de RED tem apresentado um crescimento nos últimos anos devido à reduções de custos, maior difusão de novas tecnologias de telecomunicação e controle e maior participação dos consumidores no setor elétrico.

Devido aos benefícios que a geração distribuída pode proporcionar ao sistema elétrico, a Agência Nacional de Energia Elétrica (ANEEL) viabilizou a conexão de pequenos e médios geradores ao sistema de distribuição através da Resolução Normativa nº 482/2012

(ANEEL, 2012) que estabelece as condições para o acesso de microgeração e minigeração distribuída aos sistemas de distribuição de energia elétrica.

A partir deste cenário de estímulo à micro e minigeração distribuída, a FIGURA 2 apresenta um levantamento realizado pela ANEEL (ANEEL, 2017) referente à evolução da potência instalada de microgeração solar fotovoltaica no Brasil no período de 2012 até 2017. Na FIGURA 2 é possível observar o elevado crescimento da microgeração solar após a divulgação da normativa nº 482/2012.

FIGURA 2 - CRESCIMENTO DA MICROGERAÇÃO SOLAR NO BRASIL




FONTE: ANEEL (2017)

Na FIGURA 3 é destacada a potência instalada por tipo de fonte geradora. De acordo com a figura, a geração solar fotovoltaica corresponde a aproximadamente 70% da microgeração no Brasil em 2017.


Outra importante mudança que está ocorrendo dentro do sistema elétrico é a inserção de tecnologias de armazenamento de energia. Na FIGURA 4 é apresentado um levantamento realizado por IRENA (2017) com relação à capacidade de potência instalada de baterias. Com base na figura é possível observar um crescimento exponencial na capacidade instalada de baterias nos últimos anos.

FIGURA 3 - POTÊNCIA INSTALADA POR FONTE GERADORA



FONTE: ANEEL (2017)

FIGURA 4 - CAPACIDADE MUNDIAL DE POTÊNCIA INSTALADA DE BATERIAS



FONTE: IRENA (2017)

O Plano Decenal de Expansão de Energia 2029 (EPE & MME, 2020) indica que as tecnologias de armazenamento de energia por baterias são uma alternativa para aumentar a capacidade do sistema elétrico, visando a complementação de potência.

Segundo o PNE 2050 (EPE & MME, 2020) as tecnologias de armazenamento, em especial as baterias, podem ser integradas juntamente com a geração distribuída (GD) para reduzir a injeção do excesso de eletricidade na rede e/ou realizar o deslocamento do consumo de eletricidade de acordo com as necessidades do sistema elétrico.

Segundo Centro de Gestão e Estudos Estratégicos (CGEE, 2017) os sistemas de armazenamento de energia, tanto de pequeno quanto de grande porte, trazem uma maior

confiabilidade e qualidade no fornecimento de energia. Além disso, os sistemas de armazenamento permitem uma maior integração de fontes de energia intermitentes, como a solar e a eólica. Dentre as rotas prioritárias de investimentos em P&D no Brasil para os próximos anos com foco em sistemas de armazenamento, CGEE (2017) estabeleceu como prioridade os investimentos em BMS (*Battery Management Systems*) seguido de tecnologias de armazenamento utilizando baterias.

Com o objetivo de avaliar a inserção de sistemas de armazenamento de energia dentro do sistema elétrico brasileiro, em 2016 a ANEEL lançou a chamada pública nº 021/2016, visando o desenvolvimento de projetos que utilizam tecnologia de armazenamento, desde baterias de íon de lítio até sistemas de usinas reversíveis. Ao todo foram aprovados 23 projetos de P&D envolvendo diversas tecnologias de armazenamento dentro do sistema elétrico (ANEEL, 2017).

De acordo com o documento apresentado pela EPE, em 2019, que trata de sistemas de armazenamento em baterias (EPE, 2019) dentre as diversas tecnologias de armazenamento de energia com baterias destaca-se a tecnologia de íons de lítio, devido a elevada utilização desta tecnologia em carros elétricos e nos mais diversos equipamentos eletrônicos. Com a elevada utilização e aumento expressivo na produção, as baterias de íons de lítio têm apresentado uma tendência de redução em seu custo, sendo cada vez mais viável a sua utilização dentro de sistemas elétricos.

Neste contexto de geração distribuída e sistemas de armazenamento de energia surgem as chamadas microrredes. De acordo com a normalização apresentada a respeito do tema pelo IEEE (IEEE PES, 2018) uma microrrede é formada pela interconexão de cargas e recursos de geração distribuída em uma área claramente definida e que possui recursos de controle, podendo atuar de forma conectada ou isolada da rede elétrica principal.

A possibilidade de integrar fontes de energia intermitentes como a solar e eólica, juntamente com sistemas de armazenamento de energia, e com a vantagem desses sistemas poderem ser instalados próximos aos centros consumidores e possuírem recursos de controle para o gerenciamento da operação, fazem das microrredes uma possibilidade atrativa tanto para pequenos consumidores quanto para grandes indústrias e concessionárias de energia.

Segundo IEEE PES (2018) as microrredes podem oferecer suporte à rede principal de energia quando operando no modo conectado com à rede. Esse suporte pode ser na forma de redução de picos de demanda, melhoramento da qualidade de energia e regulação de tensão.

Com isso, às inúmeras vantagens das microrredes, o aumento da inserção de geração distribuída e o aprimoramento das tecnologias de armazenamento de energia com baterias,

permitiu ao setor elétrico sofrer uma grande mudança de paradigma segundo EPE (2019), necessitando de novas abordagens de planejamento e operação, impondo grandes desafios para os próximos anos. Segundo Perez (2020), devido a característica intermitente de fontes de energia renovável como a eólica e a solar, a alta penetração de recursos de geração distribuída traz alguns impactos e desafios para a integração destes recursos no sistema elétrico. Devido a característica intermitente, fontes de geração como a solar e eólica não são controláveis para o despacho de energia visto que a produção de energia destas fontes está relacionada a fenômenos naturais e não a demanda da carga. Além disso, segundo Perez (2020) a necessidade de uma interface eletrônica, via conversor de potência, para a conexão das fontes de energia renovável na rede elétrica resulta em uma redução da inércia do sistema.

Diante dos novos desafios de integração das microrredes no setor elétrico é necessário abordagens de controle que permitam uma operação segura, otimizada e econômica da microrrede. Nesse sentido, existem várias técnicas e diferentes abordagens de controle para a operação da microrrede. Dentre as técnicas de controle, o controle preditivo baseado em modelo (do inglês *Model predictive control* – MPC) têm se destacado no controle otimizado de microrredes. No contexto de microrrede, segundo Hu *et al.* (2021), o MPC trata-se de uma abordagem de controle avançado que determina as ações de controle com base na minimização de uma determinada função objetivo de forma a permitir o despacho ótimo das unidades de geração distribuída presentes na microrrede.

Diante dos avanços na inserção de sistemas de armazenamento e geração distribuída na rede elétrica, este trabalho tem como base o projeto de PD ANEEL 02866-0442/2016 “Sistema de Controle Ótimo de Microgrid com Armazenamento de Energia para Smartgrid”, originado da chamada nº 21 da ANEEL – “Arranjos Técnicos e Comerciais para a Inserção de Sistemas de Armazenamento de Energia no Setor Elétrico Brasileiro”. O projeto está sendo executado pelos Institutos Lactec tendo como empresa contratante a Companhia Paranaense de Energia (COPEL).

Diante dessas premissas, o objetivo geral e os objetivos específicos pretendidos com a presente dissertação são apresentados na próxima seção.

1.2 OBJETIVO GERAL

O objetivo geral deste trabalho é o desenvolvimento de um algoritmo de controle utilizando a abordagem de controle preditivo baseado em modelo (MPC, do inglês *Model Predictive Control*) para a otimização da operação de uma microrrede conectada ao sistema

de distribuição de energia elétrica, onde são considerados três modos de operação: *peak shaving* ou redução do pico de demanda, suavização da geração e regulação de tensão.

1.3 OBJETIVOS ESPECÍFICOS

Os objetivos específicos deste trabalho são:

1. Estudar e compreender os principais elementos que constituem uma microrrede e a estrutura hierárquica de controle presentes em sistemas com microrredes.
2. Propor uma formulação para a otimização da redução do pico de demanda, suavização da geração e regulação de tensão utilizando a abordagem de programação linear inteira mista. Além disso, propor uma formulação considerando a realização das três operações simultaneamente (*peak shaving*, suavização da geração e regulação de tensão) em um único problema de otimização.
3. Propor um modelo de previsão de carga e de previsão de geração fotovoltaica necessários na abordagem MPC.
4. Implementar e validar computacionalmente o algoritmo de controle proposto.

2 CONCEITOS BÁSICOS E REVISÃO DE LITERATURA

Nesta seção, são abordados os principais conceitos envolvendo geração distribuída, microrredes e os principais tópicos relacionados a hierarquia de controle presente em microrredes. Na sequência, é realizada a revisão de literatura destacando os principais trabalhos relacionados com o tema.

2.1 GERAÇÃO DISTRIBUÍDA

A Geração distribuída vem cada vez ganhando espaço dentro do cenário nacional e mundial devido aos avanços tecnológicos ocorridos nos últimos anos e aos incentivos econômicos e ambientais para a inserção dessa modalidade dentro dos sistemas de energia elétrica. Para compreender melhor no que consiste a geração distribuída é necessário buscar as definições de geração distribuída dentro da literatura científica.

O trabalho de Pepermans *et al.* (2005) aborda um estudo de diferentes tecnologias, oportunidades, potenciais problemas e as definições de geração distribuída. De acordo com os autores, existe uma ampla variedade de definições envolvendo a geração distribuída, podendo ser definida em termos de geração de grande escala conectada no sistema de transmissão ou de pequena escala conectada no sistema de distribuição de energia. Do ponto de vista dos autores, a definição mais adequada de geração distribuída consiste em uma fonte de geração de energia que é conectada diretamente na rede de distribuição de energia ou conectada no local de consumo de energia, ou seja, no lado do cliente.

No trabalho de Ackermann *et al.* (2001) é realizada uma discussão sobre as questões mais relevantes para fornecer uma definição de geração distribuída. Dessa forma, de acordo com os autores, fatores como localização, potência máxima, área de atuação e tecnologia da fonte geradora não são fatores levados em consideração na definição de geração distribuída. Com isso, a geração distribuída, segundo os autores, pode ser definida como uma fonte de geração conectada diretamente na rede de distribuição de energia ou no próprio consumidor. Apesar da potência máxima não ser um fator para a definição de geração distribuída, os autores propõem que a geração distribuída pode ser classificada em diferentes categorias dependendo da faixa de potência da unidade geradora, sendo:

- Micro: de 1 W até 5 kW;
- Pequena: de 5 kW até 5 MW;
- Média: de 5 MW até 50 MW;

- Grande: 50 MW até 300 MW.

No cenário nacional, a Agência Nacional de Energia Elétrica (ANEEL) por meio da Resolução normativa 482/2012 classifica a geração distribuída em duas categorias, sendo a microgeração distribuída, composta por unidade geradora com potência instalada menor ou igual a 75 kW, e minigeração distribuída, composta por unidade geradora com potência instalada superior a 75 kW e inferior ou igual a 5 MW.

A inserção da geração distribuída dentro dos sistemas elétricos pode prover benefícios tanto para as concessionárias de energia quanto para os consumidores, sendo que esses benefícios podem ser técnicos, econômicos e/ou ambientais.

De acordo com Pepermans *et al.* (2005) alguns dos incentivos para a inserção de geração distribuída do ponto de vista dos operadores do sistema é servir como uma alternativa para evitar investimentos em expansão da capacidade do sistema de transmissão e distribuição, além de promover suporte à rede elétrica através de serviços ancilares.

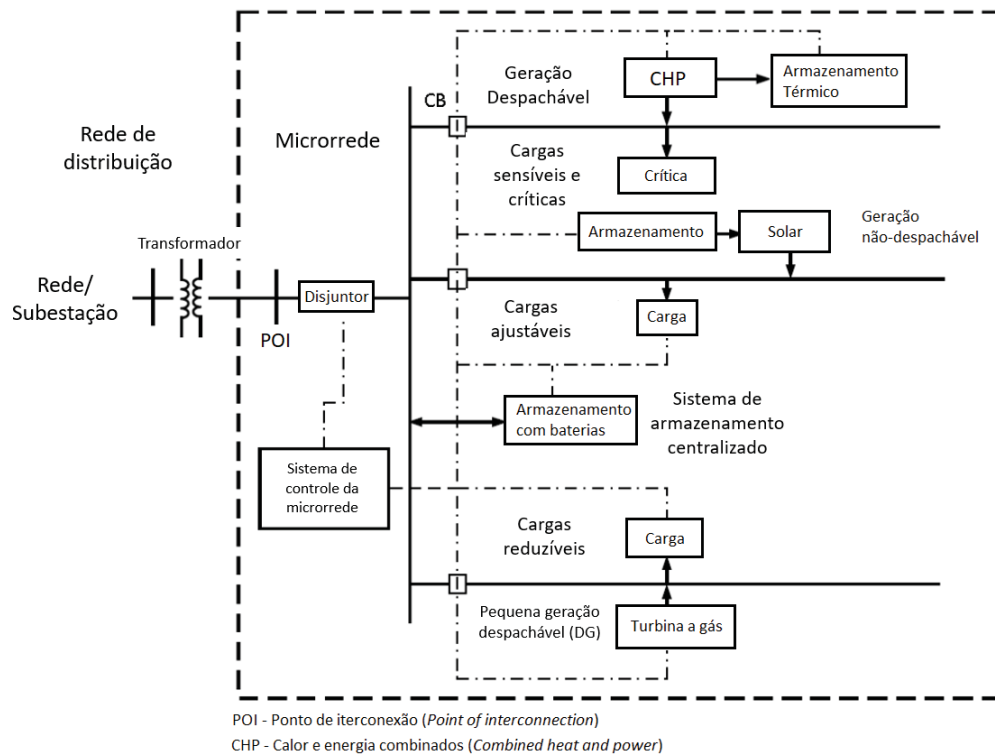
De acordo com Lopes *et al.* (2007), a inserção da geração distribuída próximos aos centros de consumo pode resultar na melhoria da qualidade de energia e proporcionar uma maior confiabilidade do fornecimento de energia, visto que em alguns casos, os consumidores podem ser atendidos pelos recursos de geração distribuída mesmo com a interrupção do fornecimento da rede principal de energia.

2.2 MICRORREDES

As microrredes podem ser definidas como um conjunto de cargas e recursos de geração distribuída dentro de uma determinada área bem definida e que pode atuar tanto conectada ou isolada da rede elétrica de distribuição (IEEE PES, 2018). A FIGURA 5 ilustra uma típica configuração de microrrede formada por fontes de geração solar, eólica, geradores síncronos e sistemas de armazenamento de energia.

Conforme ilustrado na FIGURA 5, além dos recursos de geração distribuída e das cargas, as microrredes também possuem um sistema de controle e comunicação responsáveis pela estabilidade, otimização e confiabilidade da operação da microrrede (Farrokhabadi *et al.*, 2020). O controle da microrrede é abordado com mais detalhes na próxima seção sobre estrutura e hierarquia de controle de microrredes.

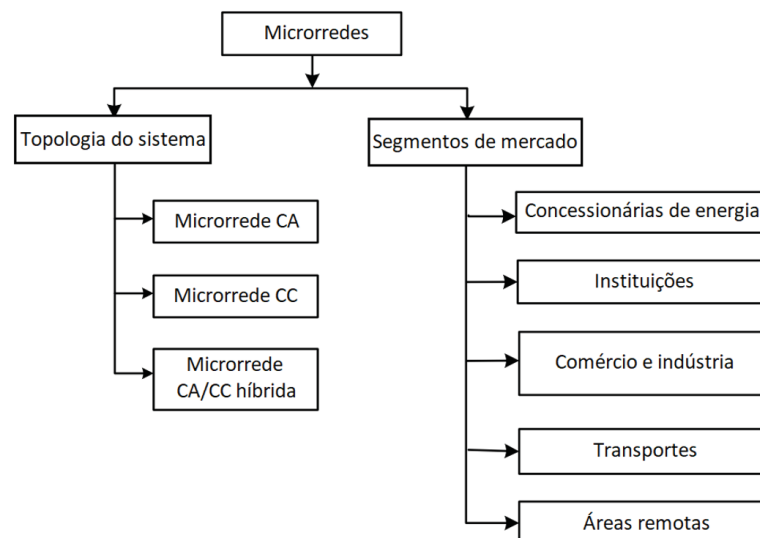
FIGURA 5 - ESTRUTURA TÍPICA DE UMA MICRORREDE



FONTE: IEEE PES (2018)

As microrredes podem possuir diferentes configurações ou topologias que dependem da aplicação na qual está sendo empregada. A FIGURA 6, apresentada no trabalho de Ahmed *et al.* (2020), apresenta as principais topologias e segmentos de aplicação das microrredes.

FIGURA 6 - TOPOLOGIAS E SEGMENTOS DE APLICAÇÕES DE MICRORREDES

AHMED *et al.* (2020)

Conforme a FIGURA 6, as microrredes podem ser empregadas em uma ampla variedade de segmentos, tanto no setor industrial e comercial, quanto na aplicação por concessionárias de energia. Também é possível o atendimento de áreas remotas onde há pouca acessibilidade a energia elétrica por meio de redes de distribuição convencionais.

As microrredes também são utilizadas na integração de sistemas com diferentes fontes de energia e diferentes sistemas de armazenamento de energia. Neste contexto, o trabalho de Perez *et al.* (2019) traz um estudo de um controle de uma microrrede CC composta por dois tipos de sistemas de geração de energia, sendo um sistema fotovoltaico e um sistema de frenagem regenerativa presente em trens, e dois sistemas de armazenamento de energia, sendo um por meio de baterias e outro através de supercapacitor. A estratégia de controle proposta pelos autores se mostrou adequada, sendo que a microrrede permitiu a integração das diferentes fontes de energia e de sistemas de armazenamento e o controle da microrrede operou de forma a garantir um nível adequado de perfil de tensão no sistema.

A FIGURA 6 também ilustra a classificação das microrredes de acordo com a topologia do sistema, podendo ser microrredes CA, CC ou Híbridas. Na sequência, é realizada uma breve explicação sobre cada uma dessas topologias ou arquiteturas de microrredes.

2.2.1 Microrredes CA

A microrrede CA é a topologia mais comum de microrrede, sendo necessárias poucas modificações na rede elétrica para a integração deste tipo de microrrede visto que a rede elétrica da concessionária opera em CA. As fontes de geração ou os sistemas de armazenamento são integrados na microrrede CA através de conversores eletrônicos CA-CC ou CC-CA conforme ilustrado na FIGURA 7 (a) (AHMED *et al.*, 2020).

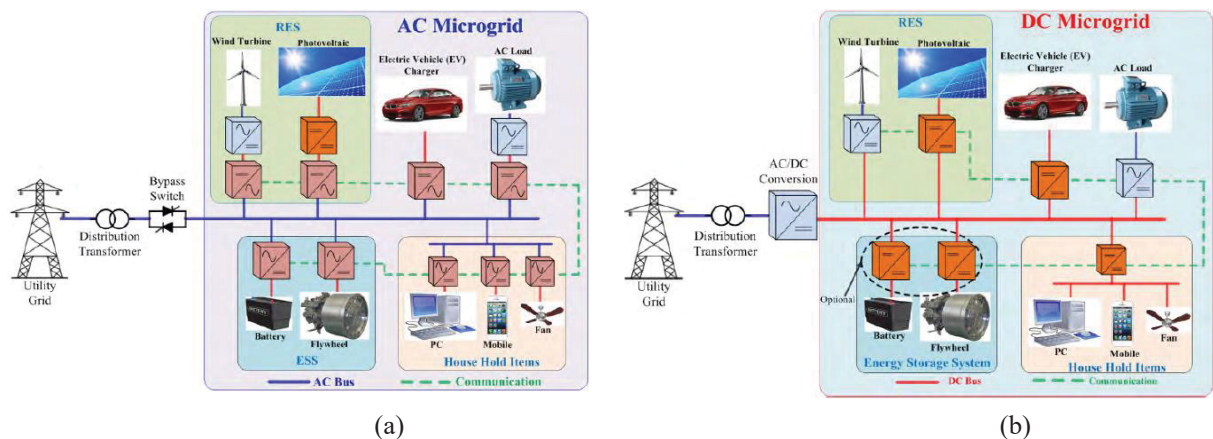
Apesar das microrredes CA proporcionarem o mínimo de modificações na rede elétrica da concessionária, fontes de geração solar e cargas CC apresentam um elevado crescimento no setor industrial e residencial e necessitam de estágio de conversão CA-CC para o acoplamento dessas cargas e fontes na rede CA. Com isso, esses múltiplos estágios de conversão CA-CC podem reduzir a eficiência do sistema (KUMAR *et al.*, 2017).

2.2.2 Microrredes CC

A utilização de microrredes CC se justifica pelo fato da grande quantidade de cargas e de alguns recursos de geração distribuída, como geração solar e alguns sistemas de

armazenamento, operarem em CC. Dessa forma, com a utilização de microrredes CC, ocorre a redução de estágios de conversão CA-CC dentro da microrrede e a eliminação de corrente reativa no sistema (AHMED *et al.*, 2020). A FIGURA 7 (b) ilustra a topologia de uma microrrede CC. Conforme ilustrado na figura, apesar da diminuição dos estágios de conversão CA-CC no interior da microrrede, é necessário a utilização de um conversor CA-CC para realizar a interface entre a microrrede e a rede elétrica da concessionária. Outro ponto importante das microrredes CC é com relação à integração dos recursos de geração distribuída. Segundo Kumar *et al.* (2017), apesar de alguns sistemas de armazenamento operarem em CC, pode não ser adequado à conexão “direta” desses sistemas de armazenamento na microrrede, ou seja, a microrrede CC não dispensa totalmente o uso de conversores CC-CC. Dessa forma, é aconselhável a utilização de conversores CC-CC para evitar flutuações de tensão, visto que as flutuações de tensão podem gerar problemas relacionados à estabilidade e proteção da microrrede CC.

FIGURA 7 - (a) MICRORREDE CA; (b) MICRORREDE CC



FONTE: KUMAR *et al.* (2017)

2.2.3 Microrredes Híbridas

A combinação das microrredes CA e CC resulta em uma topologia conhecida como microrredes híbridas e esse tipo de topologia apresenta a combinação das vantagens de cada um dos sistemas, CA e CC, proporcionando uma maior confiabilidade, eficiência e economia da operação da microrrede (AHMED *et al.*, 2020).

2.2.4 Controle de Microrredes

Conforme apresentado nas subseções anteriores, as microrredes podem ser formadas por várias fontes de energia com características distintas e diferentes configurações ou topologias, podendo ser microrredes CA, CC ou Híbridas. Além disso, algumas fontes de geração como a solar e a eólica apresentam um comportamento intermitente devido a fatores climáticos não controláveis. Dessa forma, a geração dessas fontes apresenta uma imprevisibilidade que deve ser levada em conta na operação da microrrede. Os sistemas de armazenamento de energia desempenham um papel importante na integração dos recursos de geração distribuída, como a geração solar e eólica, promovendo uma maior confiabilidade frente às imprevisibilidades destes tipos de geração, podendo atuar de forma semelhante a um gerador síncrono, absorvendo os erros temporários entre a geração e a carga da microrrede (Olivares *et al*, 2014).

Neste contexto, para gerenciar e controlar os recursos energéticos da microrrede e permitir diferentes modos de operação da mesma, as microrredes necessitam de uma estrutura de controle que atua em vários níveis, promovendo uma operação segura, confiável e econômica da microrrede.

De acordo com IEEE PES (2018), o sistema de controle de microrredes abrange as funcionalidades de controle que permitem que a microrrede opere de modo automático, permitindo a conexão ou a desconexão da rede principal, ou seja, operação em modo conectado ou isolado, e que provem serviços ancilares de energia para a rede principal. Dessa forma, o sistema de controle é capaz de coordenar automaticamente as unidades de geração, os sistemas de armazenamento, as cargas controláveis e as interações entre a microrrede e a rede principal na qual está conectada.

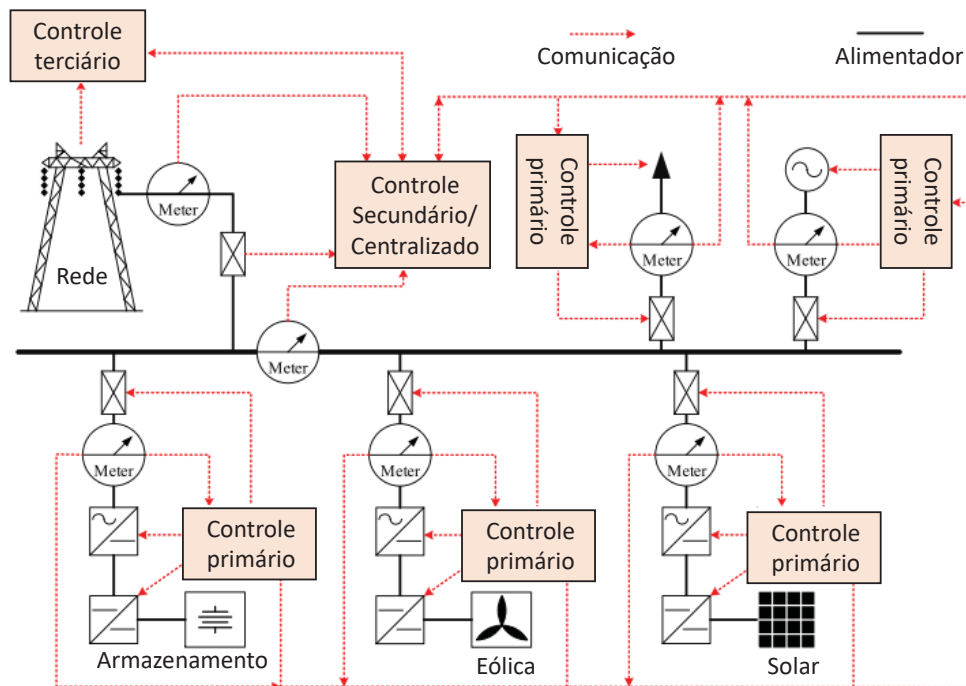
O sistema de controle da microrrede deve atuar nas seguintes situações, segundo IEEE PES (2018):

- Operação no modo conectada ou isolada da rede principal;
- Transição automática do modo conectada para isolada da rede principal;
- Ressincronização e reconexão do modo isolada para o modo conectado;
- Gerenciamento de energia, buscando a otimização da geração de potência ativa e reativa;
- Quando aplicável, prover serviços ancilares e suporte a rede elétrica da concessionária.

2.2.5 Hierarquia de controle em microrredes

No trabalho de Guerrero *et al.* (2011) a estrutura hierárquica de controle de microrredes CA é composta por quatro níveis de controle, sendo nível 0 ou *loop* de controle interno, nível 1 ou controle primário, nível 2 ou controle secundário e nível 3 ou controle terciário. De forma semelhante, os trabalhos de Ahmed *et al.* (2020) e Olivares *et al.* (2014) classificam a hierarquia de controle em microrredes em três níveis: primário, secundário e terciário. A FIGURA 8 apresenta uma configuração típica da hierarquia de controle em microrredes. Conforme ilustrado na FIGURA 8, cada nível de controle atua em diferentes pontos do sistema com funcionalidades distintas entre eles. Estas funcionalidades são descritas na sequência.

FIGURA 8 - CONTROLE PRIMÁRIO, SECUNDÁRIO E TERCIÁRIO EM MICRORREDES



FONTE: FARROKHABADI *et al.* (2020)

2.2.5.1 Controle primário

Conforme ilustrado na FIGURA 8, o controle primário atua de forma local em cada DER ou cargas presentes na microrrede. De acordo com Olivares *et al.* (2014), dentre as funcionalidades do controle primário estão a detecção de ilhamento, controle da potência de saída e balanço energético. De acordo com Guerrero *et al.* (2011), o controle primário atua no

ajuste da frequência e tensão de referência que serão repassados para o controle interno de corrente e tensão dos inversores conectados aos DERs. Dessa forma, o controle primário atua de forma semelhante ao comportamento de um gerador síncrono, o qual reduz a frequência conforme o aumento da potência ativa.

Devido a característica e funcionalidade do controle primário, este apresenta o tempo de resposta mais rápido dentre os níveis de controle na microrrede, atuando na faixa de microssegundos até segundos (IEEE PES, 2018).

2.2.5.2 Controle Secundário

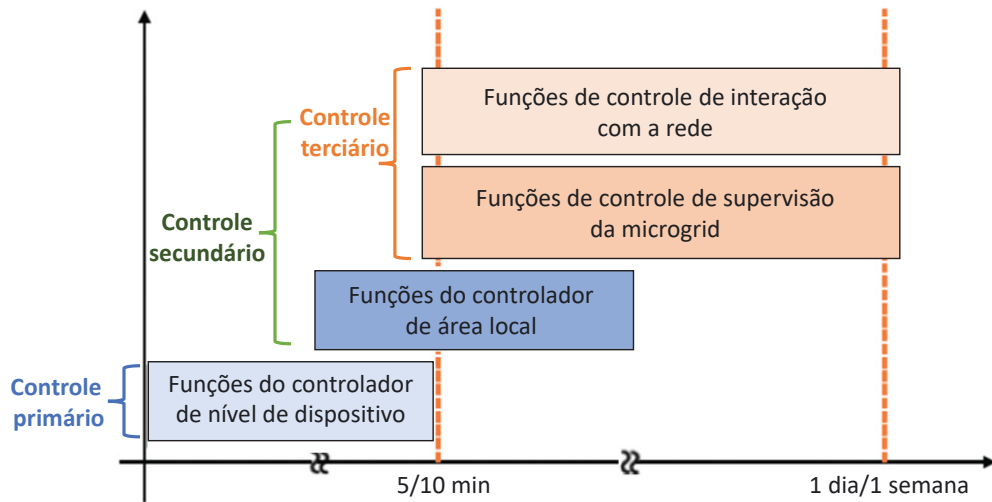
De acordo com Olivares *et al.* (2014), o controle secundário é responsável por promover uma operação confiável, segura e econômica da microrrede e compensar os desníveis de tensão e frequência produzidas pelas ações do controle primário. De acordo com os autores, esse nível de controle também pode ser chamado de Sistema de Gerenciamento de Energia (do inglês *Energy Management System* - EMS) da microrrede o qual é responsável pelo despacho dos DERs de forma a atingir um determinado objetivo de operação com a microrrede. De acordo com Guerrero *et al.* (2011), o controle secundário atua de forma a comparar a frequência e a amplitude da tensão com os respectivos valores de referências dessas grandezas, e atua na compensação desses erros de forma a enviar as ações de controle para restaurar a tensão e frequência na saída das unidades presentes na microrrede. O controle secundário possui um tempo de resposta mais lento comparado ao controle primário, podendo atuar na ordem de segundos até horas (IEEE PES, 2018).

2.2.5.3 Controle Terciário

O controle terciário compreende o nível mais alto na hierarquia de controle. De acordo com Ahmed *et al.* (2020), quando a microrrede opera no modo conectada à rede, o controle terciário atua no gerenciamento do fluxo de potência ativa e reativa entre microrrede e a rede principal através do ajuste das referências de potência dos DERs. De acordo com Olivares *et al.* (2014), o controle terciário atua de forma a coordenar a operação de múltiplas microrredes de forma a promover suporte a rede principal na qual estão conectadas, como por exemplo, na regulação de tensão e frequência. O controle terciário geralmente possui o tempo de resposta mais lento entre os três níveis de controle em microrredes, conforme ilustrado na FIGURA 9,

onde é mostrado o tempo de atuação típicos da hierarquia de controle em microrredes segundo IEEE PES (2018).

FIGURA 9 - INTERVALO DE TEMPO TÍPICOS DE ATUAÇÃO DE CONTROLE EM MICRORREDES



FONTE: IEEE (2018)

2.3 REVISÃO DA LITERATURA

Nesta seção são apresentados os principais trabalhos reportados na literatura científica relacionados a otimização e controle de microrredes, gerenciamento de sistemas com armazenamento de energia e recursos de geração distribuída que foram utilizados como base para a elaboração desta dissertação.

No trabalho de Perez *et al.* (2021) é proposto a utilização da estratégia de controle preditivo baseado em modelo (MPC) para a otimização de uma microrrede gerenciada pela concessionária de energia. A microrrede considerada no trabalho é composta por um sistema de armazenamento de energia e por um sistema de geração fotovoltaica, ambos conectados na subestação do sistema de distribuição. Nesse contexto, são apresentadas duas abordagens de MPC, sendo uma aplicada a operação da microrrede conectada à rede e outra para o modo isolada da rede principal. Para ambos os modos, foi utilizado programação linear inteira mista para a formulação do problema de otimização. Para o modo conectado, a microrrede é capaz de fornecer suporte à rede principal na forma de redução de picos de demanda (*peak shaving*) e na suavização da geração fotovoltaica, reduzindo as variações abruptas na saída do gerador solar. A função objetivo do problema de otimização do modo conectado leva em consideração o custo da energia elétrica da rede principal, o custo de utilização do SAE, desvios de

potência em relação à referência estabelecida e fatores de penalidade caso os requisitos de melhoria na qualidade de energia não sejam atendidos. Dessa forma, a estratégia de controle determina a carga e descarga do SAE de forma a otimizar a operação da microrrede, promovendo a melhoria da qualidade de energia através da redução do pico de demanda e na suavização da geração fotovoltaica, evitando flutuações de potência no sistema. Neste trabalho, porém, os autores não abordam a operação de regulação de tensão, sendo um tópico importante com relação a qualidade de energia elétrica.

No contexto de microrredes, de acordo com Bordons *et al.* (2020), a abordagem MPC é uma técnica adequada para o controle de microrredes, visto que esta abordagem resolve um problema de otimização a cada intervalo de tempo buscando minimizar uma determinada função objetivo, permitindo uma operação ótima da microrrede. Além disso, a abordagem MPC permite lidar com os limites operacionais da microrrede, como os limites de capacidade dos sistemas de armazenamento e limites de potência fornecidos pelos RES (*Renewable Energy Source*) e incorpora em sua estrutura modelos de previsão de geração e demanda que são importantes para as tomadas de decisão no controle da microrrede.

Em Malysz *et al.* (2014) é proposto um método para o controle ótimo da operação de um sistema de armazenamento de energia com baterias em uma microrrede conectada na rede elétrica. A metodologia consiste na utilização de programação linear inteira mista para a formulação do problema de otimização. Neste contexto, o problema de otimização leva em consideração o custo de utilização da energia elétrica, o custo de operação da bateria e objetivos relacionados a redução do pico de demanda e suavização da carga. O controle proposto pelos autores consiste em um sistema de gerenciamento de energia adaptativo (A-EMS) que atua em um alto nível de controle sobre um horizonte de predição deslizante. Dessa forma, o A-EMS toma as decisões com relação ao fluxo de potência entre a microrrede e a rede elétrica de forma a atingir benefícios econômicos para os consumidores, melhorar a curva de carga para a concessionária de energia e estender a vida útil do sistema de armazenamento de energia.

Em Parisio *et al.* (2014) é apresentado um estudo da aplicação de controle preditivo baseado em modelo para a otimização de uma microrrede. Os autores abordam o problema de otimização e a estrutura MPC e trazem resultados experimentais obtidos com a aplicação do controle em uma microrrede real localizada em Atenas, Grécia. A microrrede abordada no trabalho é composta por um sistema de armazenamento de energia, um sistema de geração fotovoltaica, quatro unidades de geração distribuída e dois conjuntos de cargas, sendo um de cargas controláveis e outro composto por cargas críticas ou não controláveis. Dessa forma,

utilizando programação linear inteira mista, o controle proposto é capaz de determinar a operação de cada gerador interno na microrrede, o montante de energia armazenada ou descarregada pelo sistema de armazenamento, a quantidade de energia importada ou exportada para a rede principal e a quantidade de cargas que devem ser reduzidas ou cortadas durante a operação da microrrede. Para a previsão de demanda e geração fotovoltaica os autores utilizaram a técnica de Máquina de Vetores de Suporte (do inglês, *Support Vector Machines* – SVM) para a previsão de um dia a frente. Com isso, os autores concluem que a aplicação do controle MPC + MILP é capaz de promover a otimização econômica e a redução de picos de demanda durante a operação da microrrede.

Em Shi *et al.* (2018) é proposta a otimização da operação de um sistema de armazenamento com baterias instalado em um consumidor comercial para promover a redução de picos de demanda e regulação de frequência no sistema. O problema de otimização considera o custo relacionado a degradação da bateria, restrições operacionais e incertezas presentes na previsão de carga do consumidor. De acordo com os autores, a utilização do sistema de armazenamento para promover múltiplos serviços simultaneamente, como *peak shaving* e regulação de frequência, se mostrou economicamente melhor em relação a aplicação de sistemas de armazenamento para a realização de uma única operação no sistema. Para considerar a degradação da bateria no problema de otimização, os autores propõem a utilização de um modelo linear para a degradação da bateria no qual é considerado um custo de degradação constante em uma determinada faixa de operação da bateria. Para a previsão de demanda do consumidor os autores utilizam o modelo de regressão linear múltipla (do inglês, *Multiple Linear Regression* – MLR) o qual se mostrou eficiente e de simples implementação para a previsão de carga do consumidor. Com isso, o algoritmo de controle e otimização proposto pelos autores foi eficiente em promover a redução de pico do consumidor e, simultaneamente, promover a participação do consumidor na realização da regulação de frequência do sistema.

No trabalho de Salamanca (2018) é proposto um algoritmo de controle baseado na estratégia MPC utilizando modelo de otimização MILP para a operação otimizada de uma microrrede com acoplamento CC conectada com a rede elétrica. Neste contexto, o autor considerou os aspectos regulatórios, tarifação de energia elétrica e o intercâmbio de energia entre o consumidor e a concessionária de energia para a formulação do problema de otimização com o objetivo de reduzir a conta de energia do consumidor. Adicionalmente, o custo relacionado à degradação do SAE foi levado em consideração na formulação do problema de otimização. Para os modelos de previsão de carga e geração fotovoltaica

utilizados na estratégia MPC, o autor propõe a utilização de modelos Autorregressivos Integrados de Média Móveis (do inglês, *Autoregressive Integrated Moving Average*) para a previsão de séries temporais. Além disso, o autor propõe a utilização de uma abordagem baseada em restrições probabilísticas, sendo que esta resultou em melhorias no desempenho do algoritmo MPC+MILP. Com isso, o autor destaca que a solução de controle baseada na estratégia MPC+MILP se mostrou eficiente na otimização da operação da microrrede, sendo uma estratégia viável para a implementação de soluções comerciais para o segmento de microrredes.

Com relação à modelagem dos elementos presentes em microrredes, o trabalho de Silva *et al.* (2020) apresenta uma modelagem matemática detalhada de elementos como sistemas de armazenamento com baterias, sistemas de geração solar, cargas controláveis e ilhamentos intencionais para o planejamento ótimo da operação da microrrede um dia a frente. De acordo com o autor, apesar da modelagem detalhada dos elementos presentes na microrrede, os modelos ainda mantiveram a linearidade permitindo a utilização de programação linear inteira mista para a formulação do problema de otimização. Dessa forma, a metodologia proposta para a modelagem detalhada dos recursos distribuídos da microrrede e a consideração de aspectos econômicos e tarifários da energia elétrica podem ser relevantes para operadores de microrredes na busca por uma operação otimizada e econômica.

Com relação ao controle de tensão em sistemas com recursos de geração distribuída, em Bakhshideh Zad *et al.* (2015) é proposto um modelo de otimização para a regulação de tensão em um sistema radial de média tensão. A regulação de tensão é realizada através do controle de potência reativa da geração distribuída presente no sistema de forma a manter a tensão em todas as barras do sistema dentro dos limites pré-definidos. Para a realização da regulação de tensão no sistema, os autores propõem a metodologia de análise de sensibilidade de tensão no sistema na qual é possível obter informações da influência da potência ativa e reativa na magnitude de tensão nas barras do sistema. Dessa forma, a função objetivo do problema consiste em minimizar a potência reativa fornecida pelas unidades de geração distribuídas com o objetivo de manter a tensão nas barras do sistema dentro dos limites estabelecidos. Para a solução do problema de otimização, os autores utilizaram a técnica de Otimização por Enxame de Partículas (do inglês, *Particle Swarm Optimization* – PSO). Com isso, os autores aplicaram a metodologia em um sistema teste composto por um sistema radial de distribuição de 12,6 kV e por quatro unidades de geração distribuída. Dessa forma, com os resultados apresentados, os autores concluem que a metodologia empregada foi capaz de

restaurar a tensão em todas as barras do sistema teste, mantendo a tensão dentro dos limites estabelecidos.

No trabalho de Zhang; Srivastava (2021) é proposta a utilização de um sistema de armazenamento de energia para o controle de tensão em um sistema de distribuição através da injeção de potência reativa pelo SAE. A estratégia de controle proposta é baseada na análise de sensibilidade de tensão no sistema, ou seja, no impacto que a potência ativa e reativa exerce na magnitude de tensão do sistema. Os autores demonstraram que, para o sistema considerado, a potência reativa exerce uma maior influência na magnitude da tensão em relação à potência ativa. Dessa forma, através dos resultados obtidos com a aplicação da metodologia em um sistema com dados reais, o controle do SAE determinou a quantidade de potência reativa que deve ser injetada em cada fase do sistema, reduzindo o desbalanço de tensão, melhorando o perfil de tensão e promovendo a correção do fator de potência no sistema considerado.

A abordagem de controle MPC determina as ações de controle com base na minimização de uma determinada função objetivo e na previsão do comportamento de determinadas variáveis. Dessa forma, para o controle proposto neste trabalho, é necessário a utilização de modelos de previsão para a carga e geração solar presente na microrrede.

Existem diferentes abordagens que podem ser utilizadas na previsão de geração solar e de carga de consumidores. Dentre os modelos encontrados na literatura científica, as redes neurais recorrentes LSTM (*Long-Short Term Memory*) tem se mostrado um modelo muito eficaz para a previsão de geração fotovoltaica e de carga de consumidores. Os trabalhos de Wang, Qi e Liu (2019), Abdel-Nasser e Mahmoud (2017), Lee *et al.* (2018) e Yu *et al.* (2020) mostram a utilização de LSTM baseada em redes neurais recorrentes para a previsão de geração solar. Em todos os trabalhos citados os autores utilizaram índices de performance como o MAPE (*Mean absolute percentage error*), RMSE (*Root mean square error*) e MAE (*Mean absolute error*) para avaliar o desempenho do modelo de previsão e demonstrar o bom desempenho do modelo LSTM para a previsão de geração fotovoltaica. Nos trabalhos de Liu *et al.* (2017), Agrawal, Muchahary e Tripathi (2018), Narayan e Hipel (2017) e Zheng *et al.* (2017) é abordado a utilização de LSTM para a previsão de carga de consumidores. Nos trabalhos citados, os autores utilizaram o mesmo método LSTM porém foi utilizado diferentes curvas de cargas com características diferentes entre os consumidores. Nos trabalhos de Narayan e Hipel (2017) e Agrawal, Muchahary e Tripathi (2018) foi utilizado o modelo LSTM para a previsão de demanda para um grande conjunto de cargas concentradas. Já no trabalho de Zheng *et al.* (2017) a mesma abordagem LSTM é utilizada para a previsão de

carga de um consumidor com característica residencial. Em todos os trabalhos citados, os autores demonstraram o bom desempenho da abordagem LSTM para a previsão do perfil de carga dos consumidores.

Dessa forma, com base na revisão de literatura realizada, em nenhum trabalho foi abordado a realização, de forma simultânea, da redução de pico, suavização da geração e regulação de tensão em uma mesma estratégia de controle. A utilização de modelos PLIM tem se mostrado eficiente e muito utilizado na modelagem e otimização da operação de microrredes. O custo de utilização do sistema de armazenamento de energia é levado em consideração na maioria dos trabalhos, visto que estes sistemas possuem custos elevados de implementação e os modelos de otimização atuam de forma a prolongar a vida útil destes sistemas. Neste contexto, como principais contribuições, a metodologia de otimização proposta neste trabalho oferece um modelo de otimização linear capaz de realizar três modos de operação com a microrrede simultaneamente, sendo a redução de pico, suavização da geração e regulação de tensão. Com isso, a partir de modelos lineares, a solução destes problemas de otimização é de fácil obtenção e baixo tempo de solução, o que contribui para a implementação do controle em tempo real e soluções comerciais de baixo custo, visto que existem uma grande variedade de *solvers* gratuitos para a solução de problemas de otimização lineares.

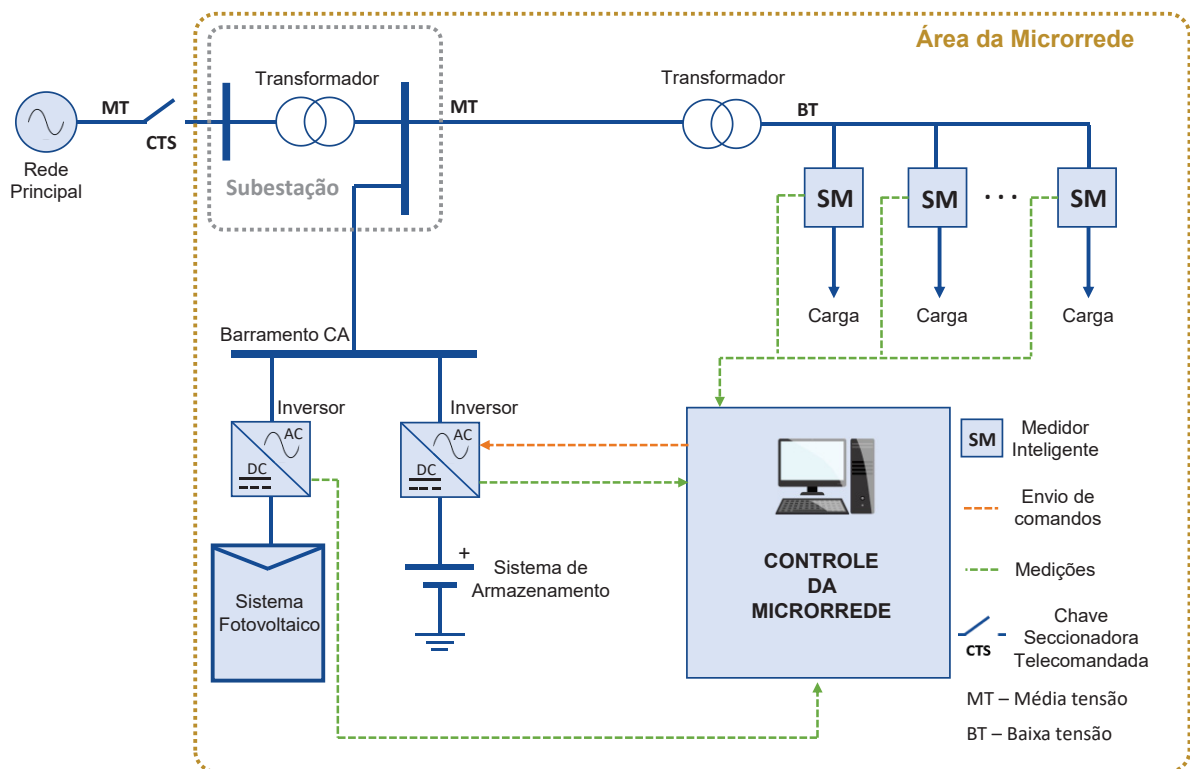
Como limitações deste trabalho, apenas o modo conectado da microrrede é abordado, não sendo considerado a possibilidade de ilhamento da microrrede. O regime transitório não é abordado, sendo considerada apenas a operação em regime permanente. A modelagem dos elementos de armazenamento de energia dentro da estratégia de controle abrange somente a dinâmica do estado de carga do sistema em função da potência de carga ou descarga da bateria, não sendo considerada as influências da temperatura, tensão e corrente da bateria. As eficiências de conversão dos inversores do sistema de armazenamento e do sistema solar foram consideradas estáticas, ou seja, independem da potência na saída dos inversores.

3 METODOLOGIA

3.1 ESTRUTURA DA MICRORREDE

A FIGURA 10 apresenta um esquemático simplificado da estrutura da microrrede considerada neste trabalho. Trata-se de uma microrrede CA composta por um sistema fotovoltaico e um sistema de armazenamento com baterias de íons de lítio conectados na saída da subestação que alimenta uma rede de distribuição de 13,8 kV. As cargas presentes na rede de distribuição não possuem recursos de geração distribuída.

FIGURA 10 - ESTRUTURA DA MICRORREDE CONSIDERADA NESTE TRABALHO



FONTE: O AUTOR (2021)

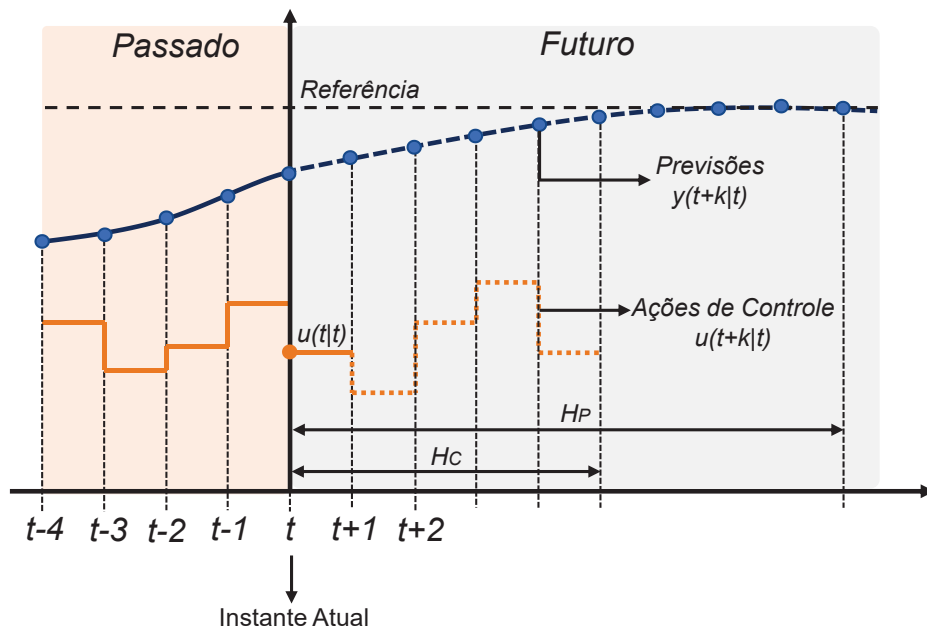
Foi assumido que a microrrede estudada apresenta uma estrutura de comunicação na qual é possível enviar e receber informação com relação à demanda da carga, geração fotovoltaica e informações referentes ao SAE. Apesar de poder operar de forma isolada, foi assumido neste trabalho que a microrrede encontra-se sempre conectada com a rede principal, focando na otimização da operação conectada para melhorias da qualidade da energia no sistema.

3.2 ABORDAGEM MPC

O controle preditivo baseado em modelo refere-se a uma abordagem de controle que determina as ações de comando com base na minimização de uma determinada função objetivo sobre um horizonte de previsão definido. Além disso, a estratégia MPC utiliza a realimentação das variáveis do sistema numa determinada frequência de amostragem, realizando um novo cálculo de otimização para todo horizonte de previsão em cada passo de integração.

Para um melhor esclarecimento, a FIGURA 11 apresenta um esquemático genérico da abordagem MPC no controle de processos.

FIGURA 11 - ESTRATÉGIA DE CONTROLE MPC



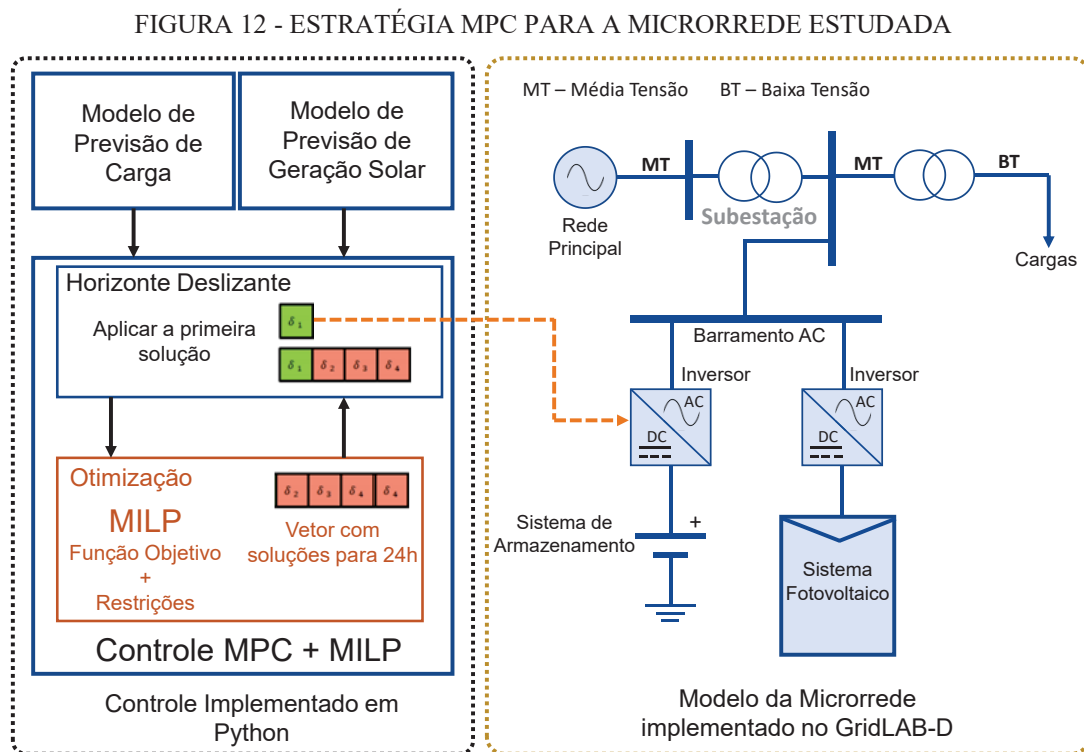
FONTE: O AUTOR (2021)

Com base na FIGURA 11 e na metodologia apresentada no trabalho de Bordons *et al.* (2020), o MPC é baseado nas seguintes estratégias:

1. Inicialmente, no instante atual t , é realizado a previsão do comportamento da variável que está sendo controlada para um horizonte de previsão H_p , ou seja, são calculados $y(t+k|t)$ para $k = 1, \dots, H_p$ com base no valor atual e passados. Neste caso, $y(t+k|t)$ pode ser interpretado como “os valores previstos $y(t+k)$ calculados no instante t .”

2. Com base no valor atual e nos valores previstos da variável controlada, são determinadas as próximas ações de controle $u(t+k|t)$ com base na minimização de uma função objetivo.
3. Com as ações de controle calculadas, é aplicada ou enviada somente a primeira ação de controle $u(t|t)$, ou seja, a ação de controle $u(t)$ calculada em t , para o processo que está sendo controlado. As demais ações de controle calculadas são descartadas.
4. No próximo instante de tempo, $t+1$, os passos 1, 2, 3 são repetidos com base nos novos valores de medição recebidos em $t+1$.

Com base na estratégia do MPC descrita acima, a FIGURA 12 apresenta um esquemático do controle MPC aplicado na microrrede estudada neste trabalho.



FONTE: O AUTOR (2021)

Com base na FIGURA 12, através das previsões do comportamento da carga e da geração fotovoltaica é realizado o processo de otimização que determina um vetor de soluções de carga e descarga do SAE para 24 horas à frente, com intervalos de 10 minutos entre as decisões. Através do conceito de horizonte deslizante, apenas a primeira solução encontrada

pelo processo de otimização é aplicada. Após 10 minutos, são realizadas novas previsões e o processo de otimização determina um vetor com novas soluções.

A função objetivo e o modelo de previsão são dois elementos fundamentais para a implementação da abordagem MPC. Esses dois elementos da estrutura do MPC são abordados com mais detalhes nas seções a seguir.

3.3 MODELOS DE OTIMIZAÇÃO

Nesta seção são apresentadas as formulações para os modelos de otimização para a operação da microrrede. Neste contexto, é inicialmente apresentado a função objetivo para cada operação e na sequência são apresentadas as restrições do problema de otimização.

3.3.1 Operação *Peak Shaving*

A otimização para a operação de *peak shaving* busca a redução do pico de demanda da rede elétrica na qual a microrrede está conectada minimizando o custo de operação da microrrede. Dessa forma, a solução do problema de otimização consiste em determinar as potências de carga e descarga do SAE de forma a reduzir o pico de demanda com o menor custo operacional possível da microrrede.

3.3.1.1 Função Objetivo

Para a formulação da função objetivo foram considerados quatro parcelas que devem ser minimizadas durante a operação da microrrede, conforme a equação (3.1).

$$\begin{aligned} \min \alpha_1 \frac{Parcela_1}{Max(Parcela_1)} + \alpha_2 \frac{Parcela_2}{Max(Parcela_2)} + \\ \alpha_3 \frac{Parcela_3}{Max(Parcela_3)} + \alpha_4 \frac{Parcela_4}{Max(Parcela_4)}. \end{aligned} \quad (3.1)$$

As parcelas da equação (3.1) representam:

- *Parcela 1*: custo da energia da rede elétrica principal;
- *Parcela 2*: custo de utilização do SAE;
- *Parcela 3*: custo adicional caso a demanda da rede principal assuma valores maiores que um determinado limite estabelecido;

- *Parcela 4*: Diferença entre o estado de carga atual do SAE e a referência.

Os denominadores das parcelas que compõem a função objetivo representam os valores máximos que cada parcela pode assumir para tornar a função objetivo normalizada e foram determinados de forma analítica, com base nos valores máximos que cada variável da função objetivo pode assumir no processo de otimização. O parâmetro α em cada representa o peso atribuído a cada parcela da função objetivo. A seguir são descritos e formulados cada uma das parcelas da função objetivo para a operação de *peak shaving*.

Parcela 1 - Custo de energia da rede elétrica principal

Neste trabalho foi considerado que a energia elétrica proveniente da rede elétrica principal conectada na microrrede possui um custo para o operador da microrrede. Dessa forma, foram assumidos custo de energia para o horário de ponta, horários intermediários e fora ponta conforme a TABELA 1. Os valores do custo da energia elétrica utilizados são referentes à tarifa branca para o grupo B1 da COPEL Distribuição.

TABELA 1 - CUSTO DA ENERGIA ELÉTRICA

Tarifa	Horário Início	Horário Fim	Preço (R\$/kWh)
Fora Ponta	00:00	17:00	0,474
Intermediário 1	17:00	18:00	0,656
Ponta	18:00	21:00	1,000
Intermediário 2	21:00	22:00	0,656
Fora Ponta	22:00	00:00	0,474

FONTE: ANEEL (2022)

Com isso, a parcela 1 da função objetivo é calculada conforme a equação (3.2)

$$Parcela_1 = \lambda_E \cdot t_s \sum_{i=1}^T P_i^{Rede} \quad (3.2)$$

onde:

- λ_E : Preço da energia (R\$/kWh);
- t_s : Intervalo de tempo (h);
- P_i^{Rede} : Potência ativa demandada da rede principal pela microrrede no instante i (kW);
- T : Total de instantes de tempo.

Parcela 2 - Custo de Utilização do SAE

Durante a operação do SAE as células de baterias sofrem degradação e, por consequência, perda de vida útil durante os ciclos de carga e descarga. Dessa forma existe um custo relacionado a utilização destes sistemas de armazenamento. No trabalho de Shi *et al.* (2018) os autores mostram uma formulação para a obtenção do custo em R\$/kWh para um sistema de armazenamento de energia com baterias de íons de lítio. De acordo com os autores, o custo relacionado a degradação da bateria é proporcional à quantidade de potência carregada ou descarregada pela bateria multiplicado por um fator chamado coeficiente de custo de degradação da bateria linearizado (λ_b) que pode ser obtido através da equação (3.3).

$$\lambda_b = \frac{\lambda_{cell}}{2N \cdot (SOC_{max} - SOC_{min})}. \quad (3.3)$$

Na equação (3.3), λ_{cell} representa o custo da célula de bateria em R\$/kWh, N representa o número de ciclos que a bateria pode operar durante a vida útil, SOC_{max} e SOC_{min} representam os limites máximos e mínimos do estado de carga da bateria, respectivamente. Os autores comentam que o coeficiente da equação (3.3) se mantém constante para uma profundidade de descarga (*Deep Of Discharge* – DOD) da bateria não muito elevado. Dessa forma, considerando um SOC_{max} de 80% e SOC_{min} de 20%, o coeficiente λ_b se mantém constante durante a operação do SAE.

A TABELA 2 apresenta os valores dos parâmetros da equação (3.3) utilizados neste trabalho.

TABELA 2 - VALORES DOS PARÂMETROS PARA O CÁLCULO DO COEFICIENTE DE CUSTO DE DEGRADAÇÃO DA BATERIA LINEARIZADO

Parâmetro	Valor
λ_{cell}	6.500 R\$/kWh
N	10.000
SOC_{max}	80%
SOC_{min}	20%

FONTE: O AUTOR (2021)

Os valores de N , SOC_{max} e SOC_{min} foram obtidos do trabalho de Shi *et al.* (2018) que representam dados de um sistemas de armazenamento com baterias de íons de lítio. O valor de λ_{cell} foi obtido no trabalho de Daza e Sperandio (2018) onde é mostrado uma expectativa de preços para SAEs de diversas tecnologias. Com isso, o valor de λ_b utilizado neste trabalho é de 0,54 R\$/kWh.

A parcela 2 da função objetivo é calculada conforme a equação (3.4)

$$Parcela_2 = \lambda_b \cdot t_s \sum_{i=1}^T (P_i^{SAE\ dc} + P_i^{SAE\ ch}) \quad (3.4)$$

onde:

- λ_b : coeficiente de custo de degradação da bateria ($R\$/kWh$);
- t_s : Intervalo de tempo (h);
- $P_i^{SAE\ dc}$: Potência descarregada pelo SAE no instante i (kW);
- $P_i^{SAE\ ch}$: Potência carregada pelo SAE no instante i (kW);
- T : Total de instante de tempo.

Parcela 3 – Custo adicional por ultrapassagem da demanda

Para a operação de *peak shaving* é estabelecido um valor de limite máximo de potência ativa que o operador da microrrede deseja demandar da rede principal. Este valor de potência ativa máximo é determinado com base na característica das curvas de carga da rede de distribuição.

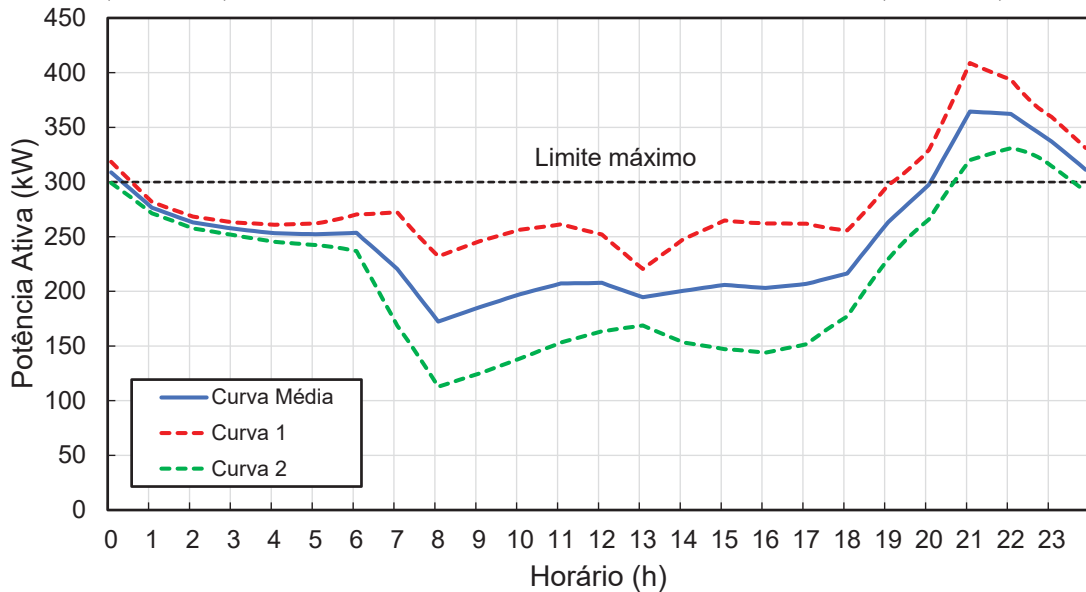
O gráfico da FIGURA 13 apresenta três curvas determinadas com base na média e nos desvios padrões das curvas de cargas de um determinado sistema de distribuição. A curva 1 e a curva 2 foram determinadas conforme as equações (3.5) e (3.6), sendo σ o desvio padrão.

$$Curva\ 1 = Curva\ Média + 3\sigma . \quad (3.5)$$

$$Curva\ 2 = Curva\ Média - 3\sigma . \quad (3.6)$$

Conforme mostrado na FIGURA 13 as curvas de cargas possuem variações na amplitude do pico de demanda de potência ativa. Dessa forma, a curva 1 da FIGURA 13 representa um patamar de carga que pode ser considerado pesado para o sistema de distribuição enquanto a curva 2 representa um patamar leve de carga.

FIGURA 13 - CURVA DE DEMANDA MÉDIA, MÉDIA SOMADA DE TRÊS DESVIOS PADRÕES (CURVA 1) E MÉDIA SUBTRAÍDA DE TRÊS DESVIOS PADRÕES (CURVA 2)



FONTE: O AUTOR (2021)

O limite de potência ativa é incluído no problema de otimização através de um custo adicional na função objetivo, ou seja, se a demanda da rede principal ultrapassar tal limite é aplicado um acréscimo no valor da função objetivo através da parcela 3. Dessa forma, sendo um problema de minimização, o custo adicional incentiva o problema de otimização em buscar a redução do pico de demanda. Com isso, a parcela 3 é formulada conforme a equação (3.7).

$$Parcela_3 = \begin{cases} \text{Custo Adicional (R\$)}, & P_i^{Rede} > \text{Limite máximo} . \\ 0, & P_i^{Rede} \leq \text{Limite máximo} . \end{cases} \quad (3.7)$$

Com base nas curvas de cargas da FIGURA 13, um limite máximo adequado de potência ativa demandada da rede principal pela microrrede a ser escolhido, considerando o tamanho do SAE a ser implementado, é de 300 kW.

Parcela 4 – Regulação do estado de carga do SAE

Para a operação de *peak shaving* é interessante que o SAE mantenha uma alta quantidade de energia armazenada para que seja utilizada no horário de pico. Dessa forma, a parcela 4 da função objetivo é formulada conforme a equação (3.8)

$$Parcela_4 = \sum_{i=1}^T |SOC^{REF} - SOC_i| \quad (3.8)$$

onde:

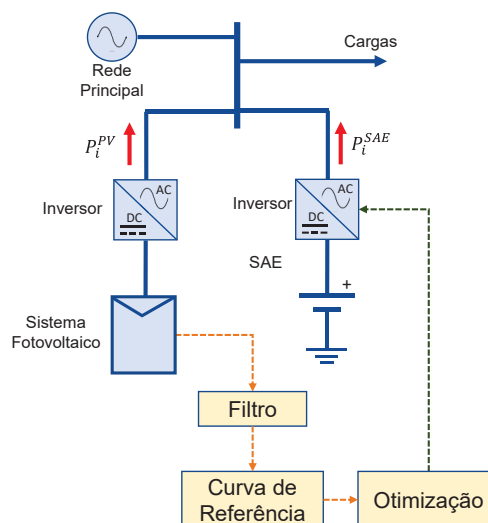
- SOC^{REF} : Estado de carga de referência (%);
- SOC_i : Estado de carga no instante i (%).

Dessa forma, estabelecendo um valor de SOC^{REF} alto, o processo de otimização atua de forma a carregar o SAE antecipadamente para manter a operação do SAE o mais próximo possível do ponto de operação de referência. Com isso, adotando um valor de SOC^{REF} próximo ao valor máximo de estado de carga do sistema de armazenamento, o SAE é carregado até próximo do seu valor limite, mesmo que toda a energia carregada não seja utilizada. Com isso, caso ocorram erros de previsão do pico de demanda, o sistema de armazenamento estará em condição de atender o pico de demanda devido ao excedente de energia carregada no SAE antecipadamente.

3.3.2 Operação Suavização da Geração

A otimização para a suavização da geração busca reduzir as intermitências na geração fotovoltaica causadas por fatores ambientais como a passagem de nuvens e chuvas. Para reduzir as intermitências é utilizado o SAE da microrrede para fornecer ou absorver potência de forma a compensar as variações abruptas de potência na saída da planta solar. A FIGURA 14 apresenta um esquemático simplificado da operação de suavização utilizada neste trabalho.

FIGURA 14 - OPERAÇÃO DE SUAUIZAÇÃO DA GERAÇÃO FOTOVOLTAICA



FONTE: O AUTOR (2021)

Com base na FIGURA 14 o processo de otimização é iniciado aplicando um filtro nos valores previstos de geração solar com o objetivo de diminuir as intermitências presentes na geração. Dessa forma, é gerada uma curva denominada “curva de referência” que representa uma geração fotovoltaica com a diminuição das intermitências. Com isso, o processo de otimização determina quais os níveis de potência de carga e descarga do SAE para que a geração resultante da planta solar seja o mais próximo possível da curva de referência.

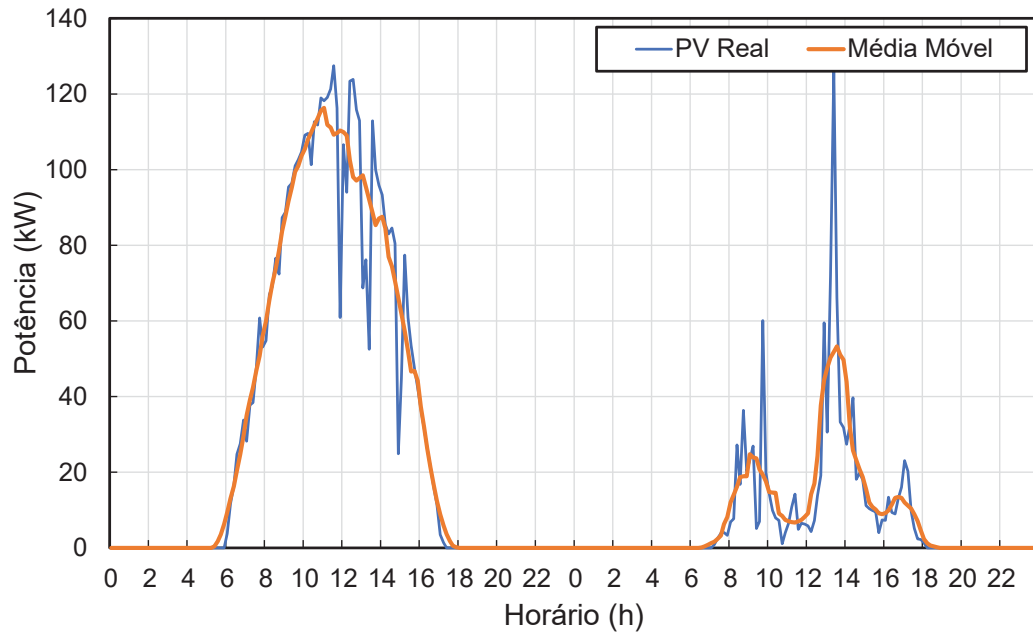
Na sequência são apresentados a metodologia adotada para a criação da curva de referência da planta fotovoltaica, a função objetivo e restrições da otimização da operação de suavização da geração.

Curva de Referência para a planta solar

A curva de referência para a planta solar representa uma curva de geração solar que apresenta as mesmas características de geração da planta, como potência de pico e horário de geração, porém com as intermitências reduzidas. Essa curva tem como objetivo servir de trajetória de referência para que o otimizador determine a carga e descarga do SAE afim de aproximar a curva de geração com a curva de referência. A obtenção da curva de referência pode ser através de filtros que suavizam uma determinada curva, ou seja, anulam as variações abruptas que ocorrem na curva. Neste trabalho é considerado o filtro de média móvel para a criação da curva de referência de geração fotovoltaica. A aplicação da curva de referência na operação de suavização da geração permite a redução das flutuações de potência no sistema elétrico visando melhorias na qualidade da energia. As flutuações de potência causam problemas de operação, fazendo geradores mudarem o ponto de operação para atendimento da demanda de forma mais recorrente, o que prejudica a operação desses geradores no ponto ótimo de eficiência. Assim, a suavização da geração também traz bons resultados para operação do sistema e até mesmo melhorias no perfil de tensão em sistemas de pequeno porte.

A FIGURA 15 apresenta um resultado da aplicação do filtro de média móvel em duas curvas de geração fotovoltaica onde pode ser observada a diminuição das intermitências da geração fotovoltaica.

FIGURA 15 - APLICAÇÃO DA MÉDIA MÓVEL PARA DUAS CURVAS DE GERAÇÃO SOLAR NA PRESENÇA DE INTERMITÊNCIAS



FONTE: O AUTOR (2021)

3.3.2.1 Função objetivo

A função objetivo para a otimização da suavização da geração envolve duas parcelas que devem ser minimizadas conforme a equação (3.9).

$$\min \alpha_1 \frac{Parcela_1}{Max(Parcela_1)} + \alpha_2 \frac{Parcela_2}{Max(Parcela_2)}. \quad (3.9)$$

A parcela 1 da equação (3.9) representa o custo de utilização do SAE para realizar a suavização da geração e é formulada da mesma forma que a parcela 1 da operação de *peak shaving*.

A parcela 2 da equação (3.9) representa a diferença de potência entre a curva de referência da geração solar e a potência resultante da planta solar somado com a potência fornecida ou absorvida pelo SAE. Para melhor entendimento a FIGURA 16 apresenta uma ilustração da parcela 2 para um caso genérico. Dessa forma, o problema de otimização busca os valores de potência do SAE que reduzem a diferença entre a curva de referência e a geração da planta solar com o menor custo operacional do SAE.


A parcela 2 é formulada conforme a equação (3.10)

$$Parcela_2 = \sum_{i=1}^T |PV_i^{ref} - (P_i^{SAE\ dc} - P_i^{SAE\ ch} + P_i^{PV})| \quad (3.10)$$

onde:

- PV_i^{ref} : Curva de referência da planta solar no instante i (kW);
- $P_i^{SAE\ dc}$: Potência descarregada pelo SAE no instante i (kW);
- $P_i^{SAE\ ch}$: Potência carregada pelo SAE no instante i (kW);
- P_i^{PV} : Potência gerada pelo PV no instante i (kW).

FIGURA 16 - DIFERENÇA ENTRE A CURVA DE REFERÊNCIA E A CURVA RESULTANTE PV + SAE



FONTE: O AUTOR (2021)

3.3.3 Operação Regulação de Tensão

A otimização para a regulação de tensão proposta neste trabalho consiste em utilizar o SAE para manter a tensão no ponto de acoplamento comum (PAC) o mais próximo possível da tensão nominal do sistema (1 pu), dentro dos limites de tensão estabelecidos no PRODIST. Para promover a regulação de tensão o SAE pode fornecer ou absorver potência ativa ou reativa a fim de compensar as variações na tensão do PAC.

3.3.3.1 Função objetivo

A Função objetivo do problema de otimização para a regulação de tensão consiste em minimizar a diferença entre a tensão nominal do sistema e a tensão no PAC. A função objetivo é formulada conforme a equação (3.11)

$$\min \text{Desvio de Tensão (pu)} = \sum_{i=1}^T |V_{REF}^{PAC} - V_i^{PAC}(i)| \quad (3.11)$$

onde:

- V_{REF}^{PAC} : Tensão nominal do PAC (pu);
- V_i^{PAC} : Tensão no PAC no instante i (pu);
- T : Total de instantes de tempo.

Na expressão (3.11), V_i^{PAC} representa a magnitude de tensão no PAC, sendo que seu valor pode sofrer variações dependendo do nível de potência ativa ou reativa fornecida pelo SAE, ou seja, dependendo dos ajustes realizados na potência ativa e reativa do SAE, esses ajustes refletem em alterações na magnitude de tensão no PAC.

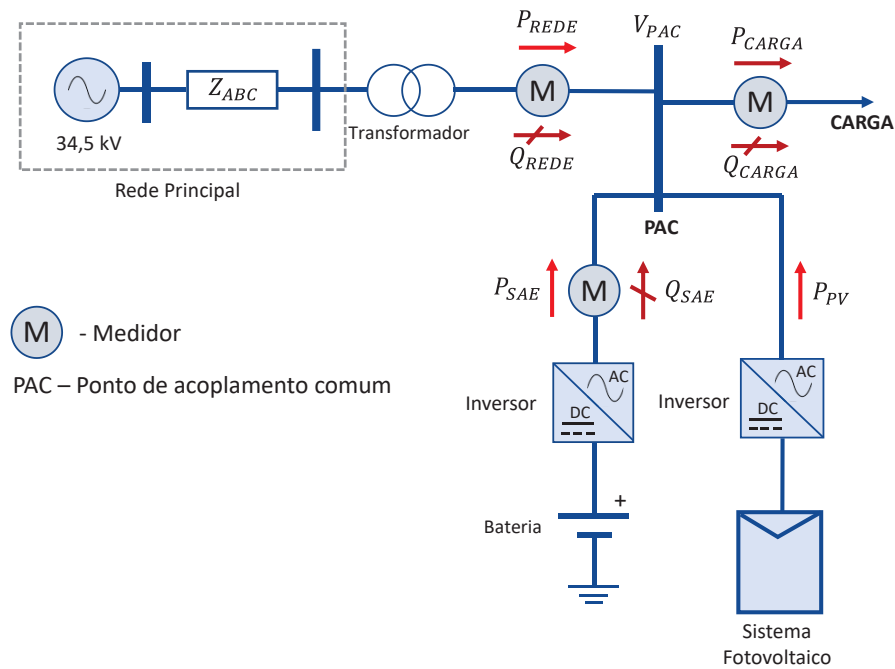
Diferentes sistemas podem apresentar características distintas no comportamento da tensão com relação a potência ativa e reativa. Com isso, para propor uma formulação para a regulação de tensão no sistema é necessário realizar uma análise prévia para compreender a relação entre a compensação ativa e reativa na regulação de tensão.

Na sequência, é apresentada a metodologia empregada para o estudo da compensação ativa e reativa no sistema estudado. As análises realizadas são baseadas na sensibilidade de tensão proposta no trabalho de Zhang; Srivastava (2021).

3.3.3.2 Compensação ativa e reativa

Para o estudo de compensação ativa e reativa foi considerado o sistema mostrado na FIGURA 17 que representa a topologia da microrrede abordada neste trabalho.

FIGURA 17 - ESQUEMÁTICO SIMPLIFICADO DA MICRORREDE



FONTE: O AUTOR (2021)

Na figura acima são representados os principais elementos que constituem a microrrede e as grandezas elétricas envolvidas na análise de compensação ativa e reativa, sendo P_{SAE} e Q_{SAE} a potência ativa e reativa, respectivamente, fornecidas ou absorvidas pelo SAE, P_{REDE} e Q_{REDE} a potência ativa e reativa, respectivamente, fornecidas pela rede principal conectada à microrrede, P_{CARGA} e Q_{CARGA} a potência ativa e reativa, respectivamente, demandadas pela carga da microrrede.

Compensação ativa

A análise da compensação ativa é realizada através da injeção de potência ativa no PAC pelo SAE. Dessa forma, é possível comparar os valores de tensão no PAC antes e depois da atuação do SAE com a injeção de potência ativa no sistema. Com isso, o fator de sensibilidade da tensão no PAC com relação a potência ativa pode ser determinado pela equação (3.12)

$$K_A = \frac{\Delta P_{SAE}}{\Delta V_{PAC}} \quad (3.12)$$

onde:

- K_A : Fator de sensibilidade da tensão com relação a potência ativa (kW/pu);

- ΔP_{SAE} : Variação de potência ativa do SAE (kW);
- ΔV_{PAC} : Variação de tensão no PAC (pu).

Dessa forma, com o cálculo do fator de sensibilidade, é possível realizar a análise da variação da magnitude de tensão no PAC com relação a potência ativa injetada no sistema pelo SAE.

Compensação Reativa

A análise da compensação reativa é realizada de forma semelhante a compensação ativa, porém, neste caso, o SAE é programado para injetar potência reativa no sistema. O fator de sensibilidade do PAC com relação a potência reativa pode ser calculado através da equação (3.13)

$$K_R = \frac{\Delta Q_{SAE}}{\Delta V_{PAC}} \quad (3.13)$$

onde:

- K_R : Fator de sensibilidade da tensão com relação a potência reativa ($kvar/pu$);
- ΔQ_{SAE} : Variação de potência reativa do SAE ($kvar$);
- ΔV_{PAC} : Variação de tensão no PAC (pu).

Dessa forma, com o cálculo do fator de sensibilidade, é possível realizar a análise da variação da magnitude de tensão no PAC com relação a potência reativa injetada no sistema pelo SAE.

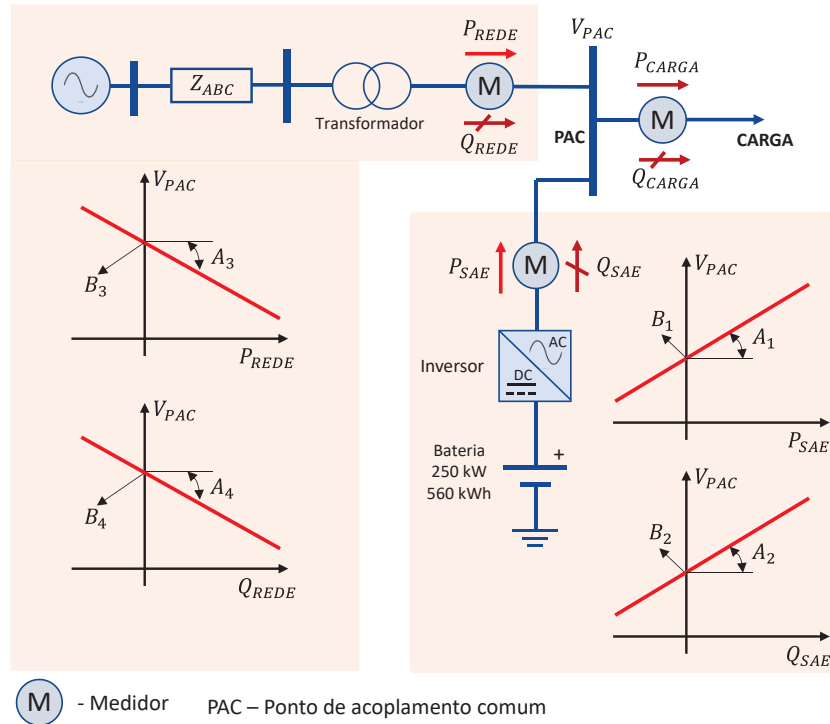
Com isso, dependendo dos valores obtidos de K_A e K_R para o sistema estudado, é possível determinar se as variações na magnitude de tensão no PAC são mais sensíveis em relação a potência ativa ou reativa injetada pelo SAE. Essa relação de sensibilidade é importante para a determinação da estratégia de controle que será adotada para promover a regulação de tensão no sistema. Os valores de K_A e K_R são calculados na seção 4.1.2.7, onde é abordado o estudo de caso.

Regulação de tensão através da relação de *droop* ativo e reativo

A relação entre a potência ativa ou reativa injetada ou absorvida pelo SAE com a tensão no PAC pode ser estabelecida através de uma curva de *droop* ativo ou reativo. Essa relação de *droop* é necessária para a formulação do problema de otimização visto que o

processo de otimização irá determinar o nível de potência ativa ou reativa que o SAE deve fornecer para promover a regulação de tensão no PAC. A FIGURA 18 apresenta, de forma hipotética, as curvas da relação de *droop* ativo e reativo para a microrrede abordada neste trabalho.

FIGURA 18 - RELAÇÕES DE *DROOP* CONSIDERANDO A POTÊNCIA ATIVA E REATIVA DA REDE PRINCIPAL, A POTÊNCIA ATIVA E REATIVA DO SAE E A TENSÃO NO PAC



FONTE: O AUTOR (2021)

As curvas de *droop* ativo e reativo apresentam um comportamento linear, sendo possível obter uma relação entre a potência ativa e a magnitude de tensão no PAC ou a relação entre a potência reativa e a magnitude de tensão no PAC.

As equações do *droop* ativo e reativo para as curvas apresentadas na FIGURA 18 podem ser representadas através de equações de reta da seguinte forma:

$$V_{PAC}(P_{SAE}) = A_1 \cdot P_{SAE} + B_1 \quad (3.14)$$

$$V_{PAC}(Q_{SAE}) = A_2 \cdot Q_{SAE} + B_2 \quad (3.15)$$

$$V_{PAC}(P_{REDE}) = A_3 \cdot P_{REDE} + B_3 \quad (3.16)$$

$$V_{PAC}(Q_{REDE}) = A_4 \cdot Q_{REDE} + B_4 \quad (3.17)$$

onde V_{PAC} é a tensão do PAC, A_1 , A_2 , A_3 e A_4 são os coeficientes angulares das retas, P_{SAE} é a potência ativa fornecida pelo SAE, Q_{SAE} é a potência reativa fornecida pelo SAE, P_{REDE} e Q_{REDE} são a potência ativa e reativa fornecidas pela rede principal, e B_1 , B_2 , B_3 e B_4 são os coeficiente lineares das retas. Os valores dos coeficientes angulares e lineares de cada uma das retas dependem da relação de sensibilidade da tensão no PAC em relação a potência ativa e reativa.

Para a implementação do controle proposto neste trabalho é necessário relacionar a V_{PAC} com a potência ativa e reativa do SAE e com a potência ativa e reativa da carga. Essa relação se faz necessária visto que a potência do SAE é a variável de controle e a potência da carga é a variável prevista no controle MPC proposto neste trabalho. Considerando a FIGURA 18, podem ser estabelecidas as seguintes relações entre as potências ativas e reativas da rede, SAE e carga:

$$P_{REDE} = P_{CARGA} - P_{SAE}. \quad (3.18)$$

$$Q_{REDE} = Q_{CARGA} - Q_{SAE}. \quad (3.19)$$

Com isso, substituindo a equação (3.18) na equação (3.16) é possível obter a seguinte relação:

$$V_{PAC} = A_3 \cdot (P_{CARGA} - P_{SAE}) + B_3. \quad (3.20)$$

Da mesma forma, substituindo a equação (3.19) na equação (3.17) é possível obter a seguinte relação:

$$V_{PAC} = A_4 \cdot (Q_{CARGA} - Q_{SAE}) + B_4. \quad (3.21)$$

Com isso, as equações (3.20) e (3.21) estabelecem a relação entre a variável controlada (V_{PAC}) com a variáveis de controle (P_{SAE} ou Q_{SAE}) e com as variáveis que podem ser previstas no sistema (P_{CARGA} e Q_{CARGA}).

Dependendo das características do sistema, a potência reativa pode exercer uma influência maior ou menor na magnitude de tensão. Caso a potência reativa exerça uma

influência muito maior na tensão do sistema do que a potência ativa, apenas a equação (3.21) pode ser considerada na estratégia de controle. Caso contrário, pode ser considerada apenas a equação (3.20) na estratégia de controle. As análises para determinar qual das equações, (3.20 ou 3.21), será utilizada na estratégia de controle proposta neste trabalho são apresentadas na seção 4.1.2.7, onde é abordado o estudo de caso.

3.3.4 Operação Híbrida: *Peak Shaving* + Suavização da Geração + Regulação de Tensão

A operação conjunta proposta neste trabalho consiste em um modo de operação da microrrede em que o problema de otimização considera todas as operações anteriores em uma mesma função objetivo, ou seja, o controlador determina as ações de controle com o propósito de promover o *peak shaving*, a suavização da geração e regulação de tensão durante a operação da microrrede. Este modo híbrido de operação se mostra interessante pois permite a combinação das vantagens de todas as operações anteriores em um único problema de otimização.

3.3.4.1 Função Objetivo

A função objetivo para a operação combinada consiste na soma das parcelas que compõem cada uma das operações vistas anteriormente. Com isso, a função objetivo é formulada conforme a expressão (3.22).

$$\begin{aligned} \min \quad & \alpha_1 \frac{\text{Parcela}_1}{\text{Max}(\text{Parcela}_1)} + \alpha_2 \frac{\text{Parcela}_2}{\text{Max}(\text{Parcela}_2)} + \alpha_3 \frac{\text{Parcela}_3}{\text{Max}(\text{Parcela}_3)} \\ & + \alpha_4 \frac{\text{Parcela}_4}{\text{Max}(\text{Parcela}_4)} + \alpha_5 \frac{\text{Parcela}_5}{\text{Max}(\text{Parcela}_5)} + \alpha_6 \frac{\text{Parcela}_6}{\text{Max}(\text{Parcela}_6)}. \end{aligned} \quad (3.22)$$

$\underbrace{\hspace{10em}}_{\text{Energia da Rede Principal}}$
 $\underbrace{\hspace{10em}}_{\text{SAE}}$
 $\underbrace{\hspace{10em}}_{\text{Peak Shaving}}$
 $\underbrace{\hspace{10em}}_{\text{SOC}}$
 $\underbrace{\hspace{10em}}_{\text{Suavização da geração}}$
 $\underbrace{\hspace{10em}}_{\text{Regulação de Tensão}}$

Conforme a expressão acima, a função objetivo para a operação combinada é composta de seis parcelas. Essas parcelas representam cada uma das operações (*Peak Shaving*, Suavização da Geração e Regulação de Tensão) e os custos de energia da rede principal e de utilização do SAE. Como cada operações possui características distintas, podem ocorrer grandes diferenças entre os valores numéricos de cada parcela na função objetivo. Dessa forma, para tornar o processo de otimização mais adequado e fazer com que os valores

de cada parcela sejam semelhantes, foi realizado o processo de normalização da função objetivo dividindo cada parcela pelo seu respectivo valor máximo. Os valores de α na função objetivo representam o peso de cada parcela na função objetivo. Dessa forma, levando em consideração as funções objetivo de cada operação vistas anteriormente, a função objetivo da operação combinada pode ser formulada conforme a expressão.

$$\begin{aligned}
\min \quad & \sum_{i=1}^T \alpha_1 \frac{P_i^{Rede} \lambda_E t_s}{\text{Max}(\text{Parcela}_1)} + \\
& \underbrace{\text{Custo da Energia Elétrica da Rede Principal}} \\
& \sum_{i=1}^T \alpha_2 \frac{(P_i^{SAE\ dc} + P_i^{SAE\ ch}) \lambda_E t_s}{\text{Max}(\text{Parcela}_2)} + \\
& \underbrace{\text{Custo relacionado a utilização do SAE}} \\
& \sum_{i=1}^T \alpha_3 \frac{\text{Penalização}}{\text{Max}(\text{Parcela}_3)} + \\
& \underbrace{\text{Custo caso não ocorra o Peak Shaving}} \\
& \sum_{i=1}^T \alpha_4 \frac{|SOC^{Ref} - SOC_i|}{\text{Max}(\text{Parcela}_4)} + \\
& \underbrace{\text{Manter o estado de carga próximo a referência}} \\
& \sum_{i=1}^T \alpha_5 \frac{|PV_i^{ref} - (P_i^{SAE\ dc} - P_i^{SAE\ ch} + P_i^{PV})|}{\text{Max}(\text{Parcela}_5)} + \\
& \underbrace{\text{Suavização da Geração Fotovoltaica}} \\
& \sum_{i=1}^T \alpha_6 \frac{|V_{PCC}^{Ref} - V_i^{PCC}|}{\text{Max}(\text{Parcela}_6)}. \\
& \underbrace{\text{Diminuir a diferença entre a tensão no PCC e a referência}}
\end{aligned} \tag{3.23}$$


3.3.5 Restrições

Nesta subseção são apresentadas as restrições aplicadas aos problemas de otimização para a operação da microrrede.

Balanco de Potência Ativa e Reativa

O balanço de potência corresponde ao equilíbrio entre as potências geradas e consumidas no interior da microrrede e as potências fornecidas ou absorvidas pela rede principal na qual a microrrede está conectada. A FIGURA 19 apresenta as variáveis relacionadas as potências ativas e reativas que são utilizadas para a formulação do balanço de potência na microrrede.

FIGURA 19 - BALANÇO DE POTÊNCIA NA MICRORREDE



FONTE: O AUTOR (2021)

Dessa forma, o balanço de potência ativa e reativa são formulados conforme as equações (3.24) e (3.25). A variável P_i^{Carga} representa a potência ativa demandada pela carga juntamente com as perdas elétricas do sistema de distribuição de energia.

$$P_i^{Rede} + P_i^{SAE\ dc} + P_i^{PV} = P_i^{SAE\ ch} + P_i^{Carga} \quad (3.24)$$

$$Q_i^{Rede} + Q_i^{SAE} = Q_i^{Carga} \quad (3.25)$$

onde:

- P_i^{Rede} : Potência da rede principal no instante i (kW);
- $P_i^{SAE\ dc}$: Potência descarregada pelo SAE no instante i (kW);
- P_i^{PV} : Potência gerada pelo PV no instante i (kW);
- $P_i^{SAE\ ch}$: Potência carregada pelo SAE no instante i (kW);
- P_i^{Carga} : Potência demandada pela carga e perdas no instante i (kW);
- Q_i^{Rede} : Potência reativa na rede principal no instante i (kvar);
- Q_i^{SAE} : Potência reativa do SAE no instante i (kvar);
- Q_i^{Carga} : Potência ativa da carga no instante i (kvar).

Decisão de carga e descarga e limites de potência do SAE

O SAE deve fornecer potência ativa e reativa para o sistema respeitando os limites operacionais estabelecidos pelos fabricantes. Dessa maneira, o algoritmo de controle não deve solicitar uma potência ativa ou reativa maior que os valores estabelecidos para o equipamento. Da mesma forma, o algoritmo de controle não pode solicitar que o SAE seja carregado e descarregado ao mesmo tempo, pois infringiria um limite físico do equipamento. Essas condições são inseridas nos problemas de otimização através das expressões (3.26), (3.27), (3.28) e (3.29)

$$P_i^{SAE\ ch} \leq \delta_i^{SAE\ ch} \cdot P_{max} \quad (3.26)$$

$$P_i^{SAE\ dc} \leq \delta_i^{SAE\ dc} \cdot P_{max} \quad (3.27)$$

$$Q_{MIN}^{SAE} \leq Q_i^{SAE} \leq Q_{MAX}^{SAE} \quad (3.28)$$

$$\delta_i^{SAE\ ch} + \delta_i^{SAE\ dc} \leq 1 \quad (3.29)$$

onde

- $P_i^{SAE\ ch}$: Potência carregada pelo SAE no instante i (kW);
- $P_i^{SAE\ dc}$: Potência descarregada pelo SAE no instante i (kW);
- P_{max} : Potência ativa máxima que pode ser fornecida ou absorvida pelo SAE (kW);
- Q_i^{SAE} : Potência Reativa do SAE no instante i ($kvar$);
- Q_{MAX}^{SAE} : Potência Reativa máxima do SAE ($kvar$);
- Q_{MIN}^{SAE} : Potência Reativa mínima do SAE ($kvar$);
- $\delta_i^{SAE\ ch}$: Variável binária de decisão de carga do SAE no instante i ;
- $\delta_i^{SAE\ dc}$: Variável binária de decisão de descarga do SAE no instante i .

Nas restrições acima são utilizadas duas variáveis binárias ($\delta_i^{SAE\ ch}$ e $\delta_i^{SAE\ dc}$) para controlar a carga e descarga do SAE, de forma que $\delta_i^{SAE\ ch} = 1$ corresponde ao carregamento do SAE e $\delta_i^{SAE\ dc} = 1$ corresponde a descarga do SAE. Com isso, pela restrição (3.29), as duas variáveis binárias nunca podem assumir o mesmo valor de 1, ou seja, não ocorre a carga e descarga do SAE simultaneamente no problema de otimização.

Estado de carga do SAE

O estado de carga (SOC) corresponde a porcentagem de energia disponível no SAE podendo. Dessa forma, o SOC deve ser restringido em um valor máximo e mínimo no problema de otimização de forma a atender os limites de energia disponível no SAE. Além dos limites operacionais, o SOC sofre variações em função da quantidade de energia carregada ou descarregada em um intervalo de tempo. Para abranger os limites operacionais e a dinâmica do SAE com relação ao SOC são inseridas as seguintes restrições:

$$SOC_i = SOC_{i-1} - \frac{1}{\eta_{SAE}} \frac{P_{i-1}^{SAE\ dc}}{E} t_s + \eta_{SAE} \frac{P_{i-1}^{SAE\ ch}}{E} t_s \quad (3.30)$$

$$SOC_{min} \leq SOC_i \leq SOC_{max} \quad (3.31)$$

onde:

- SOC_i : Estado de carga do SAE no instante i (pu);
- SOC_{i-1} : Estado de carga no instante anterior (pu);
- $P_{i-1}^{SAE\ dc}$: Potência descarregada pelo SAE no instante anterior (kW);
- $P_{i-1}^{SAE\ ch}$: Potência carregada pelo SAE no instante anterior (kW);
- E : Capacidade total do SAE (kWh);
- t_s : Intervalo de tempo (h);
- η_{SAE} : Rendimento do SAE;
- SOC_{min} : Estado de carga mínimo do SAE (pu);
- SOC_{max} : estado de carga máximo do SAE (pu).

Relação da tensão no PAC com a potência reativa do SAE

A relação entre a tensão no PAC e a potência reativa fornecida pelo SAE para a microrrede considerada neste trabalho foi estabelecida através das análises realizadas na seção 4.1.2.7. A relação entre a tensão no PAC e a potência reativa fornecida pelo SAE é inserida no problema de otimização através da seguinte restrição de igualdade

$$V_i^{PAC} = A. (Q_i^{Carga} - Q_i^{SAE}) + C \quad (3.32)$$

onde:

- V_i^{PAC} : Tensão no PAC no instante i (pu);

- Q_i^{Carga} : Potência reativa demandada pela carga no instante i ($kvar$);
- Q_i^{SAE} : Potência reativa do SAE no instante i ($kvar$);
- A : Coeficiente angular da curva de *droop* reativo no PAC ($pu/kvar$);
- C : Coeficiente linear da curva de *droop* reativo no PAC (pu).

A restrição (3.32) é necessária no problema de otimização pois estabelece a relação entre a variável que vai ser controlada (V_i^{PCC}) e a variável de controle (Q_i^{SAE}), ou seja, o problema de otimização determina os melhores valores de Q_i^{SAE} a fim de tornar os valores de V_i^{PCC} mais próximos da tensão nominal do sistema. Na restrição (3.32), K_R e C são constantes cujos valores dependem da relação de *droop* reativo do sistema que está sendo considerado no estudo.

Limites operacionais do SAE

O SAE pode tanto fornecer potência ativa quanto reativa para o sistema. A relação entre a potência ativa, reativa e aparente do SAE é dada pela seguinte equação

$$S_i^{SAE} = \sqrt{(P_i^{SAE})^2 + (Q_i^{SAE})^2} \quad (3.33)$$

onde S_i^{SAE} é a potência aparente do inversor do SAE, P_i^{SAE} e Q_i^{SAE} são a potência ativa e reativa do SAE, respectivamente. A equação (3.33) não pode ser utilizada diretamente no problema de otimização MILP por se tratar de uma equação não linear. Para inserir a equação (3.33) no problema de otimização MILP foi utilizado um processo de linearização proposto no trabalho de Moreno *et al.* (2015). Segundo os autores, a equação (3.33) pode ser linearizada através de um conjunto de restrições lineares que podem ser inseridas em problemas de otimização MILP. Dessa forma, segundo Moreno *et al.* (2015), a equação (3.33) pode ser representada pelo seguinte conjunto de restrições

$$-\frac{-\alpha \cdot P_i^{SAE} + S^2}{\sqrt{S^2 - \alpha^2}} \leq Q_i^{SAE} \leq \frac{-\alpha \cdot P_i^{SAE} + S^2}{\sqrt{S^2 - \alpha^2}} \quad \forall \alpha \in A \quad (3.34)$$

onde S é um valor constante e igual ao valor máximo da potência aparente do SAE em pu , A é uma discretização do intervalo entre $-S$ e S , sendo α valores discretizados no intervalo entre $-S$ e S (por exemplo, $\alpha = \{0,90 \ 0,80 \dots -0,80 \ -0,90\}$), formando assim, um subespaço

linear que atende a curva de capacidade do inversor, de forma que as equações geradas pelas restrições sejam lineares.

3.4 MODELOS DE PREVISÃO

As decisões de controle para a operação ótima de uma microrrede devem ser tomadas conforme o comportamento futuro de determinadas variáveis que constituem a microrrede. Dessa forma, para a microrrede considerada neste trabalho, as decisões de controle devem ser tomadas conforme o comportamento da demanda da carga e da geração solar disponível durante a operação. Como as decisões de controle são calculadas para um horizonte de tempo futuro, o comportamento da carga e da geração fotovoltaica devem ser previstos utilizando algum modelo de previsão adequado para o problema.

3.4.1 Previsão de Carga e Geração Fotovoltaica

O modelo de previsão de carga e geração solar utilizados neste trabalho foram implementados utilizando modelos LSTM baseado em redes neurais recorrentes para a previsão de múltiplos passos à frente. Os modelos de previsão de carga e de geração solar foram implementados em algoritmos diferentes resultando em três modelos de previsão, sendo um para potência ativa da carga, um para potência reativa da carga e outro para a geração fotovoltaica. Dessa forma, os modelos de previsão foram implementados utilizando históricos de dados de potência ativa, reativa e de geração fotovoltaica fornecidos pela COPEL Distribuição. Para cada modelo de previsão, os dados históricos são tratados e divididos em conjunto de treino, validação e teste para a implementação das redes neurais LSTM. Através do conjunto de dados de teste foi possível avaliar o desempenho de cada modelo de previsão. Neste trabalho são considerados dois índices de validação para os modelos de previsão, sendo a Raiz Quadrada da Média do Erro Quadrático (RMSE) e o Coeficiente de Determinação R^2 . O cálculo do RMSE é dado pela equação (3.35).

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (y(k) - \hat{y}(k))^2}. \quad (3.35)$$

Na equação (3.35), N representa o número total de dados do conjunto de teste, $y(k)$ representa o valor real da medição no instante k , $\hat{y}(k)$ é a previsão no instante k . O Coeficiente de determinação R^2 é uma medida que varia entre 0 e 1 e pode ser utilizado para indicar o quão bem o modelo de previsão se ajustou aos dados durante o teste da rede neural LSTM, ou seja, quanto mais próximo de 1 melhor é a previsão feita pelo modelo. O Coeficiente de determinação R^2 pode ser determinado pela equação (3.36).

$$R^2 = \frac{\sum_{k=1}^N (\hat{y}(k) - \bar{y})^2}{\sum_{k=1}^N (y(k) - \bar{y})^2}. \quad (3.36)$$

Na equação (3.36), N representa o número total de dados do conjunto de teste, $\hat{y}(k)$ é a previsão no instante k , $y(k)$ representa o valor real da medição no instante k e \bar{y} representa a média dos valores do conjunto de teste.

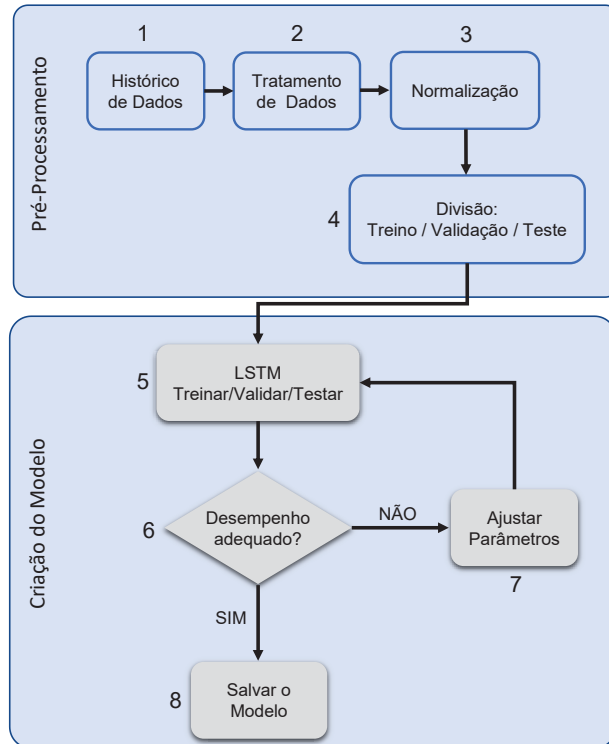
Para a estrutura de controle proposta neste trabalho deve ser previsto o comportamento da potência ativa e reativa demandada pela carga e o perfil de geração fotovoltaica para um horizonte de 24 horas a frente.

Neste trabalho, os modelos de previsão são implementados em linguagem *Python* versão 3.6.8, com o auxílio da biblioteca *Keras*, que se trata de uma biblioteca destinada para trabalhar com *Machine Learning* e é executada na plataforma *TensorFlow*. Para o treinamento da rede LSTM para a previsão de demanda da carga e geração fotovoltaica foi utilizado o otimizador *Adam* buscando a minimização do erro quadrático médio durante o treinamento e validação da rede LSTM.

A FIGURA 20 apresenta um fluxograma para esquematizar as etapas de implementação dos modelos de previsão LSTM. Conforme ilustrado na figura, os modelos de previsão são implementados em duas etapas, sendo o pré-processamento e a criação do modelo. Na etapa de pré-processamento é realizado o tratamento dos dados históricos que serão utilizados para a criação do modelo de previsão. Nessa etapa são tratados os intervalos de medição em que não ocorreram a medição por motivo de falha no equipamento de medição e são identificados possíveis *outliers*, ou seja, dados que possuem uma grande discrepância na série temporal. Na sequência do pré-processamento, os dados são normalizados em valores entre 0 e 1 para que possam ser utilizados de forma adequada com as funções de ativação da rede LSTM. No passo 4 é realizada a divisão do histórico de dados entre treino, validação. A escolha da porcentagem do histórico para treino, validação e teste foi feita com base em

tentativa e erro, observando a melhoria nos índices de desempenho do modelo LSTM para cada modelo de previsão.

FIGURA 20 - FLUXOGRAMA PARA A IMPLEMENTAÇÃO DOS MODELOS DE PREVISÃO



FONTE: O AUTOR (2021)

As estruturas dos modelos LSTM para a previsão de potência ativa, reativa e geração fotovoltaica e os índices de validação dos modelos de previsão são abordados na seção 4.1.2.9, na qual é abordado o estudo de caso deste trabalho.

4 CASO ESTUDADO

4.1 MODELAGEM DO SISTEMA DE FAXINAL DO CÉU

Nesta seção é apresentado o sistema de distribuição de energia de Faxinal do Céu – PR onde a microrrede será implementada e a modelagem deste sistema de distribuição no software *GridLAB-D*.


4.1.1 Rede de Distribuição de Faxinal do Céu

A rede de distribuição de Faxinal do Céu é composta por dois alimentadores, sendo Vila Santa Maria e Piquiri, de 13,8 kV que se originam na subestação. A subestação é composta de um transformador de 5,7 MVA com tensão no primário de 34,5 kV e tensão no secundário de 13,8 kV. Ao todo, os dois alimentadores possuem um total de 89 transformadores de distribuição, sendo 42 localizados na Vila Santa Maria e 47 no Piquiri, e um total de 510 unidades consumidoras. A FIGURA 21 ilustra a topografia do sistema de distribuição de Faxinal do Céu destacando os segmentos de linha, a distribuição dos transformadores e os agrupamentos de unidades consumidoras ao longo dos dois alimentadores.

4.1.2 Modelagem do Sistema no *GridLAB-D*

O *GridLAB-D* permite a modelagem de vários elementos presentes em sistemas de distribuição, como transformadores, linhas, cargas, capacitores, reguladores, chaves, além de elementos como painéis solares e sistemas de armazenamento de energia. Para a rede de Faxinal do Céu da FIGURA 21 foram modelados no *GridLAB-D* os segmentos de linhas de média tensão (13,8 kV), os transformadores de distribuição e da subestação e as cargas. Os parâmetros elétricos de cada elemento presente na rede de Faxinal do Céu (segmentos de linha, transformadores, cargas) foram obtidos através da Base de Dados Geográfica da Distribuidora – BDGD.

FIGURA 21 - REDE DE DISTRIBUIÇÃO DE FAXINAL DO CÉU - PR



FONTE: O AUTOR (2021)

4.1.2.1 Segmentos de Linha

A modelagem dos segmentos de linha no *GridLAB-D* é feita através dos parâmetros dos cabos como resistência, GMR, diâmetro, comprimento e espaçamento entre os condutores. Dessa forma, conforme o tipo construtivo e do diâmetro do cabo, fornecidos pelo BDGD, é possível determinar a resistência elétrica e o GMR conforme a tabela fornecida por Kersting (2001) para cada segmento de linha do sistema de Faxinal do Céu. A

TABELA 3 mostra os tipos de cabos utilizados na rede de Faxinal do Céu e os parâmetros utilizados na modelagem com o *GridLAB-D*.

TABELA 3 - CABOS UTILIZADOS NA MODELAGEM DA REDE


Cabo	Diâmetro (pol)	GMR(pés)	Resistência (Ω /mil)
2/0 Alumínio	0,414	0,0125	0,769
2 Alumínio	0,292	0,00883	1,541
4 ACSR	0,25	0,00437	2,57
4 Alumínio	0,232	0,007	2,453

FONTE: KERSTING (2001)

O espaçamento entre os condutores também deve ser fornecido na modelagem com o *GridLAB-D* para que a reatância indutiva dos segmentos de linha seja considerada na modelagem do sistema. Na rede de distribuição de Faxinal do Céu existem dois tipos de

configuração de poste, ou seja, o espaçamento entre os condutores das fases na média tensão depende do tipo de estrutura do poste. Na FIGURA 22 é apresentado as estruturas dos postes que foram considerados na modelagem da rede de distribuição no *GridLAB-D* com os respectivos espaçamentos entre os condutores de fase da média tensão.

FIGURA 22 - ESTRUTURAS DOS POSTES UTILIZADOS NA MODELAGEM DA REDE DE DISTRIBUIÇÃO NO *GRIDLAB-D*



FONTE: O AUTOR (2021)

Conforme ilustra a FIGURA 22 existem dois tipos de estruturas de poste que foram considerados na modelagem da rede de distribuição, sendo a estrutura 1 composta pelas fases A, B e C e a estrutura 2 composta por apenas as fases A e C. O alimentador de Vila Santa Maria apresenta somente a estrutura 1 na composição da rede de distribuição, enquanto o alimentador de Piquiri é composto em sua maioria pela estrutura 2.

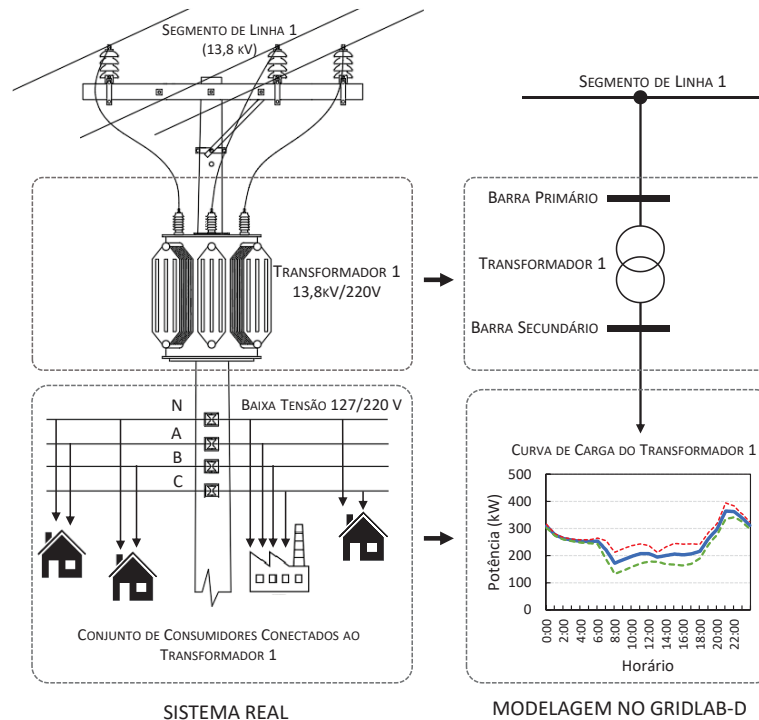
4.1.2.2 Transformadores

Os parâmetros básicos para modelar um transformador no *GridLAB-D* é o tipo de conexão entre primário e secundário, relação de transformação, e os valores de impedância. O tipo de conexão e a relação de transformação dos transformadores de faxinal do Céu foram obtidas com o BDGD.

4.1.2.3 Cargas

A rede de distribuição abordada neste trabalho é composta por 510 unidades consumidoras, sendo que cada unidade possui um perfil de carga que depende do comportamento e hábitos de cada tipo de consumidor (residencial, comercial ou industrial). Por motivos de falta de dados de consumo diário de cada consumidor as cargas foram agrupadas com relação ao transformador que atende estas cargas, ou seja, para cada transformador da rede de distribuição existe um agrupamento de carga associado. A FIGURA 23 ilustra a modelagem no *GridLAB-D* de um determinado conjunto de cargas associado a um determinado transformador da rede de distribuição.

FIGURA 23 - EXEMPLO DA MODELAGEM DE UM CONJUNTO DE CARGAS UTILIZADO NO *GRIDLAB-D*



FONTE: O AUTOR (2021)

Conforme ilustrado na FIGURA 23, os segmentos de linha da baixa tensão não foram considerados na modelagem do sistema de distribuição por motivos de simplificação. As cargas agrupadas foram modeladas através de uma curva de carga diária de potência ativa e reativa. Dessa forma, existe uma curva de carga associada ao secundário de cada transformador da rede de distribuição.

Para a criação de cada curva de carga associada aos transformadores foi adotado o procedimento descrito abaixo e ilustrado pela FIGURA 24.

1. Obter a curva de carga (potência ativa e reativa) na saída da subestação para os dois alimentadores de distribuição;
2. Através do BDGD, obter a soma da potência instalada das cargas conectadas ao respectivo transformador e a soma total da carga instalada nos alimentadores;
3. Obter a porcentagem de potência instalada de cada grupo de carga com relação a potência total instalada nos alimentadores, conforme a equação (4.1), onde S_{Trafo}^j representa a porcentagem da potência total associada ao transformador j e S_{Carga}^j representa a potência instalada total no secundário do transformador j .

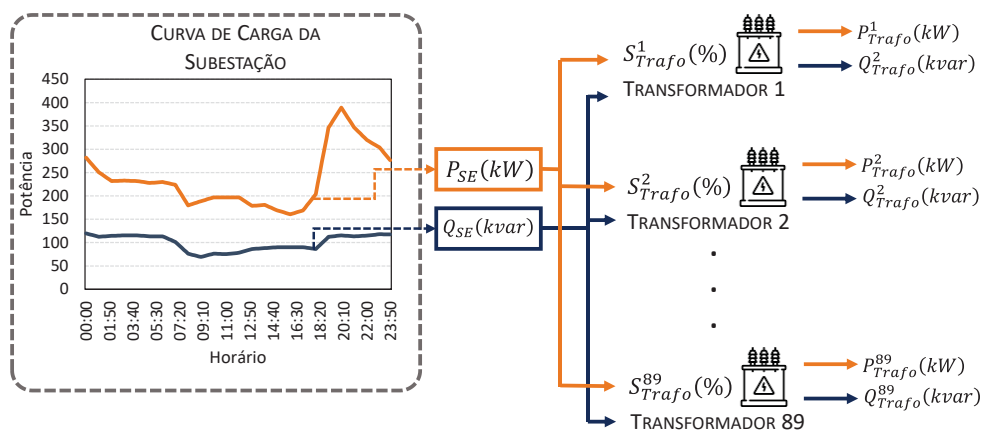
$$S_{Trafo}^j(\%) = \frac{S_{Carga}^j(kVA)}{\sum_{i=1}^{89} S_{Carga}^i(kVA)} \times 100\%. \quad (4.1)$$

4. Relacionar o percentual de potência de cada transformador i com a curva de carga da subestação através das equações (4.2) e (4.3), onde P_{Trafo}^j e Q_{Trafo}^j são, respectivamente, a potência ativa e reativa total demandada pela carga do transformador j e P_{SE} e Q_{SE} são, respectivamente, a potência ativa e reativa da curva de carga da subestação.

$$P_{Trafo}^j(kW) = \frac{P_{SE}(kW) \times S_{Trafo}^j(\%)}{100(\%)} \quad (4.2)$$

$$Q_{Trafo}^j(kvar) = \frac{Q_{SE}(kvar) \times S_{Trafo}^j(\%)}{100(\%)} \quad (4.3)$$

FIGURA 24 - OBTENÇÃO DAS CURVAS DE CARGA PARA CADA TRANSFORMADOR DA REDE DE DISTRIBUIÇÃO



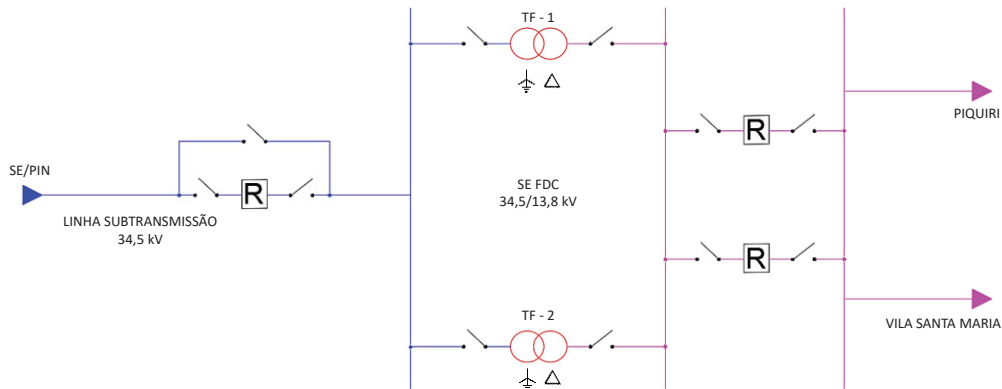
FONTE: O AUTOR (2021)

Através deste procedimento foram geradas 89 curvas de cargas associadas aos transformadores que foram utilizadas na modelagem das cargas no *GridLAB-D*.

4.1.2.4 Linha de Subtransmissão e Subestação

O sistema de Faxinal do Céu é alimentado por uma rede de subtransmissão de 34,5 kV que é conectada na entrada da subestação da cidade. A FIGURA 25 apresenta um esquemático simplificado da conexão da rede de subtransmissão com o sistema de distribuição de Faxinal do Céu.

FIGURA 25 - ESQUEMÁTICO SIMPLIFICADO DA CONEXÃO ENTRE A REDE DE SUBTRANSMISSÃO, SUBESTAÇÃO E ALIMENTADORES DE FAXINAL DO CÉU



FONTE: O AUTOR (2021)

Conforme a FIGURA 25 a subestação de Faxinal do Céu é composta por dois transformadores trifásicos de 5,7 MVA sendo um transformador principal e um transformador reserva. Através de relatórios fornecidos pela COPEL Distribuição foi possível representar a linha de subtransmissão através da seguinte matriz de impedância de fase:

$$Z_{ABC} = \begin{bmatrix} 16.41 + j251.28 & 0.28 + j167.35 & 0.28 + j167.35 \\ 0.28 + j167.35 & 16.41 + j251.28 & 0.28 + j167.35 \\ 0.28 + j167.35 & 0.28 + j167.35 & 16.41 + j251.28 \end{bmatrix} [\Omega]. \quad (4.4)$$

Dessa forma, através do objeto *line configuration* do *GridLAB-D*, foi possível inserir a matriz Z_{ABC} na modelagem do sistema.

4.1.2.5 Sistema de Geração Fotovoltaica

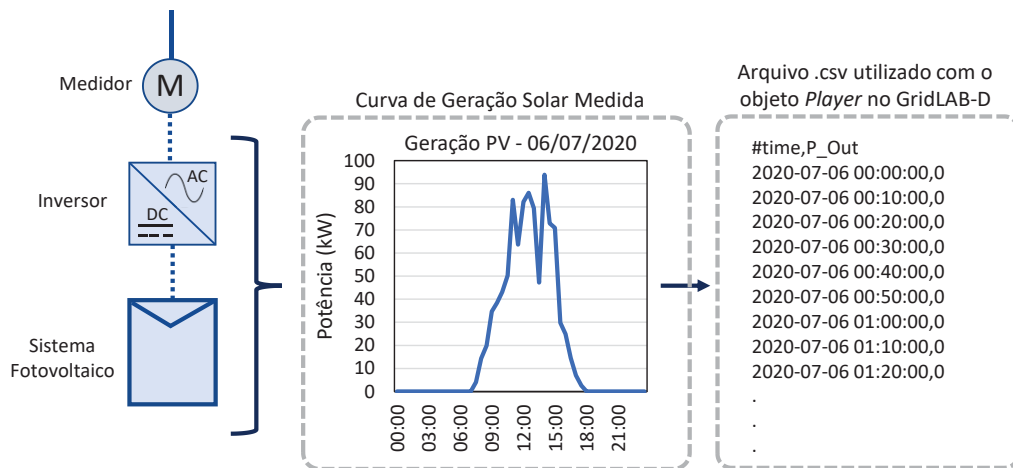
O *GridLAB-D* permite a modelagem de sistemas de geração fotovoltaica através do modulo *Generator*. Dentre os parâmetros que são utilizados na modelagem de painéis solares no *GridLAB-D* podem ser destacados:

- Tecnologia do painel, podendo ser silício monocristalino, policristalino ou silício amorfo;
- Eficiência da conversão da irradiação solar em energia elétrica;
- Área do modulo solar;

Para os painéis solares modelados no *GridLAB-D* deve existir um inversor associado a estes painéis de forma a permitir a conexão desses painéis na rede elétrica. Os inversores no *GridLAB-D* possuem uma grande variedade de parâmetros que podem ser configurados para a modelagem desses elementos, desde parâmetros associados a características elétricas como tensão, corrente e potência nominal até parâmetros associados ao modo de controle do inversor, como controle de potência ativa e reativa (PQ), controle de fator de potência, controle *volt-var*, entre outros.

A Geração fotovoltaica no *GridLAB-D* pode ser modelada de duas formas diferentes. A primeira forma é modelar o conjunto painel solar e inversor e obter a curva de geração fotovoltaica através do modulo *climate*, o qual fornece dados como irradiação, temperatura e humidade para uma determinada região ou cidade. Outra forma de modelar a geração fotovoltaica no *GridLAB-D* é inserir uma curva real de geração fotovoltaica na entrada ou saída do inversor através do objeto *Player*, ou seja, se o usuário possui uma curva de geração fotovoltaica que foi obtida através de medições realizadas em campo, por exemplo, esta curva pode ser inserida no *GridLAB-D* e pode ser utilizada junto com o modelo criado. Neste trabalho foram utilizadas curvas reais de geração fotovoltaica para a modelagem do sistema fotovoltaico no *GridLAB-D* conforme ilustrado na FIGURA 26. Para a modelagem foram criados arquivos *.csv* com a data, horário e potência de geração fotovoltaica e esses arquivos são lidos através do objeto *Player* do *GridLAB-D*. As curvas reais de geração foram obtidas através de medição na saída do inversor, ou seja, a potência gerada medida leva em consideração a eficiência do inversor utilizado.

FIGURA 26 - MODELAGEM DO SISTEMA FOTOVOLTAICO NO GRIDLAB-D



FONTE: O AUTOR (2021)

4.1.2.6 Sistema de Armazenamento de Energia

O *GridLAB-D* permite a inserção de sistemas de armazenamento de energia (SAE) com baterias através do módulo *generators* e da classe *battery*. O *GridLAB-D*, na versão utilizada neste trabalho, possui dois modelos internos de bateria, sendo o modelo de bateria de chumbo ácido e o modelo de bateria de íons de lítio. Da mesma forma que na modelagem do sistema fotovoltaico, o SAE deve ter um inversor associado para realizar a conexão entre o SAE e a rede elétrica.

Neste trabalho foi utilizado o modelo interno do *GridLAB-D* para baterias de íons de lítio. A TABELA 4 apresenta os parâmetros utilizados na configuração da modelagem do SAE no *GridLAB-D*. A escolha dos valores dos parâmetros na modelagem do SAE foram determinadas com base nas especificações técnicas do sistema real que será implementado na microrrede.

TABELA 4 - PARÂMETROS UTILIZADOS NA MODELAGEM DO SAE NO GRIDLAB-D

Parâmetro	Valor
Tensão Nominal do SAE	40 V
Potência Nominal	250 kW
Capacidade Total	560 kWh
Estado de Carga	De 0% até 100%

FONTE: O AUTOR (2021)

A TABELA 5 apresenta os valores dos parâmetros utilizados na modelagem do inversor associado ao SAE no *GridLAB-D*. O inversor pode operar em quatro quadrantes,

permitindo que seja injetada ou absorvida potência ativa ou reativa no sistema. O modo de controle do inverso é do tipo PQ constante, sendo que os valores de potência ativa (P) e reativa (Q) são fornecidos pelo controle MPC proposto neste trabalho e são passados para o modelo do inversor através do objeto *Player* do *GridLAB-D*.

TABELA 5 - PARÂMETROS UTILIZADOS NA MODELAGEM DO INVERSOR DO SAE

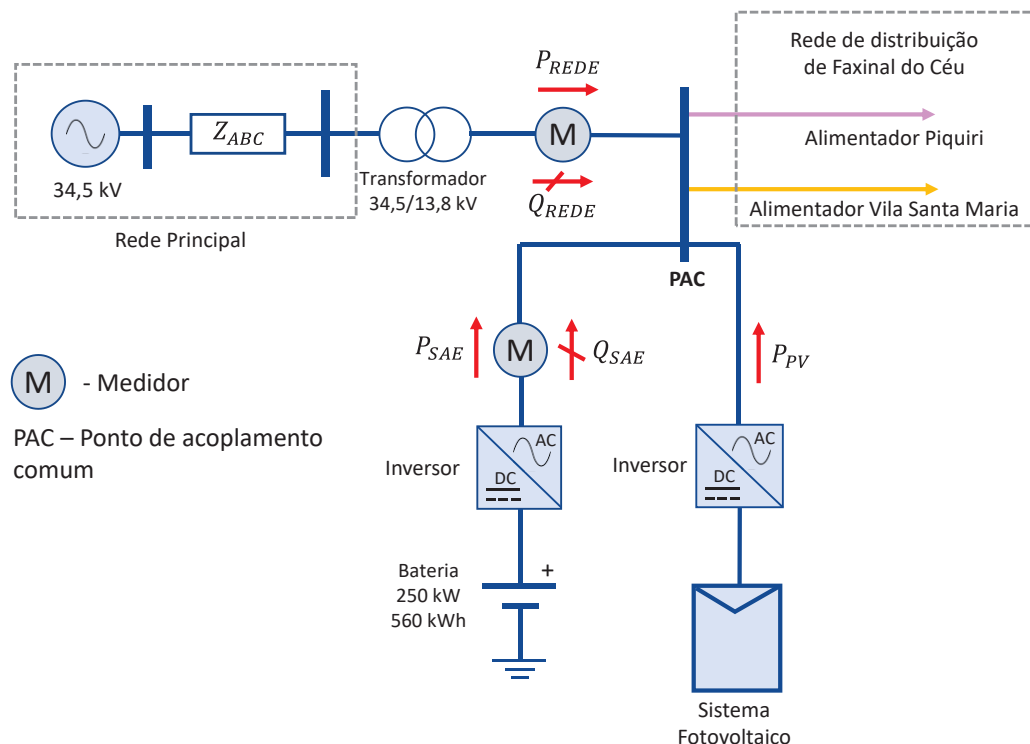
Parâmetro	Valor
Tipo de Inversor	Quatro quadrantes
Tipo de Controle	PQ Constante
Potência Nominal	300 kVA
Eficiência	0,96

FONTE: O AUTOR (2021)

4.1.2.7 Compensação ativa e reativa para o caso estudado

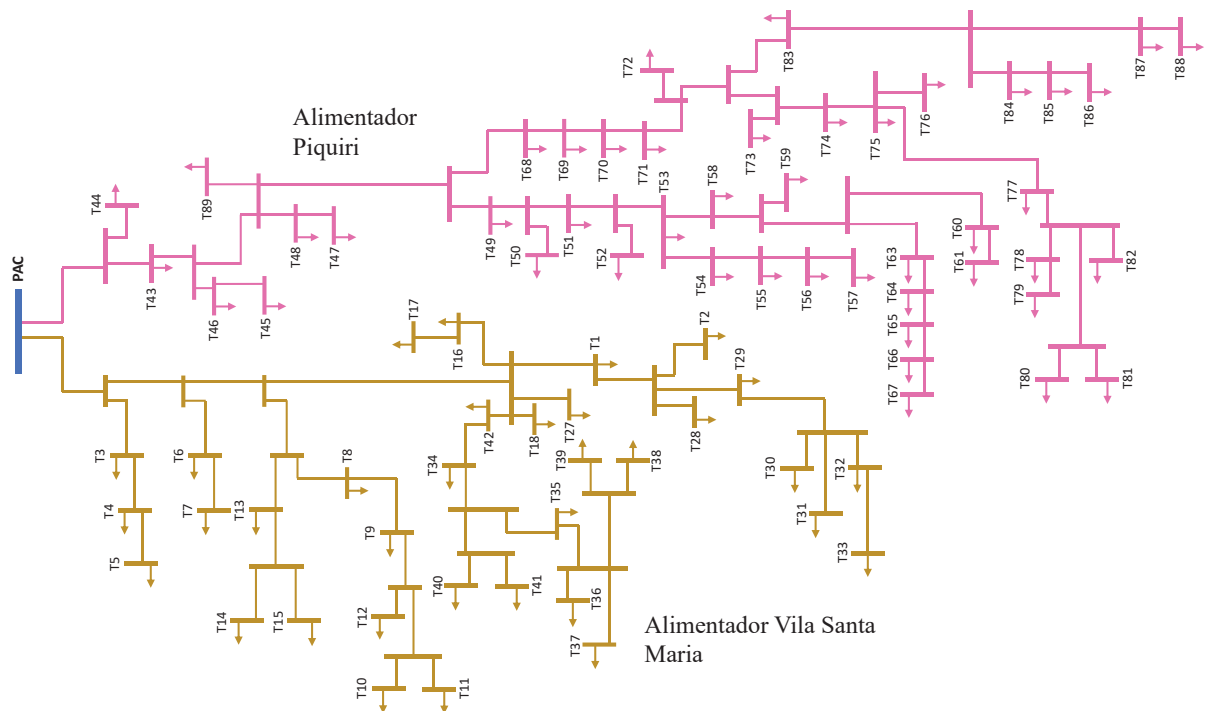
Para o estudo de compensação ativa e reativa foi utilizado o sistema mostrado na FIGURA 27 que representa o modelo de Faxinal do Céu no *GridLAB-D*. A FIGURA 28 apresenta a rede de distribuição da Faxinal do Céu composta por dois alimentadores que são conectados no PAC.

FIGURA 27 - ESQUEMÁTICO SIMPLIFICADO DA REDE DE FAXINAL DO CÉU COM A INSERÇÃO DO SAE + PV



FONTE: O AUTOR (2021)

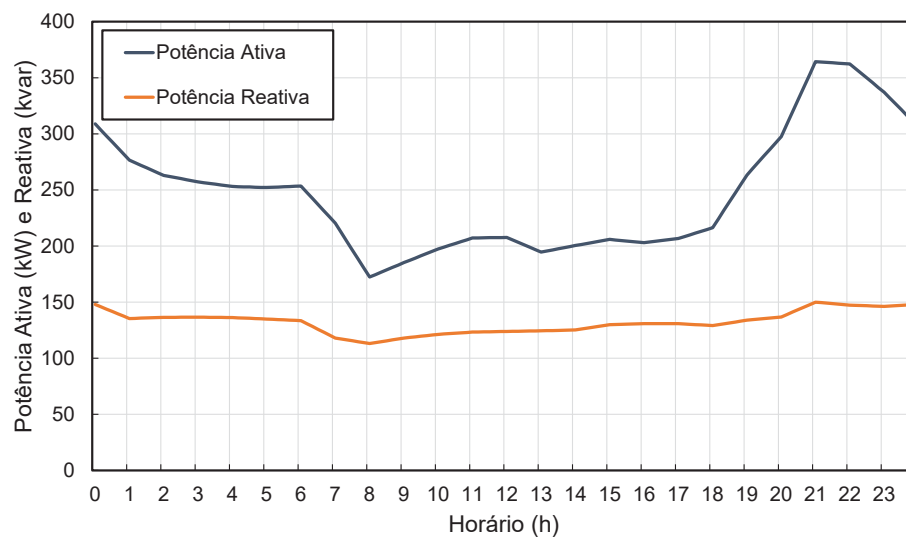
FIGURA 28 - REDE DE DISTRIBUIÇÃO 13,8 KV DE FAXINAL DO CÉU



FONTE: O AUTOR (2021)

A FIGURA 29 apresenta a curva de carga utilizada para realizar as análises de compensação ativa e reativa do sistema. A curva de carga mostrada da FIGURA 29 representa o comportamento médio da curva de potência ativa e reativa do sistema de Faxinal do Céu e foi obtida através do histórico de dados do sistema.

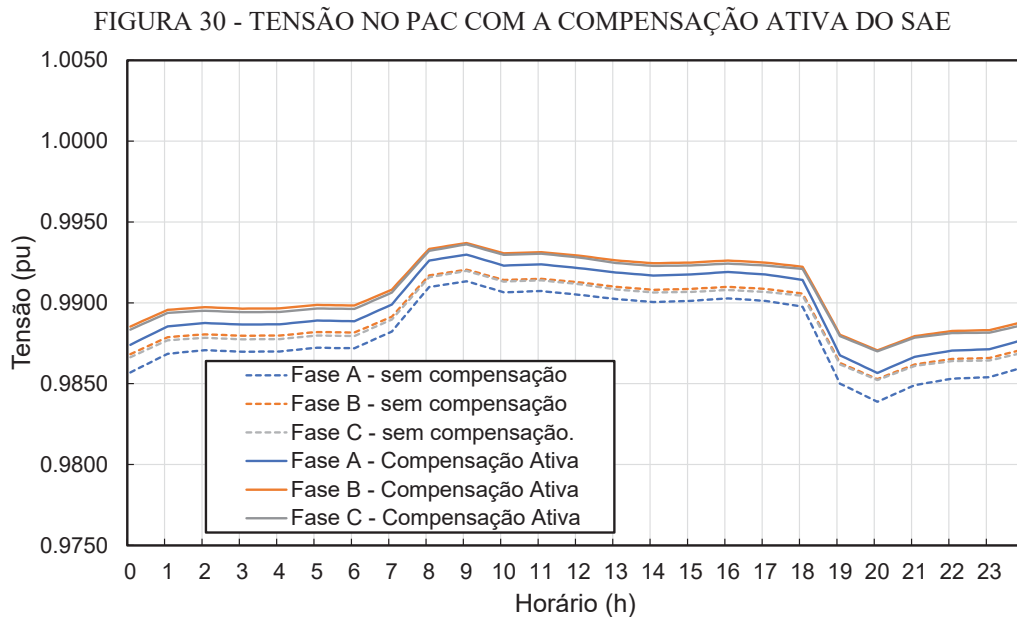
FIGURA 29 - CURVA DE DEMANDA MÉDIA DE POTÊNCIA ATIVA E REATIVA DO SISTEMA DE FAXINAL DO CÉU



FONTE: O AUTOR (2021)

Compensação ativa

A análise da compensação ativa foi realizada através da injeção de potência ativa no PAC pelo SAE. Dessa forma, o SAE foi programado no *GridLAB-D* para injetar 150 kW de potência ativa durante 24 horas e foram comparados os valores de tensão no PAC antes e depois da atuação do SAE. A FIGURA 30 apresenta a comparação da tensão no PAC antes e depois da injeção de potência ativa pelo SAE.



FONTE: O AUTOR (2021)

Com base na FIGURA 30 ocorreu um leve aumento na tensão do PAC com a atuação do SAE injetando potência ativa. Utilizando a equação (3.12) foram calculados os valores de K_A para as três fases do sistema. Como a simulação no *GridLAB-D* foi executada com intervalo de amostragem de 10 minutos, foram obtidos 144 valores de K_A para cada fase. A TABELA 6 apresenta os valores médios de K_A para as três fases do sistema.

TABELA 6 - VALORES MÉDIOS DE K_A

Fase	K_A (kW/pu)
Fase A	59.734,03
Fase B	59.859,49
Fase C	59.800,77

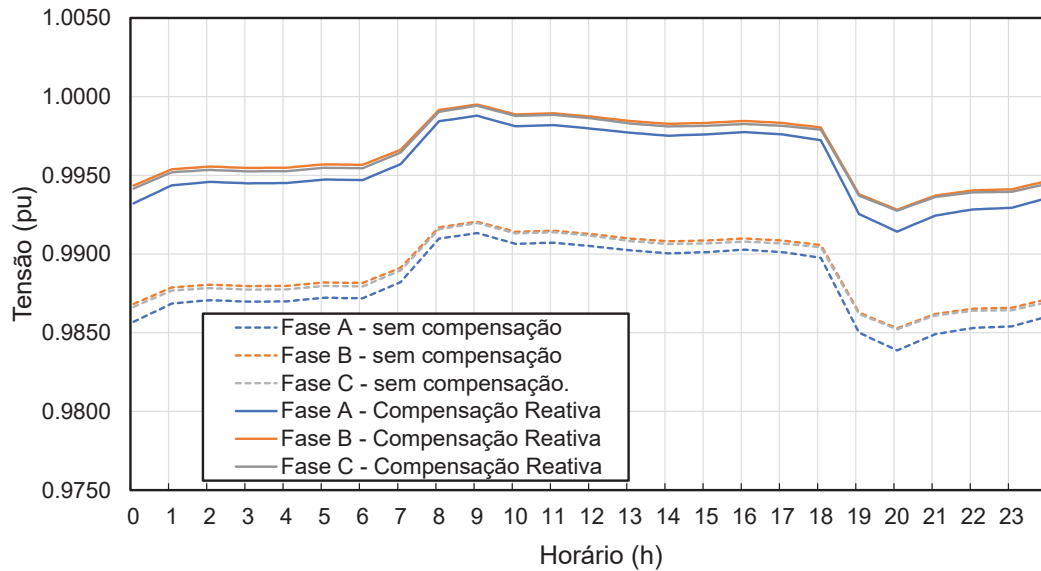
FONTE: O AUTOR (2021)

Compensação Reativa

A análise da compensação reativa no sistema foi realizada de forma semelhante a compensação ativa, porém, neste caso, o SAE foi programado para injetar 150 kvar durante

24 horas. A FIGURA 31 apresenta a comparação da tensão no PAC antes e depois da injeção de potência reativa pelo SAE. Com base na FIGURA 31 a injeção de reativo pelo SAE levou a uma variação na tensão do PAC muito mais significativa em relação a compensação ativa.

FIGURA 31 - TENSÃO NO PAC COM A COMPENSAÇÃO REATIVA DO SAE



FONTE: O AUTOR (2021)

Utilizando a equação (3.13) foram calculadas as médias dos valores de K_R apresentados na TABELA 7 para as três fases do sistema.

TABELA 7 - VALORES MÉDIOS DE K_R

Fase	K_R (kW/pu)
Fase A	13.315,58
Fase B	13.331,45
Fase C	13.326,40

FONTE: O AUTOR (2021)

Os valores obtidos de K_R foram menores que os valores obtidos de K_A indicando que a tensão no PAC possui uma sensibilidade maior com relação a potência reativa, ou seja, é necessária uma quantidade maior de potência ativa para ocasionar a mesma variação de tensão que a potência reativa. Desta forma, de acordo com os resultados, é possível estabelecer que o controle de potência reativo é suficiente para regulação de tensão, considerando que a potência ativa não tem influência sobre o valor do nível de tensão. A partir disso, será desenvolvido uma estratégia de controle de tensão baseado na relação direta entre módulo de tensão e potência reativa.


Através dos resultados obtidos com relação a compensação reativa e ativa foi assumido, neste trabalho, que apenas a potência reativa tem influência na tensão do PAC. Dessa forma, o modelo de otimização para a regulação de tensão busca aproximar a tensão no PAC o mais próximo possível do seu valor nominal (1 pu) através da compensação reativa realizada com o SAE.

Regulação de tensão através da relação de *droop* reativo

A relação entre a potência reativa injetada ou absorvida pelo SAE com a tensão no PAC pode ser estabelecida através de uma curva de *droop* reativo.

Para encontrar a relação de *droop* no sistema estudado foram realizadas análises de três pontos de operação da curva de carga média do sistema. Os pontos de operação da curva média considerados no estudo são os pontos que ocorrem nos horários de 3h, 12h e 21h apresentados na FIGURA 32. Os pontos foram escolhidos de forma a abranger a característica da curva média durante a madrugada, início da tarde e horário de pico.


FIGURA 32 - PONTOS DE OPERAÇÃO CONSIDERADOS PARA A ANÁLISE DA RELAÇÃO DE DROOP NO SISTEMA DE FAXINAL DO CÉU



FONTE: O AUTOR (2021)

Para se obter a relação da tensão no PAC para diferentes valores de potência reativa, o SAE deve fornecer diferentes patamares de potência reativa para os pontos de operação da FIGURA 32. Com isso, a FIGURA 33 apresenta a curva de potência reativa programada para a operação do SAE durante as simulações. A operação do SAE foi programada de forma que o SAE absorva potência reativa no período de 0h até 12h e forneça potência reativa para o sistema das 12h até as 23:50h. Conforme pode ser observado na FIGURA 33, o nível de potência do SAE durante as simulações é alterado em 2,08 *kvar* a cada 10 minutos.

FIGURA 33 - CURVA DE POTÊNCIA REATIVA DO SAE




FONTE: O AUTOR (2021)

Considerando a curva de potência reativa do SAE mostrada na FIGURA 33, foram realizadas três simulações utilizando o modelo do sistema no *GridLAB-D* para cada um dos pontos de operação mostrados na FIGURA 32. Nas simulações foi observado o comportamento da tensão no PAC com relação às potências reativas do SAE e da rede principal para se obter o coeficiente de *droop* do sistema.

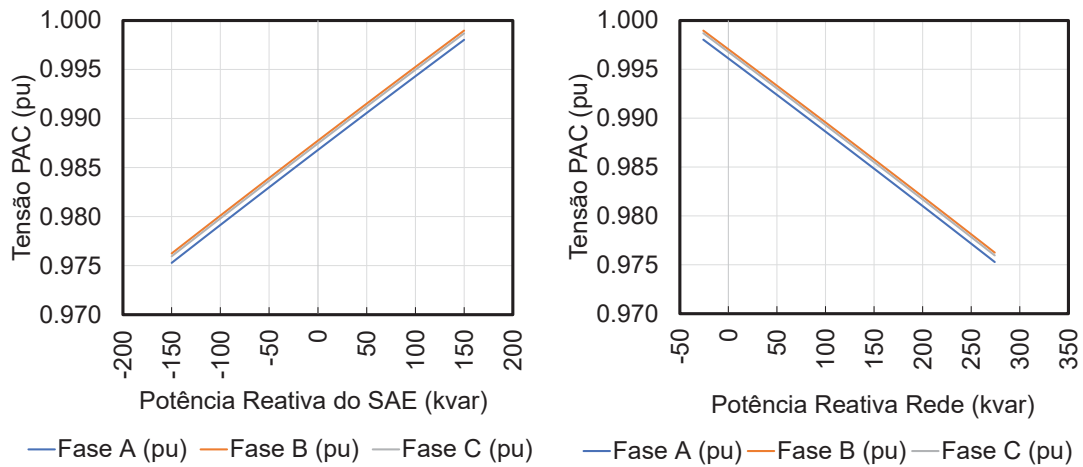
A FIGURA 34, FIGURA 35 e FIGURA 36 apresentam a variação da tensão no PAC com relação à potência reativa do SAE e reativa da rede para os três pontos de operação considerados na simulação.

FIGURA 34 - TENSÃO NO PAC COM A VARIAÇÃO DA POTÊNCIA REATIVA PARA O PONTO DE OPERAÇÃO 1




FONTE: O AUTOR (2021)

FIGURA 35 - TENSÃO NO PAC COM A VARIAÇÃO DA POTÊNCIA REATIVA PARA O PONTO DE OPERAÇÃO 2



FONTE: O AUTOR (2021)

FIGURA 36 - TENSÃO NO PAC COM A VARIAÇÃO DA POTÊNCIA REATIVA PARA O PONTO DE OPERAÇÃO 3



FONTE: O AUTOR (2021)

Com base nas curvas apresentadas nas FIGURA 34, FIGURA 35 e FIGURA 36 é possível observar a característica da curva de *droop* no PAC. Com relação a operação do SAE, a tensão no PAC aumenta conforme o SAE fornece potência reativa para o sistema dando a característica da curva de *droop* com coeficiente angular positivo. O fornecimento de potência reativa pelo SAE faz com que haja a diminuição do fluxo de potência reativa na rede principal. Dessa forma, com relação a potência reativa da rede principal, a tensão no PAC diminuiu conforme o fluxo de potência reativa diminui na rede principal, fazendo com que a curva de *droop* tenha o coeficiente angular negativo. As equações do *droop* reativo para as

curvas apresentadas nas FIGURA 34, FIGURA 35 e FIGURA 36 podem ser representadas através da equação de reta da seguinte forma:

$$V_{PAC} = A \cdot Q + B \quad (4.5)$$

onde V_{PAC} é a tensão do PAC, A é o coeficiente angular da reta, Q é a potência reativa do SAE ou da rede e B é o coeficiente linear da reta. Como isso, foram calculados os coeficientes angulares e lineares para as curvas da FIGURA 34, FIGURA 35 e FIGURA 36 para obter uma equação que relaciona a tensão no PAC com a potência reativa da rede. A TABELA 8 apresenta os valores dos parâmetros encontrados para os pontos de operação considerados na simulação.

TABELA 8 - VALORES DE A (COEF. ANGULAR), B (COEF. LINEAR) E K_R PARA OS PONTOS DE OPERAÇÃO CONSIDERADOS

Ponto de Operação	Fase	A (Coef. Angular) (pu/kvar)	B (Coef. Linear) (pu)	K_R (kvar/pu)
1	A	$-7,62856e^{-5}$	0,9952	-13.108,6
	B	$-7,61436e^{-5}$	0,9963	-13.133,0
	C	$-7,64516e^{-5}$	0,9961	-13.080,1
2	A	$-7,62951e^{-5}$	0,9962	-13.107,0
	B	$-7,60620e^{-5}$	0,9971	-13.147,1
	C	$-7,60182e^{-5}$	0,9968	-13.154,7
3	A	$-7,65903e^{-5}$	0,9931	-13.056,4
	B	$-7,66678e^{-5}$	0,9946	-13.043,2
	C	$-7,67784e^{-5}$	0,9944	-13.024,5

FONTE: O AUTOR (2021)

Para obter uma equação geral para ser utilizada no modelo de otimização foram calculadas as médias dos parâmetros da TABELA 8 para os três pontos de operação. Os valores médios são mostrados na TABELA 9.

TABELA 9 - MÉDIAS DE A, B E K_R

Parâmetro	Valor
Média A (pu/kvar)	$-7,63658e^{-5}$
Média B (pu)	0,9955
Média K_R (kvar/pu)	-13.094,95

FONTE: O AUTOR (2021)

Dessa forma, através da formulação apresentada na seção 3.3.3.2, a equação que relaciona a tensão no PAC com a potência reativa da rede para o sistema estudado pode ser expressa por

$$V_{PAC} = \frac{1}{K_R} \cdot Q_{REDE} + B \quad (4.6)$$

onde V_{PAC} é a tensão no PAC em pu , K_R é o coeficiente inverso de sensibilidade em $kvar/pu$, Q_{REDE} é a potência reativa trifásica na rede principal e B é o coeficiente linear da equação de *droop* em pu . Nota-se que o coeficiente angular de *droop* é igual ao coeficiente encontrado pelo método de sensibilidade, ou seja, $A = 1/K_R$. Dessa forma, considerando os valores apresentados na TABELA 9 e considerando que $Q_{REDE} = Q_{CARGA} - Q_{SAE}$, a equação (4.6) pode ser reescrita da seguinte forma:

$$V_{PAC} = -\frac{1}{13094,95} \cdot (Q_{CARGA} - Q_{SAE}) + 0.9955 \quad (4.7)$$

onde Q_{CARGA} é a potência reativa demandada pela carga e Q_{SAE} é a potência absorvida ou fornecida pelo SAE. Dessa forma, a equação (4.7) estabelece a relação entre a tensão no PAC com a potência reativa da carga e com a potência reativa do SAE para o sistema estudado neste trabalho.

4.1.2.8 Modelos de previsão de carga e geração fotovoltaica para o caso estudado

A seguir são apresentadas as estruturas dos modelos LSTM para a previsão de carga e geração fotovoltaica e os índices de desempenho para cada modelo de previsão proposto neste trabalho.

4.1.2.9 Previsão de Carga para o caso estudado

O histórico de dados utilizados para a implementação do algoritmo de previsão de carga é composto de medições realizadas em dois alimentadores de distribuição localizados no município de Faxinal do Céu – PR com intervalo de amostragem de 10 minutos entre as medições. Neste histórico estão presentes os registros de potência ativa, potência reativa, potência aparente e fator de potência dos dois alimentadores de distribuição que constituem a microrrede. A TABELA 10 apresenta as porcentagens de treino, validação e teste utilizadas neste trabalho para os modelos de previsão de carga implementados.


TABELA 10 - DIVISÃO DOS HISTÓRICOS DE DADOS ENTRE TREINO, VALIDAÇÃO E TESTE PARA A IMPLEMENTAÇÃO DOS MODELOS DE PREVISÃO

Modelo de Previsão	Amostras totais	Treino	Validação	Teste
Previsão Carga Ativa	56.830	65% (36.940 Amostras)	20% (11.366 Amostras)	15% (8.524 Amostras)
Previsão Carga Reativa	56.830	65% (36.940 Amostras)	20% (11.366 Amostras)	15% (8.524 Amostras)

FONTE: O AUTOR (2021)


A FIGURA 37 e FIGURA 38 apresentam o decaimento do erro quadrático médio durante o treinamento e validação da rede LSTM para a previsão de potência ativa e reativa, respectivamente. Nestas figuras é possível observar que o erro quadrático médio diminui conforme o número de épocas aumenta, ou seja, a rede neural consegue se adaptar aos dados de treino e validação e consegue realizar previsões mais assertivas conforme a rede LSTM é treinada. O número de épocas para o treinamento foi definido até que o erro quadrático médio dos dados de treino não apresentasse melhorias, ou seja, quando o erro quadrático não diminuísse à medida que as épocas passassem.

FIGURA 37 - DECAIMENTO DO EQM DURANTE O TREINAMENTO E VALIDAÇÃO DA REDE LSTM PARA A PREVISÃO DE POTÊNCIA ATIVA



FONTE: O AUTOR (2021)

FIGURA 38 - DECAIMENTO DO EQM DURANTE O TREINAMENTO E VALIDAÇÃO DA REDE LSTM PARA A PREVISÃO DE POTÊNCIA REATIVA



FONTE: O AUTOR (2021)

A TABELA 11 apresenta os parâmetros das redes neurais LSTM utilizadas para a implementação dos modelos de previsão de potência ativa e reativa da carga agrupada na microrrede.

TABELA 11 - PARÂMETROS DAS REDES LSTM PARA A IMPLEMENTAÇÃO DOS MODELOS DE PREVISÃO DE POTÊNCIA ATIVA E REATIVA DA CARGA DA MICRORREDE

Modelo de Previsão	Camadas Ocultas	Células LSTM	Batch Size	Dropout	Épocas Treinamento
Previsão Carga Ativa	2	48 - 48	50	0,3 – 0,3	80
Previsão Carga Reativa	2	48 - 48	50	0,3 – 0,3	80

FONTE: O AUTOR (2021)

A TABELA 12 apresenta os valores do RMSE e do coeficiente de determinação R^2 obtidos através das equações (3.35) e (3.36) para os dados de teste dos modelos de previsão.


TABELA 12 - RMSE E R^2 PARA O CONJUNTO DE DADOS DE TESTE DOS MODELOS DE PREVISÃO DE POTÊNCIA ATIVA E REATIVA DA CARGA DA MICRORREDE

Modelo de Previsão	RMSE	R^2
Previsão Carga Ativa	13,66	0,94
Previsão Carga Reativa	5,28	0,94

FONTE: O AUTOR (2021)

A FIGURA 39 apresenta os valores de medição de potência ativa e os valores previstos obtidos utilizando o modelo LSTM para a previsão de potência ativa durante uma semana.


FIGURA 39 - VALORES MEDIDOS E PREVISTOS DE POTÊNCIA ATIVA UTILIZANDO O MODELO DE PREVISÃO IMPLEMENTADO



FONTE: O AUTOR (2021)

A FIGURA 40 apresenta os valores de medição de potência reativa e os valores previstos obtidos utilizando o modelo LSTM para a previsão de potência reativa durante uma semana.

FIGURA 40 - VALORES MEDIDOS E PREVISTOS UTILIZANDO O MODELO DE PREVISÃO PARA POTÊNCIA REATIVA IMPLEMENTADO



FONTE: O AUTOR (2021)

4.1.2.10 Previsão de Geração Fotovoltaica para o caso estudado

Com relação à previsão de geração fotovoltaica, para a implementação do modelo de previsão foi utilizado um histórico de dados de medição no período de 01/09/2016 até 30/09/2017 de uma planta solar localizada na cidade de Rosana-SP. Da mesma forma que nos modelos de previsão de carga, a previsão de geração fotovoltaica deve ser feita para um horizonte de 24 horas à frente para a estrutura de controle proposta neste trabalho.

A TABELA 13 apresenta as porcentagens e números de amostras utilizadas para o treinamento, validação e teste na rede neural LSTM para previsão de geração fotovoltaica.


TABELA 13 - DIVISÃO DO HISTÓRICO DE DADOS ENTRE TREINO, VALIDAÇÃO E TESTE PARA A IMPLEMENTAÇÃO DO MODELO DE PREVISÃO DE GERAÇÃO FOTOVOLTAICA

Modelo de Previsão	Amostras totais	Treino	Validação	Teste
Previsão Geração Fotovoltaica	56.830	65% (36.940 Amostras)	20% (11.366 Amostras)	15% (8.524 Amostras)

FONTE: O AUTOR (2021)

A FIGURA 41 apresenta o decaimento do erro quadrático médio durante o treinamento e validação do modelo de previsão. A TABELA 14 apresenta os parâmetros das redes neurais LSTM utilizadas para a implementação do modelo de previsão de geração fotovoltaica.

FIGURA 41 - DECAIMENTO DO EQM DURANTE O TREINAMENTO E VALIDAÇÃO DA REDE LSTM PARA A PREVISÃO DE GERAÇÃO FOTOVOLTAICA



FONTE: O AUTOR (2021)

TABELA 14 - PARÂMETROS DA REDE LSTM PARA A IMPLEMENTAÇÃO DO MODELO DE PREVISÃO DE GERAÇÃO FOTOVOLTAICA

Modelo de Previsão	Camadas Ocultas	Células LSTM	Batch Size	Dropout	Épocas Treinamento
Previsão Geração Fotovoltaica	2	48 - 48	50	0,3 – 0,3	150

FONTE: O AUTOR (2021)

Para avaliar o desempenho do modelo de previsão foram calculados o RMSE e o coeficiente de determinação R^2 apresentados na TABELA 15 utilizando os dados de teste.


TABELA 15 - RMSE E R^2 PARA O CONJUNTO DE TESTE DO MODELO DE PREVISÃO DE GERAÇÃO FOTOVOLTAICA

Modelo de Previsão	RMSE	R^2
Previsão Geração Fotovoltaica	11,88	0,91

FONTE: O AUTOR (2021)

A FIGURA 42 apresenta os valores de medição de geração fotovoltaica e os valores previstos obtidos utilizando o modelo de previsão LSTM durante uma semana.

FIGURA 42 - VALORES MEDIDOS E PREVISTOS UTILIZANDO O MODELO DE PREVISÃO DE GERAÇÃO FOTOVOLTAICA IMPLEMENTADO

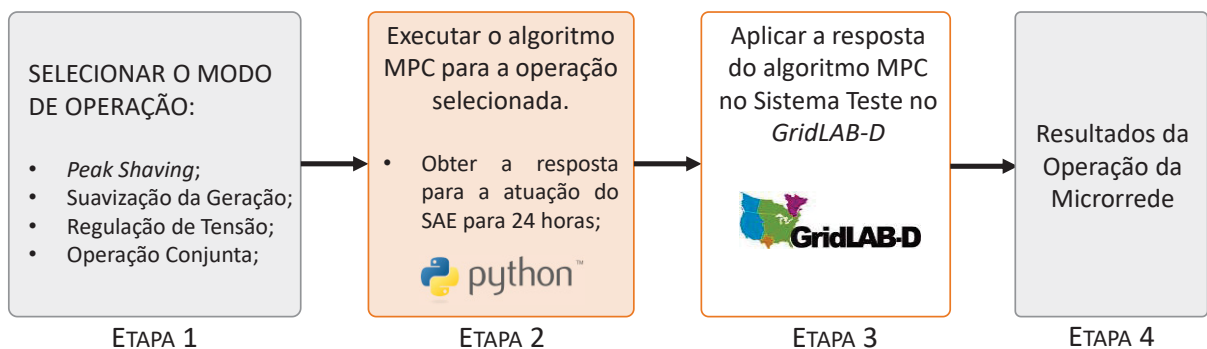


FONTE: O AUTOR (2021)

5 SIMULAÇÕES E RESULTADOS

Neste capítulo são apresentadas as simulações realizadas e os resultados obtidos com a metodologia proposta neste trabalho para cada modo de operação da microrrede. A FIGURA 43 apresenta um esquemático que ilustra o processo de simulação realizado neste trabalho. Inicialmente é feita a escolha do modo de operação da microrrede que se deseja analisar. Em seguida, é executado o algoritmo MPC que determina as ações de controle, ou seja, as decisões de carga e descarga do SAE, para a operação da microrrede considerando uma determinada curva de carga e um perfil de geração fotovoltaica. O algoritmo MPC determina as ações de controle para 24 horas com intervalo de 10 minutos entre as decisões. Na sequência, as decisões de controle geradas pelo MPC são aplicadas no modelo da microrrede implementada no *GridLAB-D*. Com isso, é executado o fluxo de potência no *GridLAB-D* considerando as respostas do MPC e são analisados o comportamento da potência da rede principal, o comportamento da geração fotovoltaica e os perfis de tensão no sistema.

FIGURA 43 - PROCESSO DE SIMULAÇÃO E OBTENÇÃO DOS RESULTADOS




FONTE: O AUTOR (2021)

5.1 OPERAÇÃO DE *PEAK SHAVING*

Para a operação de *peak shaving* foi avaliado o comportamento da potência ativa demandada da rede principal pela microrrede considerando diferentes condições de geração fotovoltaica e do estado de carga inicial do SAE. Dessa forma, foram escolhidas duas curvas de geração fotovoltaica características, a de um dia ensolarado e a de um dia nublado, para serem utilizadas durante as simulações. As curvas de geração fotovoltaica são mostradas na FIGURA 44.

FIGURA 44 - CURVAS DE GERAÇÃO SOLAR COM CARACTERÍSTICA DE DIA ENSOLARADO E NUBLADO



FONTE: O AUTOR (2021)

A TABELA 16 apresenta os cenários analisados para a operação de *peak shaving*.


TABELA 16 - CENÁRIOS CONSIDERADOS PARA AS SIMULAÇÕES DA OPERAÇÃO DE PEAK SHAVING

Cenário	Período de Análise	Geração Fotovoltaica	Estado de Carga inicial do SAE
1	24 Horas	Dia Ensolarado	20%
2	24 Horas	Dia Ensolarado	80%
3	24 Horas	Dia Nublado	20%
4	24 Horas	Dia Nublado	80%
5	168 Horas	Dias Ensolarados e Nublados	20%

FONTE: O AUTOR (2021)

A curva de carga utilizada nas simulações dos cenários 1 até 4 é mostrada na FIGURA 45. A curva de carga da FIGURA 45 foi escolhida por apresentar um perfil de carga considerado pesada para o sistema de Faxinal do Céu, sendo que o valor de pico atinge 425 kW. Na sequência, são apresentados os resultados obtidos para a operação de *peak shaving* considerando cada um dos cenários da TABELA 16.

FIGURA 45 - CURVA DE CARGA UTILIZADA PARA AS SIMULAÇÕES DA OPERAÇÃO DE PEAK SHAVING




FONTE: O AUTOR (2021)

Cenário 1 – Dia ensolarado com SOC inicial em 20%


A FIGURA 46 e FIGURA 47 apresentam, respectivamente, o comportamento da potência ativa da rede principal e o comportamento do estado de carga do SAE para as condições do cenário 1.

FIGURA 46 - RESULTADO PARA A OPERAÇÃO DE PEAK SHAVING CONSIDERANDO AS CONDIÇÕES DO CENÁRIO 1



FONTE: O AUTOR (2021)

FIGURA 47 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING PARA O CENÁRIO 1



FONTE: O AUTOR (2021)

Com base nos resultados apresentados podemos observar a comparação entre a curva da rede principal sem microrrede e com a microrrede operando no modo *peak shaving*. A potência ativa da rede principal não superou o valor de 300 kW proporcionando a redução do pico de demanda do sistema. A TABELA 17 apresenta a comparação do pico de demanda e do fator de carga para o sistema com e sem a microrrede.

TABELA 17 - PICO MÁXIMO E FATOR DE CARGA PARA O CENÁRIO 1 DA OPERAÇÃO DE PEAK SHAVING

Parâmetro	Sem MPC	Com MPC	Percentuais de Melhorias
Pico Máximo	425,6 kW	300 kW	Redução de 29,51%
Fator de Carga	0,526	0,757	Aumento de 43,92%

FONTE: O AUTOR (2021)

A redução no pico de demanda do sistema foi de 125,6 kW e, além disso, a operação de *peak shaving* contribuiu para a melhoria do fator de carga do sistema.

Com relação a operação do SAE, este foi carregado durante o horário das 0h até as 07h:30m e descarregado durante o horário das 20h:00 até 23h:50. A TABELA 18 apresenta alguns parâmetros da atuação do SAE para o cenário 1 durante esta simulação de *peak shaving*.

TABELA 18 - PARÂMETROS DA ATUAÇÃO DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING NAS CONDIÇÕES DO CENÁRIO 1

Parâmetro	Valor
SOC Inicial	20%
SOC Final	31%
Energia Carregada na Bateria (Lado CC)	335,8 kWh
Energia Descarregada da Bateria (Lado CC)	277,5 kWh
Energia Absorvida pelo SAE (Lado CA)	349,7 kWh
Energia Fornecida pelo SAE (Lado CA)	266,4 kWh


FONTE: O AUTOR (2021)

Conforme a TABELA 18, os valores de energia encontrados na simulação estão de acordo com a eficiência do SAE especificada no algoritmo MPC que foi de 0,96.

Cenário 2 - Dia ensolarado com SOC inicial em 80%


No Cenário 2 foi considerado que o estado de carga inicial do SAE é de 80% e foram consideradas as mesmas curvas de carga e de geração fotovoltaica do cenário 1. A FIGURA 48 e FIGURA 49 apresentam, respectivamente, o comportamento da potência ativa da rede principal e o estado de carga do SAE para a simulação de *peak shaving* com as condições do cenário 2.

FIGURA 48 - RESULTADO PARA A OPERAÇÃO DE PEAK SHAVING CONSIDERANDO AS CONDIÇÕES DO CENÁRIO 2



FONTE: O AUTOR (2021)

FIGURA 49 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING PARA O CENÁRIO 2



FONTE: O AUTOR (2021)

Com os resultados apresentados é possível observar a redução do pico de demanda da rede principal. Da mesma forma que no cenário 1, a potência ativa da rede principal não superou o valor de 300 kW. A TABELA 19 apresenta os valores de pico máximo de demanda e fator de carga para as condições do cenário 2.

TABELA 19 - PICO MÁXIMO E FATOR DE CARGA PARA O CENÁRIO 2 DA OPERAÇÃO DE PEAK SHAVING

Parâmetro	Sem MPC	Com MPC	Percentuais de Melhorias
Pico Máximo	425,6 kW	300 kW	Redução de 29,51%
Fator de Carga	0,526	0,708	Aumento de 34,60%

FONTE: O AUTOR (2021)

A redução do pico de demanda para o cenário 2 foi de 125,6 kW, sendo a mesma redução encontrada para o cenário 1. Com relação ao fator de carga, houve uma melhoria com relação a condição sem microrrede, porém, o fator de carga do cenário 2 foi menor que no cenário 1. A TABELA 20 apresenta alguns parâmetros da atuação do SAE para o cenário 2 durante a simulação de *peak shaving*.

TABELA 20 - PARÂMETROS DA ATUAÇÃO DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING NAS CONDIÇÕES DO CENÁRIO 2


Parâmetro	Valor
SOC Inicial	80%
SOC Final	31%
Energia Carregada na Bateria (Lado CC)	0 kWh
Energia Descarregada da Bateria (Lado CC)	277,5 kWh
Energia Absorvida pelo SAE (Lado CA)	0 kWh
Energia Fornecida pelo SAE (Lado CA)	266,4 kWh

FONTE: O AUTOR (2021)

Cenário 3 - Dia nublado com SOC inicial em 20%


O cenário 3 considera um perfil de geração solar característica de um dia nublado, ou seja, ocorre uma redução na potência gerada pela planta solar da microrrede. A FIGURA 50 e FIGURA 51 apresentam, respectivamente, o comportamento da potência ativa da rede principal e o estado de carga do SAE para a simulação de *peak shaving* com as condições do cenário 3.

FIGURA 50 - RESULTADO PARA A OPERAÇÃO DE PEAK SHAVING CONSIDERANDO AS CONDIÇÕES DO CENÁRIO 3



FONTE: O AUTOR (2021)

FIGURA 51 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING PARA O CENÁRIO 3



FONTE: O AUTOR (2021)

Os resultados encontrados para o cenário 2 foram muito semelhantes aos obtidos no cenário 1 com relação a atuação do SAE no sistema. Dessa forma, o SAE absorveu potência no horário das 0h até as 07h:40 e foi descarregado durante o pico de demanda proporcionando a redução da potência ativa da rede principal.

A principal diferença entre o cenário 1 e o cenário 3 foi a disponibilidade de geração fotovoltaica. Com isso, em comparação com o cenário 1, no cenário 3 não houve uma redução significativa na potência demandada da rede principal durante o horário de geração fotovoltaica. A TABELA 21 apresenta os valores de pico máximo de demanda e fator de carga para as condições do cenário 3.

TABELA 21 - PICO MÁXIMO E FATOR DE CARGA PARA O CENÁRIO 3 DA OPERAÇÃO DE PEAK SHAVING

Parâmetro	Sem MPC	Com MPC	Percentuais de Melhorias
Pico Máximo	425,6 kW	300 kW	Redução de 29,51%
Fator de Carga	0,526	0,841	Aumento de 59,89%

FONTE: O AUTOR (2021)

Da mesma forma que nos cenários anteriores, a redução do pico de demanda da rede principal para o cenário 3 foi de 125,6 kW. O fator de carga para o cenário 3 apresentou uma melhoria com relação aos cenários anteriores. Essa melhoria no fator de carga é devido ao modo de operação do SAE e da pouca disponibilidade de geração fotovoltaica para o cenário 3, fazendo com que a curva de demanda de rede principal seja mais próxima do valor de demanda máxima de 300 kW. A TABELA 22 apresenta alguns parâmetros da atuação do

SAE para o cenário 3 durante a simulação de *peak shaving* os quais foram os mesmos valores obtidos para o cenário 1.

TABELA 22 - PARÂMETROS DA ATUAÇÃO DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING NAS CONDIÇÕES DO CENÁRIO 3


Parâmetro	Valor
SOC Inicial	80%
SOC Final	31%
Energia Carregada na Bateria (Lado CC)	335,8 kWh
Energia Descarregada da Bateria (Lado CC)	277,5 kWh
Energia Absorvida pelo SAE (Lado CA)	349,8 kWh
Energia Fornecida pelo SAE (Lado CA)	266,4 kWh

FONTE: O AUTOR (2021)

Cenário 4 - Dia nublado com SOC inicial em 80%


O Cenário 4 considera a mesma curva de geração fotovoltaica do cenário 3, porém o estado de carga inicial do SAE foi considerado 80% na simulação. A FIGURA 52 e FIGURA 53 apresentam, respectivamente, o comportamento da potência ativa da rede principal e o estado de carga do SAE para a simulação de *peak shaving* com as condições do cenário 4.

FIGURA 52 - RESULTADO PARA A OPERAÇÃO DE PEAK SHAVING CONSIDERANDO AS CONDIÇÕES DO CENÁRIO 4



FONTE: O AUTOR (2021)

FIGURA 53 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING PARA O CENÁRIO 4



FONTE: O AUTOR (2021)

Para as condições do cenário 4 a operação do SAE foi a mesma obtida para o cenário 2, ou seja, o SAE foi descarregado no período das 20h:00m até as 23h:50m proporcionando a redução do pico de demanda. A TABELA 23 apresenta os valores de pico máximo de demanda e fator de carga para as condições do cenário 4.

TABELA 23 - PICO MÁXIMO E FATOR DE CARGA PARA O CENÁRIO 4 DA OPERAÇÃO DE PEAK SHAVING

Parâmetro	Sem MPC	Com MPC	Percentuais de Melhorias
Pico Máximo	425,6 kW	300 kW	Redução de 29,51%
Fator de Carga	0,526	0,793	Aumento de 50,76%

FONTE: O AUTOR (2021)

Com os valores da TABELA 23 é possível observar a redução de 125,6 kW da demanda da rede principal e a melhoria do fator de carga com relação ao caso sem microrrede. Apesar da operação do SAE para o cenário 4 ser o mesmo obtido para o cenário 2, o fator de carga do cenário 4 apresentou uma melhoria com relação ao obtido para o cenário 2. Essa diferença é dividida a curva de geração fotovoltaica considerada nas simulações visto que, para o cenário 2, a maior disponibilidade de geração fotovoltaica contribuiu para a diminuição da potência ativa demandada da rede principal. O mesmo não se observou no cenário 4 visto que, devido a pouca geração fotovoltaica, a curva de demanda da rede principal ficou mais próxima da potência máxima demandada da rede principal.

A TABELA 24 apresenta alguns parâmetros da atuação do SAE para o cenário 4 durante a simulação de *peak shaving* os quais foram os mesmos valores obtidos para o cenário 2.


TABELA 24 - PARÂMETROS DA ATUAÇÃO DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING NAS CONDIÇÕES DO CENÁRIO 4

Parâmetro	Valor
SOC Inicial	80%
SOC Final	31%
Energia Carregada na Bateria (Lado CC)	0 kWh
Energia Descarregada da Bateria (Lado CC)	277,5 kWh
Energia Absorvida pelo SAE (Lado CA)	0 kWh
Energia Fornecida pelo SAE (Lado CA)	266,4 kWh

FONTE: O AUTOR (2021)

Análise da Função Objetivo

Para cada cenário apresentado anteriormente o algoritmo de controle MPC determina as ações de controle de forma a minimizar a função objetivo. Para os cenários anteriores foi considerado a mesma curva de carga, porém com diferentes curvas de geração fotovoltaica e o estado de carga inicial do SAE. Dessa forma, foi avaliado o comportamento da função objetivo em cada instante de tempo para os diferentes cenários avaliados conforme apresentado na FIGURA 54. Com base na FIGURA 54 é possível observar que os cenários 1 e 3 apresentam valores maiores na função objetivo no horário das 0h até 8h em relação aos cenários 2 e 4. Esse aumento no valor da função objetivo nesses horários é devido ao carregamento do SAE, visto que para estes cenários o SAE encontra-se inicialmente com estado de carga em 20%. Outra variação no valor da função objetivo que pode ser observado é no horário em que ocorre a geração fotovoltaica. Dessa forma, os cenários 1 e 2 apresentam valores menores na função objetivo entre os horários de 7h até 18h devido a maior disponibilidade de geração fotovoltaica para estes cenários. Dessa forma, o custo relacionado a energia da rede principal sofre uma maior redução nos cenários 1 e 2.


FIGURA 54 - VALORES DA FUNÇÃO OBJETIVO PARA A OPERAÇÃO DE *PEAK SHAVING*

FONTE: O AUTOR (2021)

Cenário 5 – Simulação do MPC durante um período de uma semana


Para o cenário 5 foi realizado uma simulação em que o algoritmo MPC para a operação de *peak shaving* é executado para 168 horas, ou seja, uma semana. Dessa forma, é possível observar como o algoritmo se adapta a diferentes curvas de carga e diferentes curvas de geração fotovoltaica. As curvas de carga utilizadas na simulação são os dados de Faxinal do Céu do dia 03/11/2017 até 09/11/2017. As curvas de cargas foram escolhidas de modo a contemplar diferentes dias da semana, sendo que dia 03/11/2017 é recesso de feriado, 04/11/2017 e 05/11/2017 são curvas de sábado e domingo e o restante são dias úteis. A FIGURA 55 e FIGURA 56 apresentam, respectivamente, o comportamento da potência ativa da rede principal e o estado de carga do SAE para a simulação de *peak shaving* com as condições do cenário 5.

FIGURA 55 - RESULTADO PARA A OPERAÇÃO DE PEAK SHAVING NO PERÍODO DE UMA SEMANA



FONTE: O AUTOR (2021)

FIGURA 56 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE PEAK SHAVING NO PERÍODO DE UMA SEMANA



FONTE: O AUTOR (2021)

Com base no resultado apresentado na FIGURA 55, é possível observar que houve a redução do pico de demanda para todos os dias da semana, sendo que a potência ativa da rede principal não superou o valor de 300 kW. A TABELA 25 apresenta os valores de pico máximo de demanda e fator de carga para as condições do cenário 5.

TABELA 25 - PICO MÁXIMO E FATOR DE CARGA PARA O CENÁRIO 5 DA OPERAÇÃO DE PEAK SHAVING

Dia	Pico Máximo			Fator de Carga		
	Sem MR	Com MR	Redução do Pico	Sem MR	Com MR	Porcentagem de melhoria
03/11/2017	325 kW	300 kW	7,69 %	0,60	0,70	16,67 %
04/11/2017	337 kW	300 kW	10,97 %	0,60	0,66	10,00 %
05/11/2017	343,1 kW	300 kW	12,56 %	0,55	0,62	12,73 %
06/11/2017	381,2 kW	300 kW	21,30 %	0,57	0,71	24,56 %
07/11/2017	365,1 kW	300 kW	17,83 %	0,56	0,68	21,43 %
08/11/2017	360,1 kW	300 kW	16,68 %	0,56	0,67	19,64 %
09/11/2017	409,4 kW	300 kW	26,72 %	0,52	0,69	32,69 %

FONTE: O AUTOR (2021)


Com base nos resultados apresentados na TABELA 25, para todos os dias da simulação o pico máximo de demanda da rede principal foi reduzido, sendo que a maior redução foi de 109,4 kW no dia 09/11/2017. Quanto a melhoria do fator de carga, foi observado a melhora no fator de carga do sistema em todos os dias considerados na simulação com a operação da microrrede em modo *peak shaving*.

Com relação a operação do SAE, foi observado uma operação semelhante à dos cenários anteriores para todos os dias considerados no cenário 5. O SAE forneceu potência ativa no horário de maior demanda e absorveu potência ativa logo após o pico de demanda ficar abaixo de 300 kW.

5.2 OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO

Para a análise do desempenho da operação de suavização da geração proposta neste trabalho foram consideradas duas curvas de geração fotovoltaica que apresentam um nível elevado de intermitências devido a fatores climáticos. A FIGURA 57 apresenta as curvas utilizadas nas simulações do MPC para a suavização da geração.

FIGURA 57 - CURVAS DE GERAÇÃO SOLAR UTILIZADAS NAS SIMULAÇÕES DA OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO FOTOVOLTAICA




FONTE: O AUTOR (2021)

A curva de geração 1 da FIGURA 57 apresenta a característica de um dia nublado e chuvoso com poucas aberturas de sol durante o dia. A curva 2 da FIGURA 57 apresenta a característica de um dia com predominância de sol com a presença de nuvens durante o dia. Com isso, o algoritmo de controle MPC foi executado para cada uma das curvas da FIGURA 57 e o resultado do algoritmo foi utilizado nas simulações no *GridLAB-D*. Durante as simulações o estado de carga inicial do SAE foi considerado 50%.


A FIGURA 58 e FIGURA 59 apresentam, respectivamente, o comportamento da potência ativa da rede principal e o estado de carga do SAE para a simulação de suavização da geração fotovoltaica considerando a curva 1 de geração da FIGURA 57.

FIGURA 58 - OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO CONSIDERANDO A CURVA 1 DE GERAÇÃO FOTOVOLTAICA



FONTE: O AUTOR (2021)

FIGURA 59 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO PARA A CURVA 1 DE GERAÇÃO FOTOVOLTAICA



FONTE: O AUTOR (2021)


Conforme a FIGURA 58, a potência ativa da rede principal apresentou um perfil mais suavizado com a aplicação do controle MPC com relação a curva sem a aplicação do controle. Dessa forma, para a curva analisada, o controle MPC foi eficiente em reduzir as variações abruptas que ocorrem na geração fotovoltaica para determinadas condições climáticas. Com relação a operação do SAE, é possível observar pela FIGURA 59 que o estado de carga final é menor do que o estado de carga inicial, ou seja, o SAE descarregou mais energia do que carregou durante a operação de suavização da geração. A TABELA 26 apresenta alguns parâmetros da atuação do SAE para a suavização da geração.

TABELA 26 - PARÂMETROS DA ATUAÇÃO DO SAE DURANTE A OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO

Parâmetro	Valor
SOC Inicial	50%
SOC Final	48,8%
Energia Carregada na Bateria (Lado CC)	43,9 kWh
Energia Descarregada da Bateria (Lado CC)	50,5 kWh
Energia Absorvida pelo SAE (Lado CA)	45,7 kWh
Energia Fornecida pelo SAE (Lado CA)	48,5 kWh

FONTE: O AUTOR (2021)

A FIGURA 60 apresenta os valores de tensão no PAC com a aplicação do controle MPC para a suavização da geração.




FONTE: O AUTOR (2021)

Conforme mostrado na FIGURA 60, não houve mudanças significativas no módulo da tensão no PAC com a aplicação da suavização da geração. Porém, mesmo não havendo mudanças significativas no módulo da tensão, o controle MPC contribuiu para que a curva de tensão no PAC apresentasse um comportamento mais suavizado evitando variações abruptas nos valores de tensão. Além disso, é enfatizado a redução das flutuações de potência demandada pela rede, o que diminui os impactos de variações na rede elétrica.

As mesmas análises realizadas anteriormente foram realizadas para a segunda curva de geração da FIGURA 57 considerando a mesma condição inicial de estado de carga de 50 %. A FIGURA 61 e FIGURA 62 apresentam, respectivamente, o comportamento da potência ativa da rede principal e o estado de carga do SAE para a simulação de suavização da geração fotovoltaica considerando a curva 2 de geração da FIGURA 57.


Conforme o resultado apresentado na FIGURA 61, o controle MPC foi eficiente na suavização da geração fotovoltaica proporcionando uma curva de potência ativa suavizada da rede principal, evitando que ocorram variações abruptas nos valores de potência ativa. Da mesma forma que na análise anterior, o SAE ficou com o estado de carga final menor do que o inicial indicando que a energia carregada no SAE foi menor que a energia descarregada durante a operação de suavização.

FIGURA 61 - OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO CONSIDERANDO A CURVA 2 DE GERAÇÃO FOTOVOLTAICA



FONTE: O AUTOR (2021)

FIGURA 62 - ESTADO DE CARGA DO SAE DURANTE A OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO PARA A CURVA 2 DE GERAÇÃO FOTOVOLTAICA



FONTE: O AUTOR (2021)

A TABELA 27 apresenta alguns parâmetros da atuação do SAE para a suavização da geração.


TABELA 27 - PARÂMETROS DA ATUAÇÃO DO SAE DURANTE A OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO

Parâmetro	Valor
SOC Inicial	50%
SOC Final	48,9%
Energia Carregada na Bateria (Lado CC)	41,4 kWh
Energia Descarregada da Bateria (Lado CC)	47,5 kWh
Energia Absorvida pelo SAE (Lado CA)	43,1 kWh
Energia Fornecida pelo SAE (Lado CA)	45,6 kWh

FONTE: O AUTOR (2021)

A FIGURA 63 apresenta os valores de tensão no PAC com a aplicação do controle MPC para a suavização da geração para a curva de geração 2.

FIGURA 63 - TENSÃO NO PAC COM A OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO FOTOVOLTAICA PARA A CURVA 2 DE GERAÇÃO FOTOVOLTAICA




FONTE: O AUTOR (2021)

Da mesma forma que ocorreu com a curva 1, a operação de suavização da curva 2 não resultou em mudanças significativas nos módulos da tensão no PAC.


A FIGURA 64 e FIGURA 65 apresentam, respectivamente, o comportamento da potência ativa da rede principal e o estado de carga do SAE considerando a operação de suavização da geração durante quatro dias seguidos.

FIGURA 64 - OPERAÇÃO DE SUAVIZAÇÃO DA GERAÇÃO DURANTE O PERÍODO DE QUATRO DIAS



FONTE: O AUTOR (2021)

FIGURA 65 - ESTADO DE CARGA DO SAE PARA A OPERAÇÃO DE SUAVIZAÇÃO DURANTE O PERÍODO DE QUATRO DIAS




FONTE: O AUTOR (2021)

Conforme pode ser observado na FIGURA 64, o controle MPC atuou de forma eficiente para a suavização da geração fotovoltaica durante a operação contínua de quatro dias.

5.3 OPERAÇÃO DE REGULAÇÃO DE TENSÃO

Para avaliar o desempenho do algoritmo MPC para a regulação de tensão no PAC da microrrede abordada neste trabalho foi considerada a curva de carga e de geração fotovoltaica mostradas na FIGURA 66. A curva de carga é uma curva real do alimentador estudado e representa um patamar de carga pesada para o sistema.

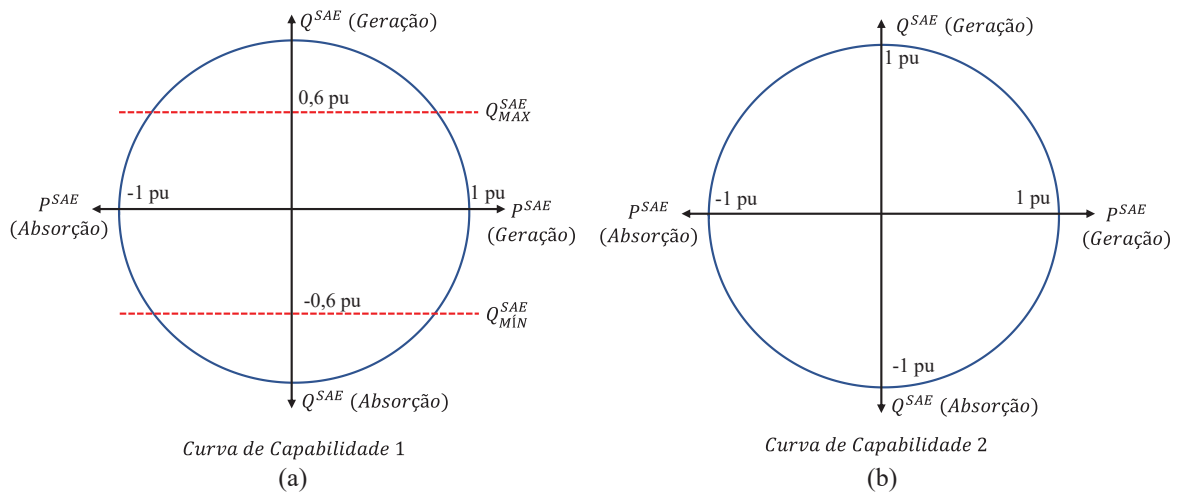
FIGURA 66 - CURVAS DE POTÊNCIA ATIVA E REATIVA DA CARGA E GERAÇÃO FOTOVOLTAICA UTILIZADAS NAS SIMULAÇÕES DA OPERAÇÃO DE REGULAÇÃO DE TENSÃO



FONTE: O AUTOR (2021)

Além da curva de carga mostrada acima, foram consideradas duas curvas de capacidade distintas durante a operação do SAE nas simulações conforme ilustrado na FIGURA 67. Com isso, considerando que diferentes fabricantes estabelecem diferentes curvas de capacidade para o SAE, é possível avaliar o desempenho do algoritmo MPC para a regulação de tensão considerando diferentes características na curva de capacidade. Conforme ilustrado na FIGURA 67, na curva de capacidade 1 a potência reativa fornecida ou absorvida pelo SAE possui um limite máximo de $0,6 pu$ enquanto que na curva de capacidade 2 o limite máximo de potência reativa absorvida ou fornecida pelo SAE é de $1 pu$.

FIGURA 67 - CURVAS DE CAPABILIDADE DO SAE

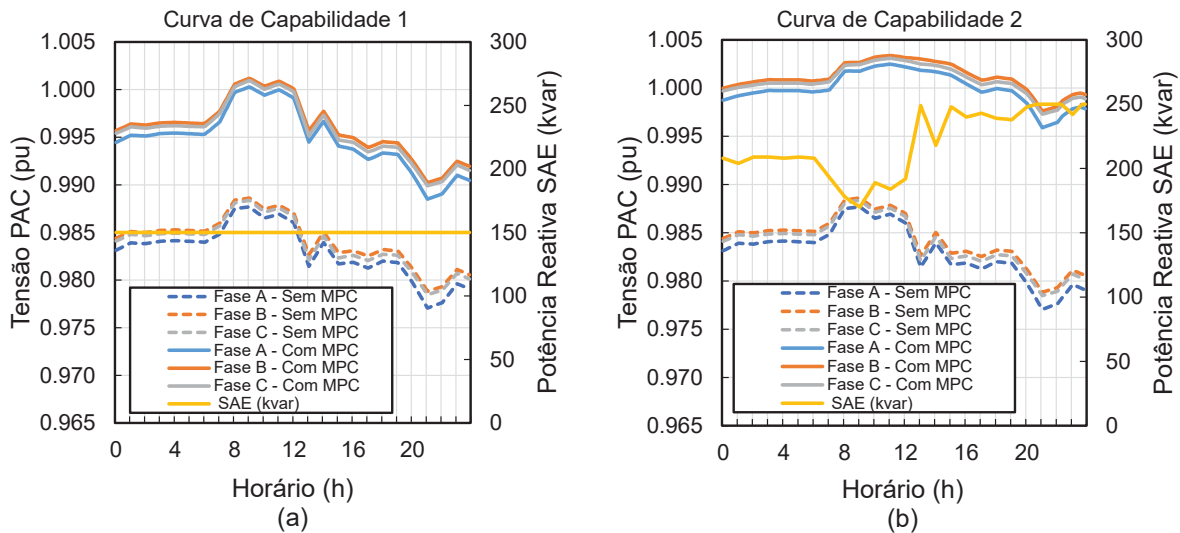


FONTE: O AUTOR (2021)

Regulação de Tensão no PAC

A FIGURA 68 apresenta a tensão no PAC com a aplicação do controle MPC para a operação de regulação de tensão. No mesmo gráfico da FIGURA 68, no eixo direito, é indicado a potência reativa fornecida pelo SAE durante a operação do MPC.

FIGURA 68 - TENSÃO DO PAC E POTÊNCIA REATIVA FORNECIDA PELO SAE PARA A OPERAÇÃO DE REGULAÇÃO DE TENSÃO



FONTE: O AUTOR (2021)

De acordo com a FIGURA 68, é possível observar que o MPC atuou de forma a aproximar a tensão do PAC de 1 pu, ou seja, o SAE forneceu potência reativa para o sistema de forma a aumentar a magnitude de tensão no barramento principal, segundo a característica de *droop* reativo.

Conforme observado na FIGURA 68 (a), para a simulação envolvendo a curva de capacidade 1 do SAE é possível observar que em todos os instantes de tempo o SAE forneceu o máximo possível de reativo para o sistema, ou seja, 150 *kvar*, conforme as limitações operacionais da curva de capacidade 1. Considerando a curva de capacidade 2 para a operação do SAE, é possível observar na FIGURA 68 (b) que o SAE forneceu diferentes níveis de potência reativa para o sistema ao longo da operação da microrrede. Dessa forma, através dos resultados apresentados, o algoritmo de controle MPC utilizando a curva de capacidade 2 apresentou um melhor desempenho na regulação de tensão no PAC visto que existe uma maior disponibilidade de fornecimento de reativo em relação a curva de capacidade 1. Ou seja, o conversor eletrônico é capaz de realizar o controle da magnitude de tensão no seu ponto de acoplamento (de forma local), tendo assim grandes benefícios para qualidade da energia no sistema de distribuição em questão.

A TABELA 28 apresenta a comparação das menores magnitudes de tensão para o sistema com e sem a aplicação do MPC para a regulação de tensão.

TABELA 28 - VALORES MÍNIMOS DE MAGNITUDE DE TENSÃO NO PAC COM A ATUAÇÃO DO MPC.

Fase	Menor Magnitude de Tensão no PAC (<i>pu</i>)			Percentual de Melhoria em relação ao sistema sem MPC	
	Sem MPC	Com MPC		Curva de Capacidade 1	Curva de Capacidade 2
		Curva de Capacidade 1	Curva de Capacidade 2		
A	0,9770	0,9884	0,9958	1,17%	1,92%
B	0,9788	0,9902	0,9976	1,16%	1,92%
C	0,9784	0,9899	0,9972	1,18%	1,92%

FONTE: O AUTOR (2021)


Através dos valores da TABELA 28 é possível observar a melhoria na magnitude de tensão no PAC no caso mais crítico da curva de carga considerada nas simulações, ou seja, no instante em que ocorre o menor valor de tensão. Dessa forma, a atuação do MPC tanto para a curva de capacidade 1 quanto a 2 resultou no aumento na magnitude da tensão, tornando a tensão no PAC mais próxima da tensão nominal do sistema.

Fator de Potência na Rede Principal

Apesar do fator de potência da rede principal não ser considerado na operação da microrrede, o controle MPC proporcionou uma melhoria no fator de potência da rede principal conforme apresentado na FIGURA 69 e na TABELA 29. Isso porque o controle de tensão atua diretamente no suprimento de reativo na rede. Assim, com o balanço de potência

reativa controlado, é possível melhorar o perfil de fator de potência na rede, o que pode trazer grandes benefícios para outras aplicações, com nas indústrias.

FIGURA 69 - FATOR DE POTÊNCIA NA REDE PRINCIPAL COM A ATUAÇÃO DO MPC DURANTE A OPERAÇÃO DE REGULAÇÃO DE TENSÃO



FONTE: O AUTOR (2021)

TABELA 29 - VALORES MÍNIMOS DE FATOR DE POTÊNCIA DA REDE PRINCIPAL COM A ATUAÇÃO DO MPC

Menor Valor de Fator de Potência na Rede Principal		Percentual de Melhoria em relação ao sistema sem MPC		
Sem MPC	Com MPC		Curva de Capabilidade 1	Curva de Capabilidade 2
	Curva de Capabilidade 1	Curva de Capabilidade 2		
0,527	0,946	0,825	79,51%	56,55%


FONTE: O AUTOR (2021)

Conforme apresentado na FIGURA 69 e na TABELA 29, para ambas as curvas de capacidade do SAE ocorreu a melhoria no fator de potência da rede principal. O maior percentual de melhoria no fator de potência ocorreu no horário de maior geração solar, visto que, para a microrrede sem o MPC, a geração solar ocasiona a diminuição da potência ativa da rede principal, porém o mesmo não ocorre com a potência reativa. Com a atuação do MPC para a regulação de tensão, o SAE fornece potência reativa para o sistema ocasionando a diminuição da potência reativa na rede principal e, por consequência, a melhoria no fator de potência.

Perfil de Tensão do sistema

Através da atuação do controle MPC para a regulação de tensão no PAC foi possível observar a melhoria no perfil de tensão do sistema estudado. Dessa forma, foram coletadas as magnitudes de tensão em todas as barras do sistema com a atuação do controle MPC no horário de 21h, visto que nesse horário ocorreu o menor valor de magnitude de tensão no PAC com a atuação do controle MPC. A FIGURA 70 apresenta o perfil de tensão do sistema estudado considerando as curvas de capacidade 1 e 2 do SAE.

FIGURA 70 - PERFIL DE TENSÃO NO HORÁRIO DE 21h. (a) CURVA DE CAPABILIDADE 1. (b) CURVA DE CAPABILIDADE 2



FONTE: O AUTOR (2021)

Através dos resultados apresentados na FIGURA 70 é possível observar a melhoria no perfil de tensão do sistema estudado com a atuação do controle MPC, sendo que em todas as barras do sistema ocorreu a elevação da magnitude de tensão sem ultrapassar os limites operacionais estabelecidos pela regulamentação.

Através dos resultados apresentados na FIGURA 70 foi identificado que o menor valor de tensão no horário de 21h ocorreu na barra 36 do sistema estudado. A TABELA 30 apresenta a melhoria no módulo de tensão da barra 36 com a atuação do controle MPC.

TABELA 30 - VALORES MÍNIMOS DE MAGNITUDE DE TENSÃO NA BARRA 36

Fase	Magnitude de Tensão Barra 36 – horário 21h			Percentual de Melhoria em relação ao sistema sem MPC	
	Sem MPC	Com MPC		Curva de Capabilidade 1	Curva de Capabilidade 2
		Curva de Capabilidade 1	Curva de Capabilidade 2		
Fase A	0,9756	0,9870	0,9944	1,17%	1,93%
Fase B	0,9775	0,9889	0,9963	1,17%	1,92%
Fase C	0,9772	0,9886	0,9960	1,17%	1,92%


FONTE: O AUTOR (2021)

5.4 OPERAÇÃO HÍBRIDA: *PEAK SHAVING* + SUAVIZAÇÃO DA GERAÇÃO + REGULAÇÃO DE TENSÃO

Para avaliar o desempenho do algoritmo MPC para a operação conjunta envolvendo o *Peak Shaving*, a Suavização da Geração Fotovoltaica e a Regulação de Tensão no PAC foi considerada a curva de carga mostrada na FIGURA 66 e a curva de capacidade mostrada na FIGURA 67 (b).


A FIGURA 71 apresenta o resultado da simulação com relação a potência ativa demandada da rede principal pela microrrede com a atuação do MPC.

FIGURA 71 - OPERAÇÃO HÍBRIDA: *PEAK SHAVING* + SUAVIZAÇÃO DA GERAÇÃO + REGULAÇÃO DE TENSÃO



FONTE: O AUTOR (2021)

Conforme apresentado na FIGURA 71, o controle MPC foi eficaz em reduzir as variações na potência ativa da rede principal devido as variações na potência de saída da planta de geração fotovoltaica. Além disso, o SAE atuou na redução do pico de demanda da rede principal fazendo com que a demanda de potência ativa da rede principal não ultrapassasse 300 kW. A FIGURA 72 apresenta o comportamento do SOC durante a operação da microrrede.



Conforme apresentado na figura acima, o SAE foi carregado nas primeiras horas da operação, sendo que o SOC passou de 50% para 74%. No período de geração fotovoltaica o SOC sofreu poucas variações devido as baixas potências e curtos períodos de atuação do SAE para a suavização da geração fotovoltaica. Na sequência, com o aumento da demanda da carga, o SAE atuou de forma a fornecer parte da potência demandada pela carga e proporcionar a redução do pico de demanda da rede principal, sendo que o SOC nesse período passou de 72% para 23% no final da operação. A TABELA 31 apresenta os percentuais de melhoria com relação a redução do pico de demanda e o aumento do fator de carga do sistema com a atuação do MPC.

TABELA 31 - PICO MÁXIMO E FATOR DE CARGA PARA A OPERAÇÃO HÍBRIDA DO MPC

Parâmetro	Sem MPC	Com MPC	Percentuais de Melhorias
Pico Máximo	425,6 kW	300 kW	Redução de 29,52%
Fator de Carga	0,529	0,731	Aumento de 38,19%

FONTE: O AUTOR (2021)

Com relação à regulação de tensão, a FIGURA 73 e a TABELA 32 apresentam os resultados obtidos para a atuação do MPC para a regulação de tensão no PAC e os percentuais de melhoria para o ponto onde ocorreu a menor magnitude de tensão com a atuação do MPC.





TABELA 32 – VALORES MÍNIMOS DE MAGNITUDE DE TENSÃO NO PAC COM A ATUAÇÃO DO MPC PARA A OPERAÇÃO HÍBRIDA.

Fase	Menor Magnitude de Tensão no PAC (pu)		Percentual de Melhoria em relação ao sistema sem MPC
	Sem MPC	Com MPC	
Fase A	0,9770	0,9956	1,90%
Fase B	0,9788	0,9973	1,89%
Fase C	0,9784	0,9970	1,90%

FONTE: O AUTOR (2021)

Com base nos resultados acima, além do *peak shaving* e da suavização da geração, o MPC atuou na regulação de tensão no PAC de forma a aproximar a tensão do valor nominal do sistema. Além disso, conforme apresentado na FIGURA 74 e na TABELA 33 a atuação do MPC para a operação conjunta proporcionou um aumento no fator de potência da rede principal, proporcionando melhorias para o sistema.

FIGURA 74 - FATOR DE POTÊNCIA COM O MPC NA OPERAÇÃO CONJUNTA



FONTE: O AUTOR (2021)


TABELA 33 - VALORES MÍNIMOS DE FATOR DE POTÊNCIA DA REDE PRINCIPAL COM A ATUAÇÃO DO MPC PARA A OPERAÇÃO HÍBRIDA.

Menor Valor de Fator de Potência na Rede Principal		Percentual de Melhoria em relação ao sistema sem MPC
Sem MPC	Com MPC	
0,491	0,854	74,110%

FONTE: O AUTOR (2021)

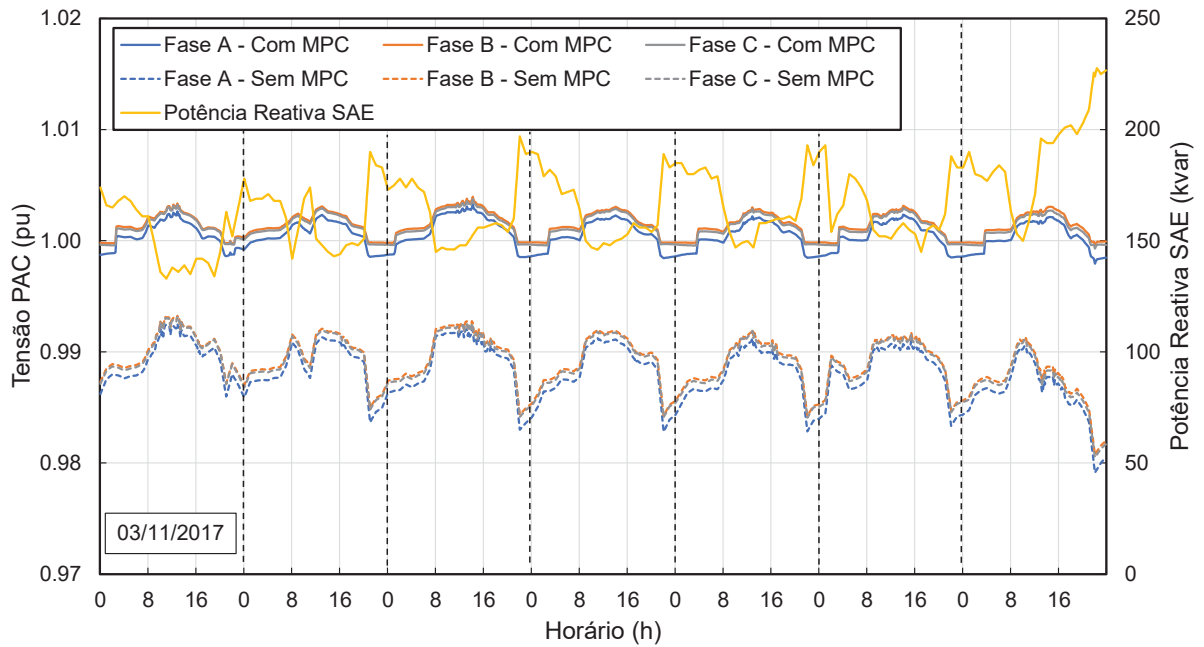
A FIGURA 75 e a FIGURA 76 apresentam os resultados obtidos para a atuação do MPC durante uma operação de 168 horas, ou seja, uma semana. A TABELA 34 e a TABELA 35 apresentam alguns valores numéricos para a atuação do MPC durante o regime de atuação de 168 horas, destacando os valores de redução de pico, fator de carga e magnitude de tensão no PAC com a atuação do controle MPC.

FIGURA 75 - OPERAÇÃO HÍBRIDA DO MPC DURANTE UMA SEMANA



FONTE: O AUTOR (2021)

FIGURA 76 - TENSÃO NO PAC DURANTE A OPERAÇÃO HÍBRIDA DO MPC DURANTE UMA SEMANA



FONTE: O AUTOR (2021)

TABELA 34 – REDUÇÃO DO PICO DE DEMANDA E FATOR DE CARGA DO SISTEMA COM A OPERAÇÃO DO MPC DURANTE 168 HORAS

Dia	Pico Máximo			Fator de Carga		
	Sem MR	com MR	Redução do Pico	Sem MR	Com MR	Percentual de Melhoria
03/11/2017	325 kW	300 kW	7,69%	0,61	0,68	12,31%
04/11/2017	337 kW	300 kW	10,97%	0,59	0,66	11,29%
05/11/2017	343,1 kW	300 kW	12,56%	0,51	0,58	13,22%
06/11/2017	381,2 kW	300 kW	21,30%	0,53	0,67	25,97%
07/11/2017	365,1 kW	300 kW	17,83%	0,58	0,70	22,25%
08/11/2017	360,1 kW	300 kW	16,68%	0,57	0,69	20,94%
09/11/2017	409,4 kW	300 kW	26,72%	0,52	0,70	34,05%

FONTE: O AUTOR (2021)

TABELA 35 – VALORES MÍNIMOS DE MAGNITUDE DE TENSÃO NO PAC COM A ATUAÇÃO DO MPC PARA A OPERAÇÃO HÍBRIDA DURANTE 168 HORAS.

Dia	Sem MPC			Com MPC			Percentual de Melhoria		
	Fase A	Fase B	Fase C	Fase A	Fase B	Fase C	Fase A	Fase B	Fase C
03/11/2017	0,9860	0,9872	0,9870	0,9986	0,9998	0,9996	1,28%	1,28%	1,28%
04/11/2017	0,9837	0,9850	0,9848	0,9985	0,9998	0,9996	1,51%	1,51%	1,51%
05/11/2017	0,9830	0,9843	0,9841	0,9985	0,9998	0,9996	1,58%	1,57%	1,57%
06/11/2017	0,9828	0,9842	0,9841	0,9984	0,9998	0,9996	1,59%	1,58%	1,57%
07/11/2017	0,9828	0,9842	0,9841	0,9985	0,9998	0,9996	1,59%	1,58%	1,57%
08/11/2017	0,9833	0,9847	0,9846	0,9985	0,9998	0,9996	1,54%	1,53%	1,53%
09/11/2017	0,9791	0,9808	0,9805	0,9979	0,9995	0,9993	1,92%	1,91%	1,92%

FONTE: O AUTOR (2021)

Com base nos resultados apresentados, o MPC foi capaz de atuar para diferentes curvas de cargas e diferentes curvas de geração fotovoltaica proporcionando a redução do pico de demanda, a suavização da geração e a regulação de tensão no PAC.

6 CONCLUSÃO

O presente trabalho tratou do estudo e implementação do controle preditivo baseado em modelo (MPC) para a otimização da operação de microrredes que operam conectadas ao sistema elétrico de distribuição. Nesse sentido, foram apresentados os principais conceitos envolvendo microrredes, hierarquia de controle associados à operação de microrredes.

A implementação do controle preditivo baseado em modelo foi realizada considerando três modos de operação da microrrede: *Peak Shaving*, Suavização da Geração Fotovoltaica e Regulação de Tensão.

Através dos resultados obtidos com o controle MPC foi possível avaliar o impacto das ações de controle em um sistema de teste. O sistema de teste utilizado neste trabalho consiste em um sistema de distribuição de energia composto por dois alimentadores de média tensão que foi implementado no *GridLAB-D* utilizando dados reais do sistema de distribuição onde a microrrede será implementada.

A partir dos resultados obtidos para a operação de *Peak Shaving* foi possível demonstrar a efetividade do controle preditivo em promover a redução do pico de demanda do sistema. Os resultados também demonstraram uma melhoria do fator de carga do sistema para diferentes curvas de carga.

Da mesma forma, o controle preditivo implementado com vistas à suavização da geração fotovoltaica foi efetivo em reduzir as intermitências causadas por fatores climáticos durante o período de geração fotovoltaica.

Com relação a regulação de tensão, o controle preditivo atuou de forma que o SAE fornecesse potência reativa para o sistema a fim de aproximar a tensão no Ponto de Acoplamento Comum (PAC) da tensão nominal do sistema. Com os resultados obtidos, foi possível demonstrar a melhoria na magnitude de tensão do PAC.

Por fim, as operações de *Peak Shaving*, Suavização da Geração e Regulação de Tensão foram consideradas simultaneamente em um mesmo problema de otimização. Para esta simulação, o controle preditivo se mostrou eficiente em realizar a redução do pico de demanda, a suavização da geração e regulação de tensão, simultaneamente, para um determinado conjunto de curvas de cargas e com diferentes condições de geração fotovoltaica.

6.1 TRABALHOS FUTUROS

Como sugestões de trabalhos futuros e de aprimoramento da solução proposta neste trabalho, podem ser citados:

- Implementar um modelo de otimização considerando a rede de distribuição, permitindo a análise de fontes de geração e sistemas de armazenamento distribuídos ao longo da rede;
- Implementar um modelo de otimização para a regulação de tensão considerando uma referência de tensão variável que depende do patamar de carga do sistema;
- Incluir a possibilidade de ilhamento da microrrede dentro da estratégia de controle e otimização, considerando um sistema com a presença de cargas críticas e controláveis;

REFERÊNCIAS

- ACKERMANN, T.; ANDERSSON, G.; SÖDER, L. Distributed generation: A definition. **Electric Power Systems Research**, v. 57, n. 3, p. 195–204, 2001. Disponível em: [https://doi.org/10.1016/S0378-7796\(01\)00101-8](https://doi.org/10.1016/S0378-7796(01)00101-8). Acesso em: 04 jan. 2021.
- AHMED, M.; MEEGAHAPOLA, L.; VAHIDNIA, A.; DATTA, M. Stability and Control Aspects of Microgrid Architectures-A Comprehensive Review. **IEEE Access**, v. 8, p. 144730–144766, 2020. Disponível em: <https://ieeexplore.ieee.org/document/9162105>. Acesso em: 04 jan. 2021.
- ABDEL-NASSER, Mohamed; MAHMOUD, Karar. Accurate photovoltaic power forecasting models using deep LSTM-RNN. **Neural Comput & Applic**. Aswan, p. 2727-2740, 2017. Disponível em: <https://link.springer.com/article/10.1007/s00521-017-3225-z>. Acesso em: 10 jan. 2021.
- AGRAWAL, Rahul Kumar; MUCHAHARY, Frankle; TRIPATHI, Madan Mohan. Long term load forecasting with hourly predictions based on long-short-term-memory networks. **2018 IEEE Texas Power and Energy Conference (TPEC)**, p. 1-6, 2018. Disponível em: <http://dx.doi.org/10.1109/tpec.2018.8312088>. Acesso em: 10 fev. 2021.
- ANEEL. **Agência aprova 23 propostas da chamada de P&D sobre armazenamento de energia**. 2017. Disponível em: https://www.aneel.gov.br/sala-de-imprensa-exibicao-2/-/asset_publisher/zXQREz8EVIZ6/content/agencia-aprova-23-propostas-da-chamada-de-p-d-sobre-armazenamento-de-energia/656877. Acesso em: 04 jan. 2021.
- ANEEL. **Nota Técnica nº 0056/2017-SRD/ANEEL: Atualização das projeções de consumidores residenciais e comerciais com microgeração solar fotovoltaicos no horizonte 2017-2024**. 2017. Disponível em: https://www.aneel.gov.br/documents/656827/15234696/Nota+T%C3%A9cnica_0056_PROJE%C3%87%C3%95ES+GD+2017/38cad9ae-71f6-8788-0429-d097409a0ba9. Acesso em: 04 jan. 2021.
- ANEEL. **RESOLUÇÃO NORMATIVA Nº 482, DE 17 DE ABRIL DE 2012**. 2012. Disponível em: <http://www2.aneel.gov.br/cedoc/ren2012482.pdf>. Acesso em: 04 jan. 2021.
- ANEEL. **RANKING NACIONAL DE TARIFAS RESIDENCIAIS (GRUPO B1)**. 2022. Disponível em: <https://www.aneel.gov.br/ranking-das-tarifas>. Acesso em: 01 nov. 2021.
- BAKSHIDEH ZAD, B.; HASANVAND, H.; LOBRY, J.; VALLÉE, F. Optimal reactive power control of DGs for voltage regulation of MV distribution systems using sensitivity analysis method and PSO algorithm. **International Journal of Electrical Power and Energy Systems**, v. 68, p. 52–60, 2015. Elsevier Ltd. Disponível em: <http://dx.doi.org/10.1016/j.ijepes.2014.12.046>. Acesso em: 04 jan. 2021.
- BORDONS, C.; GARCIA-TORRES, F.; RIDAO, M. A. **Model Predictive Control of Microgrids**. 2020.

CGEE. **Prospecção Tecnológica no Setor Elétrico Brasileiro**. 2017. Disponível em: https://www.cgee.org.br/documents/10195/734063/aneel_2017_8-8.pdf/ce6a0ec6-bcd8-4392-9875-435dabaf3566?version=1.3. Acesso em: 04 jan. 2021.

DAZA, Eric Fernando Boeck; SPERANDIO, Mauricio. **Sistemas de Armazenamento de Energia**: desafios regulatórios e econômicos para sua inserção em sistemas de potência. Porto Alegre, 2018.

EPE & MME. **Plano Decenal de Expansão de Energia 2029**. 2020. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/Documents/PDE%202029.pdf>. Acesso em: 04 jan. 2021.

EPE & MME. **PNE 2050 - Plano Nacional de Energia**. 2020. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-227/topico-563/Relatorio%20Final%20do%20PNE%202050.pdf>. Acesso em: 27 dez. 2020.

EPE. **Caderno de Demanda de Eletricidade**. 2018. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-295/Caderno%20de%20Demanda%20de%20Eletricidade.pdf>. Acesso em: 29 dez. 2020.

EPE. **Recursos Energéticos Distribuídos**: Documento de apoio ao PNE 2050. 2019. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-227/topico-457/GT%20PNE%20-%20RED%20-%20Relat%C3%B3rio%20Final.pdf>. Acesso em: 27 dez. 2020.

EPE. **Sistemas de Armazenamento em Baterias**. 2019. Disponível em: https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-441/EPE-DEE-NT-098_2019_Baterias%20no%20planejamento.pdf. Acesso em: 05 jan. 2021.

FARROKHABADI, M *et al.* Microgrid Stability Definitions, Analysis, and Examples. **IEEE Transactions on Power Systems**, v. 35, n. 1, p. 13–29, 2020. Disponível em: <https://ieeexplore.ieee.org/document/8750828>. Acesso em: 05 jan. 2021.

GUERRERO, J. M.; VASQUEZ, J. C.; MATAS, J.; DE VICUÑA, L. G.; CASTILLA, M. Hierarchical control of droop-controlled AC and DC microgrids - A general approach toward standardization. **IEEE Transactions on Industrial Electronics**, v. 58, n. 1, p. 158–172, 2011. Disponível em: <https://ieeexplore.ieee.org/document/5546958>. Acesso em: 05 jan. 2021.

HU, J.; SHAN, Y.; GUERRERO, J. M.; *et al.* Model predictive control of microgrids – An overview. **Renewable and Sustainable Energy Reviews**, v. 136, n. March 2020, p. 110422, 2021. Elsevier Ltd. Disponível em: <https://doi.org/10.1016/j.rser.2020.110422>. Acesso em: 06 set. 2021.

IEEE PES. **IEEE 2030.7-2017 Standard for the Specification of Microgrid Controllers**. 2018. Disponível em: <https://ieeexplore.ieee.org/document/8340204>. Acesso em: 05 jan. 2021.

- IRENA. **Electricity Storage and Renewables: Costs and Markets to 2030**. 2017. Disponível em: https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2017/Oct/IRENA_Electricity_Storage_Costs_2017.pdf. Acesso em: 04 jan. 2021.
- KERSTING, W. H. **Distribution system modeling and analysis**. 2001.
- KUMAR, D.; ZARE, F.; GHOSH, A. DC Microgrid Technology: System Architectures, AC Grid Interfaces, Grounding Schemes, Power Quality, Communication Networks, Applications, and Standardizations Aspects. **IEEE Access**, v. 5, p. 12230–12256, 2017. Disponível em: <https://ieeexplore.ieee.org/document/7937799>. Acesso em: 04 jan. 2021.
- LOPES, J. A. P.; HATZIARGYRIOU, N.; MUTALE, J.; DJAPIC, P.; JENKINS, N. Integrating distributed generation into electric power systems: A review of drivers, challenges and opportunities. **Electric Power Systems Research**, v. 77, n. 9, p. 1189–1203, 2007. Disponível em: <https://doi.org/10.1016/j.epsr.2006.08.016>. Acesso em: 04 jan. 2021.
- LEE, Woonghee *et al.* Forecasting Solar Power Using Long-Short Term Memory and Convolutional Neural Networks. **IEEE Access**, v. 6, p. 73068-73080, 2018. Disponível em: <https://ieeexplore.ieee.org/document/8543793>. Acesso em: 04 jan. 2021.
- LIU, Chang; JIN, Zhijian; GU, Jie; QIU, Caiming. Short-term load forecasting using a long short-term memory network. **2017 IEEE Pes Innovative Smart Grid Technologies Conference Europe (ISGT-Europe)**, p. 1-6, 2017. IEEE. Disponível em: <http://dx.doi.org/10.1109/isgteurope.2017.8260110>. Acesso em: 04 jan. 2021.
- MORENO, R.; MOREIRA, R.; STRBAC, G. A MILP model for optimising multi-service portfolios of distributed energy storage. **Applied Energy**, v. 137, p. 554–566, 2015. Elsevier Ltd. Disponível em: <http://dx.doi.org/10.1016/j.apenergy.2014.08.080>. Acesso em: 04 jan. 2021.
- MALYSZ, P.; SIROUSPOUR, S.; EMADI, A. An optimal energy storage control strategy for grid-connected microgrids. **IEEE Transactions on Smart Grid**, v. 5, n. 4, p. 1785–1796, 2014. Disponível em: <https://ieeexplore.ieee.org/document/6839070>. Acesso em: 04 jan. 2021.
- NARAYAN, Apurva; HIPEL, Keith W. Long short term memory networks for short-term electric load forecasting. **2017 IEEE International Conference on Systems, Man, And Cybernetics (SMC)**, Waterloo, p. 2573-2578, 2017. Disponível em: <https://ieeexplore.ieee.org/document/8123012>. Acesso em: 04 jan. 2021.
- OLIVARES, D. E.; MEHRIZI-SANI, A.; ETEMADI, A. H.; *et al.* Trends in microgrid control. **IEEE Transactions on Smart Grid**, v. 5, n. 4, p. 1905–1919, 2014. Disponível em: <https://ieeexplore.ieee.org/document/6818494>. Acesso em: 04 jan. 2021.
- PEPERMANS, G.; DRIESEN, J.; HAESLONCKX, D.; BELMANS, R.; D'HAESELEER, W. Distributed generation: Definition, benefits and issues. **Energy Policy**, v. 33, n. 6, p. 787–798, 2005. Disponível em: <https://doi.org/10.1016/j.enpol.2003.10.004>. Acesso em: 04 jan. 2021.

- PARISIO, A.; RIKOS, E.; GLIELMO, L. A model predictive control approach to microgrid operation optimization. **IEEE Transactions on Control Systems Technology**, vol. 22, no. 5, p. 1813-1827, 2014. Disponível em: <https://ieeexplore.ieee.org/document/6705582>. Acesso em: 04 jan. 2021.
- PEREZ, F.; LÓPEZ-SALAMANCA, H. L.; DE MEDEIROS, L.; *et al.* Optimal Operation Of An Urban Microgrid Using Model Predictive Control Considering Power Quality Improvements. **Brazilian Archives of Biology and Technology**, v. 64, p. 1–16, 2021. Disponível em: <https://doi.org/10.1590/1678-4324-75years-2021210156>.
- PEREZ, F. Control of AC/DC Microgrids with Renewables in the Context of Smart Grids: Including Ancillary Services and Electric Mobility. 2020. Tese (Doutorado) - Université Paris-Saclay; Universidade federal de Itajuba. 2020.
- PEREZ, F., IOVINE, A., DAMM, G., GALAI-DOL, L. AND RIBEIRO, P.F. Stability analysis of a dc microgrid for a smart railway station integrating renewable sources. **IEEE Transactions on Control Systems Technology**, 28(5), p.1802-1816, 2019. Disponível em: <https://ieeexplore.ieee.org/document/8766869>. Acesso em: 10 nov. 2021.
- SALAMANCA, Henry Leonardo López. Controle e otimização de microrredes em baixa tensão no contexto brasileiro. 2018. 187 f. Tese (Doutorado em Engenharia Elétrica e Informática Industrial) - Universidade Tecnológica Federal do Paraná, Curitiba, 2018.
- SHI, Y.; XU, B.; WANG, D.; ZHANG, B. Using Battery Storage for Peak Shaving and Frequency Regulation: Joint Optimization for Superlinear Gains. **IEEE Transactions on Power Systems**, v. 33, n. 3, p. 2882–2894, 2018. Disponível em: <https://ieeexplore.ieee.org/document/8027056>. Acesso em: 16 jan. 2021.
- SILVA, V. A.; AOKI, A. R.; LAMBERT-TORRES, G. Optimal day-ahead scheduling of microgrids with battery energy storage system. **Energies**, v. 13, n. 19, p. 1–28, 2020. Disponível em: <https://doi.org/10.3390/en13195188>. Acesso em: 16 jun. 2021.
- WANG, Kejun; QI, Xiaoxia; LIU, Hongda. A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network. **Applied Energy**, p. 1-14, 2019. Disponível em: <https://doi.org/10.1016/j.apenergy.2019.113315>. Acesso em: 16 jun. 2021.
- YU, Dukhwan *et al.* Forecasting Day-Ahead Hourly Photovoltaic Power Generation Using Convolutional Self-Attention Based Long Short-Term Memory. **Energies**, p. 1-17, 2020. Disponível em: <https://doi.org/10.3390/en13154017>. Acesso em: 16 jun. 2021.
- ZHENG, Jian *et al.* Electric load forecasting in smart grids using Long-Short-Term-Memory based Recurrent Neural Network. **2017 51St Annual Conference on Information Sciences and Systems (CISS)**, Baltimore, p. 1-6, 2017. Disponível em: <https://ieeexplore.ieee.org/document/7926112>. Acesso em: 16 jun. 2021.
- ZHANG, Y.; SRIVASTAVA, A. Voltage control strategy for energy storage system in sustainable distribution system operation. **Energies**, v. 14, n. 4, p. 1–12, 2021. Disponível em: <https://doi.org/10.3390/en14040832>. Acesso em: 16 jun. 2021.