

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DANILO DE PAULA E SILVA

**GERENCIAMENTO DE UMA MICRORREDE
UTILIZANDO CONTROLE PREDITIVO COM
INCERTEZAS METEOROLÓGICAS**

VITÓRIA-ES

2020

DANILO DE PAULA E SILVA

**GERENCIAMENTO DE UMA MICRORREDE
UTILIZANDO CONTROLE PREDITIVO COM
INCERTEZAS METEOROLÓGICAS**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do título de Doutor em Engenharia Elétrica.

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Orientador: Jussara Farias Fardin

VITÓRIA-ES

2020

Ficha catalográfica disponibilizada pelo Sistema Integrado de Bibliotecas - SIBI/UFES e elaborada pelo autor

D278g de Paula e Silva, Danilo, 1979-
Gerenciamento de uma microrrede utilizando controle preditivo com incertezas meteorológicas / Danilo de Paula e Silva. - 2020.
198 f. : il.

Orientadora: Jussara Farias Fardin.
Tese (Doutorado em Engenharia Elétrica) - Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Geração renovável. 2. Controle preditivo. 3. Energia - Armazenamento. 4. Previsão do tempo. 5. Energia eólica. 6. Energia solar. I. Farias Fardin, Jussara. II. Universidade Federal do Espírito Santo. Centro Tecnológico. III. Título.

CDU: 621.3

DANILO DE PAULA E SILVA

**GERENCIAMENTO DE UMA MICRORREDE
UTILIZANDO CONTROLE PREDITIVO COM
INCERTEZAS METEOROLÓGICAS**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do título de Doutor em Engenharia Elétrica.

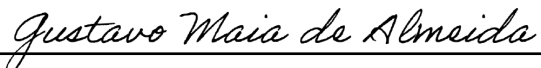
Aprovada em 07 de dezembro de 2020:



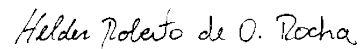
Prof^a.Dra. Jussara Farias Fardin
Universidade Federal do Espírito Santo
Orientadora



Prof. Dr. Edilson Fernandes de Arruda
Universidade Federal do Rio de Janeiro
Examinador



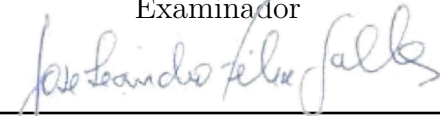
Prof. Dr. Gustavo Maia de Almeida
Instituto Federal do Espírito Santo
Examinador



Prof. Dr. Helder Roberto de Oliveira Rocha
Universidade Federal do Espírito Santo
Examinador



Prof. Dr. Augusto César Rueda Medina
Universidade Federal do Espírito Santo
Examinador



Prof. Dr. José Leandro Félix Salles
Universidade Federal do Espírito Santo
Examinador

Dedico este trabalho à minha esposa Elânia pelo seu amor, apoio incondicional e paciência durante os anos de estudos, aos meus filhos Guilherme e José Vítor que são meus presentes e minha maior motivação e aos meus pais e irmã, José Geraldo, Leila e Mariana pelo constante incentivo e confiança nas minhas realizações ao longo da vida.

Agradecimentos

Agradeço aos professores Jussara Farias Fardin e José Leandro Félix Salles, pelas orientações fornecidas durante o curso e também pelo tempo disponível na publicação de um artigo científico de alto impacto.

Agradeço ao professor Masxuel Rocha Pereira pelo importante apoio na parametrização do modelo de previsão meteorológico e pela disponibilização dos dados que foram fundamentais para esta pesquisa.

Agradeço aos alunos de iniciação científica Jéferson Monteiro, Lilian Naoko, Marcelo Dório e Vinícius Ottz pela dedicação e comprometimento com as atividades de pesquisa que contribuíram diretamente com este trabalho.

Agradeço também ao engenheiros Mestre Guilherme Barbariori e Mestre Débora de Souza Martins que dedicaram parte do seu tempo com contribuições, ideias e sugestões em uma etapa importante da pesquisa.

Agradeço ao apoio financeiro recebido da Fundação de Amparo à Pesquisa do Estado do Espírito Santo (FAPES), projeto nº 67666027 e a autorização do Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo (IFES) para a realização desta pesquisa através do processo 23158.001738 / 2018-33.

No que diz respeito ao empenho, ao compromisso, ao esforço, à dedicação, não existe meio termo. Ou você faz uma coisa bem feita ou não faz.

Ayrton Senna da Silva

Resumo

O gerenciamento de microrredes é um problema que envolve a compra e venda de energia, geração de energia renovável variante no tempo e custos de operação e manutenção. A microrrede pode operar de forma autônoma isolada ou conectada à rede principal. Neste trabalho, propõe-se um modelo original de otimização para a gestão de uma microrrede isolada que considera a conexão automática à rede para fornecer serviços ancilares à rede principal, como a venda do excedente de geração renovável e a compra de energia para carregar o banco de baterias. A otimização proposta é formulada via controle preditivo econômico híbrido através do método da soma ponderada e baseada no horizonte de rolagem. O algoritmo proposto inclui novas restrições para atender a uma regulamentação específica de conexão/desconexão com a rede principal, como o tempo mínimo de conexão/desconexão e o número máximo de conexões. Neste trabalho, também propõe-se um novo modelo híbrido de banco de baterias que inclui a conexão/desconexão da rede principal. Uma plataforma de simulação de uma microrrede em malha aberta foi desenvolvida para integrar cada equipamento como um sistema misto lógico dinâmico que contempla as variáveis contínuas, binárias, inteiras e as restrições operacionais. Os resultados de simulação em malha aberta mostraram que os equipamentos operaram de forma coerente em relação a uma microrrede real. Para o gerenciamento da microrrede, o modelo de otimização proposto com incertezas gaussianas foi testado com erros relativos médios de 15%, 25% e 35% nas variáveis meteorológicas e se mostrou pouco sensível ao aumento da variância. A otimização proposta usando modelo de previsão meteorológico de mesoescala se mostrou sensível ao erro de previsão, que causou variações de 1% na demanda atendida, 27,3% nos custos do banco de baterias e 13,3% nos lucros financeiros. Comparado com a estratégia que utiliza a programação linear inteira mista multi-período e a estratégia baseada em regras, mostrou-se que o modelo de otimização proposto gerencia a microrrede com mais segurança (ou seja, fornece estado de carga abaixo de seu valor crítico durante um período inferior a 25% em relação às outras estratégias). Em locais com alta geração de energia, apenas a otimização proposta obtém lucro com a venda de energia.

Palavras-chave: microrrede, controle preditivo econômico híbrido, gerenciamento, sistemas dinâmicos lógicos mistos, incertezas meteorológicas.

Abstract

Microgrid management is a multi-objective problem that involves purchasing and selling energy, time-variant renewable generation, and maintenance costs. The microgrid can operate autonomously on an island or through mode connected with the main grid. This paper proposes an original optimization model for the management of an isolated microgrid that considers the automatic grid connection to provide ancillary services to the main grid, such as selling the excess renewable generation and purchasing electricity to charge the battery bank. The proposed optimization is formulated via hybrid economic predictive control through the weighted sum method, and based on the rolling horizon. It includes new constraints to meet a specific connection/disconnection regulation, such as the minimum connection/disconnection time and the maximum connection frequency. This paper also proposes a new hybrid model of a battery bank that includes the grid connection/ disconnection. An open-loop microgrid simulation framework was developed for each equipment as a mixed logical dynamical system that includes continuous, binary, integer variables and operational constraints. The results of open-loop simulations show that the equipments operated in a coherent way according to a real microgrid. The proposed algorithm is sensitive to the forecasting error, which causes variations of 1% in the met demand, 27.3% in the battery bank costs, and 13.3% in the financial profits. Compared to multi-period mixed integer linear programming and the rule-based strategy, we show that the proposed controller manages the microgrid more safely (i.e., it provides state of charge below its critical value during a period less than 25% of that offered by other strategies). In locations with high energy generation, only the proposed optimization obtain a profit by selling energy.

Keywords: microgrid, hybrid economic model predictive control, management, mixed logic dynamic system, weather uncertainty.

Lista de ilustrações

Figura 1.1 – Arquitetura típica de uma microrrede.	26
Figura 1.2 – Estrutura hierárquica da microrrede.	27
Figura 2.1 – Autômato híbrido discreto.	45
Figura 2.2 – Mapeamento das variáveis de decisão no espaço das funções objetivo.	51
Figura 2.3 – (a) Exemplo de optimalidade de Pareto; (b) Possíveis relações de dominância em relação à solução do ponto B.	53
Figura 3.1 – Fluxograma de modelagem da Microrrede.	60
Figura 3.2 – Diagrama unifilar de um sistema eólico.	62
Figura 3.3 – Comparativo entre a curva de potência real de uma turbina eólica e a curva de potência obtida por um polinômio interpolador do 4º grau com erro quadrático médio de $6,61 \cdot 10^{-5}$ %.	63
Figura 3.4 – Curva de operação da turbina eólica com controle de passo.	64
Figura 3.5 – Fluxograma de operação do banco de baterias. A equação do SOC é chaveada em função dos modos de operação da MG e se o banco de baterias está carregado ou não.	67
Figura 3.6 – Máquina de estados finita do controlador de carga.	69
Figura 3.7 – O balanço de potência da MG isolada define se o banco de baterias irá carregar ou descarregar.	71
Figura 3.8 – O balanço de potência da MG conectada define se a MG compra ou vende energia da rede principal.	71
Figura 3.9 – Intervalo de tempo máximo de conexão e desconexão da MG.	72
Figura 4.1 – Diagrama de blocos do HEMPC.	83
Figura 5.1 – Diagrama Unifilar da conexão da MG com a rede da UFES.	86
Figura 5.2 – Fluxograma do algoritmo da plataforma de simulação da microrrede.	88
Figura 5.3 – Cenário 1: SOC, modo de conexão da MG e o evento que habilita as cargas.	90
Figura 5.4 – Cenário 1: Geração de potência fotovoltaica e eólica.	91
Figura 5.5 – Cenário 1: Demanda das cargas e balanço de potência.	91
Figura 5.6 – Cenário 1: Estados discretos de operação do banco de baterias. Note que o estado <i>reset</i> carregado gera um pulso para a transição entre os estados carregado e cíclico isolado.	92
Figura 5.7 – Cenário 1: Estados discretos de operação da turbina eólica.	93
Figura 5.8 – Cenário 2: estado da carga do banco de baterias.	94
Figura 5.9 – Cenário 2: Estados discretos de operação do banco de baterias.	94
Figura 5.10 – Cenário 2: Demanda das cargas e balanço de potência.	95
Figura 5.11 – Cenário 2: Variáveis binárias do modo de conexão da MG, habilitação das cargas e compra e venda de energia (0 é compra e 1 é venda de energia).	96

Figura 5.12–Cenário 3: SOC, modo de conexão da MG e o evento que habilita as cargas.	96
Figura 5.13–Cenário 3: Estados discretos de operação do banco de baterias.	97
Figura 5.14–Cenário 3: Demanda das cargas e balanço de potência.	98
Figura 5.15–Cenário 3: Geração de potência fotovoltaica e eólica.	98
Figura 5.16–Cenário 3: Estados discretos de operação da turbina eólica.	99
Figura 5.17–(a) Irradiância, (b) temperatura e (c) curva da velocidade dos ventos em 24 h.	101
Figura 5.18–Curva da irradiância em um dia nublado.	102
Figura 5.19–Potência eólica prevista em comparação com uma distribuição gaussiana normal. Os pontos azuis fora da reta indicam que a potência eólica não tem distribuição Gaussiana	103
Figura 5.20–Tarifas de compra e venda de energia elétrica em 24 h.	103
Figura 5.21–Curvas da demanda real e da demanda prevista que considera que a programação das cargas foi adiada em 2 horas.	104
Figura 5.22–Cenário 1: ênfase na minimização do custo do banco de baterias.	107
Figura 5.23–Cenário 2: prioriza a venda de energia utilizando dados do NOAA.	110
Figura 5.24–Cenário 3: conservação do banco de baterias utilizando os dados do LEAL.	111
Figura 5.25–(a) Curvas de temperatura real e prevista; (b) Erros de previsão de temperatura em uma semana.	116
Figura 5.26–(a) Curvas de irradiância real e prevista; (b) Erros de previsão de irradiância em uma semana.	117
Figura 5.27–(a) Curvas de velocidade dos ventos real e prevista; (b) Erros de previsão de velocidade em uma semana.	118
Figura 5.28–Cenário 1: (a) Estado da carga, modo de conexão da MG; (b) Balanço de potência e potência das RES em uma semana.	120
Figura 5.29–Cenário 1: Demanda real e atendida em uma semana.	120
Figura 5.30–Cenário 2: (a) Estado da carga, modo de conexão da MG; (b) Balanço de potência e potência das RES em uma semana.	121
Figura 5.31–Comparação entre estratégias de gerenciamento da MG em Natal-RN (a) Nível do SOC; (b) Balanço de potência e potência das RES.	124
Figura 5.32–Comparação entre estratégias de gerenciamento da MG em Santa Vitória-RS (a) Nível do SOC; (b) Balanço de potência e potência das RES.	125
Figura C.1–Variação do ponto de máxima potência a partir de mudanças na irradiância e temperatura a cada instante k : P_{MPPT} representa o ponto de operação de (C.3).	171
Figura C.2–Exemplo de curva de potência eólica para turbinas com controle estol.	172
Figura F.1–Fluxograma de obtenção e processamento do conjunto de dados meteo- rológicos e de potência renovável.	182

Lista de tabelas

Tabela 1	– Resumo literário sobre modelagem de MG.	33
Tabela 2	– Resumo literário sobre gerenciamento das MG.	37
Tabela 3	– Referências sobre gerenciamento da MG que utilizam MPC e descrevem as previsões de dados meteorológicos. Variáveis previstas: λ : Irradiância; v : Velocidade dos ventos; T : Temperatura; Dir : Direção do vento.	38
Tabela 4	– Conversão de relações lógicas em inequações inteiras-mistas mais utilizadas.	46
Tabela 5	– Custo de O&M do banco de baterias para diferentes balanços de potência e modos de operação da MG.	80
Tabela 6	– Principais especificações dos equipamentos elétricos da MG.	87
Tabela 7	– Valores numéricos dos parâmetros utilizados na simulação.	89
Tabela 8	– Parâmetros comuns para todos os resultados.	105
Tabela 9	– Valores dos pesos, definidos <i>a priori</i> , para cada Cenário de simulação.	106
Tabela 10	– Sensibilidade dos termos da função objetivo para diferentes valores de MAPE para o Cenário 1.	108
Tabela 11	– Análise de sensibilidade da previsão meteorológica individual e do deslocamento da demanda em 2 horas para o Cenário 1.	109
Tabela 12	– Sensibilidade dos termos da função objetivo para diferentes valores de MAPE para o Cenário 1 com uma tendência positiva de 15%.	109
Tabela 13	– Sensibilidade dos termos da função objetivo para diferentes valores de MAPE para o Cenário 2.	110
Tabela 14	– Sensibilidade dos termos da função objetivo para diferentes valores de MAPE para o Cenário 3.	112
Tabela 15	– Parâmetros comuns para todos os resultados.	114
Tabela 16	– Valores numéricos dos pesos para cada Cenário de simulação.	115
Tabela 17	– Valores numéricos dos parâmetros para cada localização com sua condição meteorológica específica.	115
Tabela 18	– Coeficientes de correlação entre potência e dados meteorológicos.	118
Tabela 19	– Valores estatísticos da potência renovável e erros de previsão meteorológica em Santa Vitória do Palmar-RS.	119
Tabela 20	– Valores estatísticos da potência renovável e erros de previsão meteorológica em Natal-RN.	119
Tabela 21	– Sensibilidade dos termos da função objetivo com relação aos erros de previsão para os Cenário 1 e 2 em uma semana.	123
Tabela 22	– Comparação do desempenho do HEMPC com as estratégias MILPm e RBS.	126

Tabela 23 – Comparação dos índices de segurança operacional da microrrede entre as estratégias HEMPC, MILPm e RBS.	126
Tabela 24 – Custo computacional entre iterações para diversos horizontes de previsão.	127
Tabela 25 – Variável auxiliar $z_{pv}(k)$ que representa uma combinação linear do SAS em (3.4).	143
Tabela 26 – Variáveis auxiliares $z_w(k)$ da turbina eólica que representam uma combinação linear do SAS em (3.10).	144
Tabela 27 – Variáveis auxiliares $z_s(k)$ do SOC que representam uma combinação linear do SAS em (3.13).	145
Tabela 28 – Variáveis auxiliares $z_{p1}(k)$ e $z_{p2}(k)$	146
Tabela 29 – Variáveis auxiliares $z_L(k)$ para n_c cargas controláveis.	147
Tabela 30 – Variável auxiliar $z_{pva}(k)$ que representa uma combinação linear do SAS em (C.5).	171
Tabela 31 – Variáveis auxiliares $z_w(k)$ da turbina eólica com controle estol.	173
Tabela 32 – Variáveis da base de dados brutos gerada pelo código do modelo WRF.	183

Lista de abreviaturas e siglas

ADP	<i>Approximating Dynamic Programming</i> - Programação Dinâmica Aproximada
ANEEL	Agência Nacional de Energia Elétrica
ANN	<i>Neural Artificial Network</i> - Redes Neurais Artificiais
CHP	<i>Combined Heat and Power</i> - Sistemas que Combinam Calor e Potência
DHA	<i>Discrete Hybrid Automata</i> - Autômato Discreto Híbrido
EG	<i>Event Generator</i> - Gerador de Eventos
EMPC	<i>Economic Model Predictive Control</i> - Controle Preditivo Econômico
EMS	<i>Energy Management System</i> - Sistema de Gerenciamento de Energia
ESS	<i>Energy Storage Systems</i> - Sistemas de Armazenamento de Energia
FSM	<i>Finite State Machine</i> - Máquina de Estados Finitos
HMPC	<i>Hybrid Model Predictive Control</i> - Controle Preditivo Híbrido
HEMPC	<i>Hybrid Economic Model Predictive Control</i> - Controle Preditivo Econômico Híbrido
HYSDEL	<i>HYbrid System DEscription Language</i>
LEAL	Laboratório de Energias Alternativas
MILP	<i>Mixed Integer Linear Programming</i> - Programação Linear Inteira Mista
MIQP	<i>Mixed Integer Quadratic Programming</i> - Programação Quadrática Inteira Mista
MIQCQP	<i>Mixed Integer Quadratically Constrained Quadratic Program</i>
MG	<i>Microgrid</i> - Microrrede
MLD	<i>Mixed Logical Dynamic Systems</i> - Sistemas Dinâmicos Lógicos Mistos
MPC	<i>Model Predictive Control</i> - Controle preditivo Baseado em Modelo
MPPT	<i>Maximum Power Point Tracking</i> - Rastreamento do Ponto de Máxima Potência

MS	<i>Model selector</i> - Seletor de Modos
NOAA	<i>National Oceanic and Atmospheric Administration</i> - Centro Nacional de Administração Oceânica e Atmosférica dos Estados Unidos
NMIP	<i>Nonlinear Mixed Integer Programming</i> - Programação Não Linear Inteira Mixta
NP	<i>Nonlinear Programming</i> - Programação Não Linear
O&M	Operação e Manutenção
PC	<i>Personal Computer</i> - Computador Pessoal
PCC	Ponto de Conexão Comum
PV	<i>Photovoltaic Panel</i> - Painel Fotovoltaico
PWA	<i>Piecewise Afine Systems</i> - Sistemas Afins por Partes
QP	<i>Quadratic Programming</i> - Programação Quadrática
RES	<i>Renewable Energy Resources</i> - Fontes Renováveis
SAS	<i>Switch Afine Systems</i> - Sistema Comutado por Partes
SCADA	<i>Supervisory Control and Data Acquisition</i>
SMILP	<i>Stochastic Mixed Integer Linear Programming</i> - Programação Linear Inteira Mista Estocástica
SMPC	<i>Stochastic Model Predictive Control</i> - Controle Preditivo Híbrido Estocástico
SOC	<i>State Of Charge</i> - Estado de Carga
SP	<i>Stochastic Programming</i> - Programação Estocástica
SS	<i>Space State</i> - Espaço de Estados
UC	<i>Unit Commitment</i>
UFES	Universidade Federal do Espírito Santo

Sumário

1	INTRODUÇÃO	25
1.1	Estado da Arte	28
1.1.1	Controle primário	29
1.1.2	Controle secundário	29
1.1.3	Revisão bibliográfica - modelagem da microrrede	33
1.1.4	Revisão bibliográfica - gerenciamento da microrrede	34
1.2	Motivação e Justificativa	38
1.3	Objetivos e Contribuições da Tese	39
1.3.1	Objetivos específicos	39
1.4	Organização do Trabalho	41
2	FUNDAMENTAÇÃO TEÓRICA	43
2.1	Sistemas Híbridos	43
2.1.1	Autômato híbrido discreto - DHA	44
2.1.2	Sistemas dinâmicos lógicos mistos - MLD	45
2.1.3	Modelos HYSDEL	46
2.2	Controle Preditivo Baseado em Modelo - MPC	46
2.2.1	Controle preditivo híbrido - HMPC	47
2.2.2	Controle preditivo econômico - EMPC	49
2.3	Otimização Multiobjetivo	50
2.3.1	Métodos de solução	54
2.3.1.1	Métodos clássicos	54
2.3.1.2	Métodos de solução evolutivos	54
2.4	Modelos de Previsão Meteorológicos	55
2.4.1	Modelo WRF	56
2.5	Discussão	57
3	MODELAGEM DOS EQUIPAMENTOS E CONDIÇÕES OPERACIONAIS DA MICRORREDE	59
3.1	Geração Fotovoltaica	60
3.2	Geração Eólica	62
3.3	Banco de Baterias	65
3.4	Cargas Elétricas	67
3.5	Controlador de Carga	68
3.6	Tarifas de Energia	69
3.7	Balanco de potência	70

3.8	Condições Operacionais de Conexão e Desconexão da MG	71
3.9	Discussão	75
4	PROBLEMA DE OTIMIZAÇÃO	77
4.1	Formulação da Função Objetivo	77
4.1.1	Banco de baterias	78
4.1.2	Tarifas de energia	80
4.1.3	Desconforto causado pelo corte de cargas	81
4.1.3.1	Restrições	81
4.2	Controle Preditivo Econômico Híbrido	81
4.2.1	Algoritmo HEMPC	83
4.3	Discussão	84
5	RESULTADOS NUMÉRICOS E ANÁLISES	85
5.1	Integração dos Modelos e Simulação da MG	85
5.1.1	Cenários de simulação	90
5.1.2	Discussão dos resultados da simulação em malha aberta	90
5.2	Gerenciamento da MG	100
5.2.1	HEMPC com incertezas meteorológicas gaussianas	100
5.2.1.1	Análise dos dados meteorológicos previstos	101
5.2.1.2	Curva das tarifas de energia	103
5.2.1.3	Curva de demanda	104
5.2.1.4	Cenários de simulação	105
5.2.1.5	Discussão dos resultados da simulação	106
5.2.2	HEMPC com incertezas utilizando modelo meteorológico não gaussiano	112
5.2.2.1	Análise dos dados meteorológicos	115
5.2.2.2	Simulação dos cenários	119
5.2.2.3	Análise de sensibilidade do HEMPC em relação aos erros de previsão	121
5.2.2.4	Comparação do algoritmo proposto com outras estratégias de gerenciamento	123
5.2.3	Custo computacional	126
6	CONCLUSÕES	129
6.1	Trabalhos Futuros	131
	REFERÊNCIAS	133
	APÊNDICE A – MODELAGEM MLD	143
A.1	Geração Fotovoltaica	143
A.2	Geração Eólica	143
A.3	Banco de Baterias	144

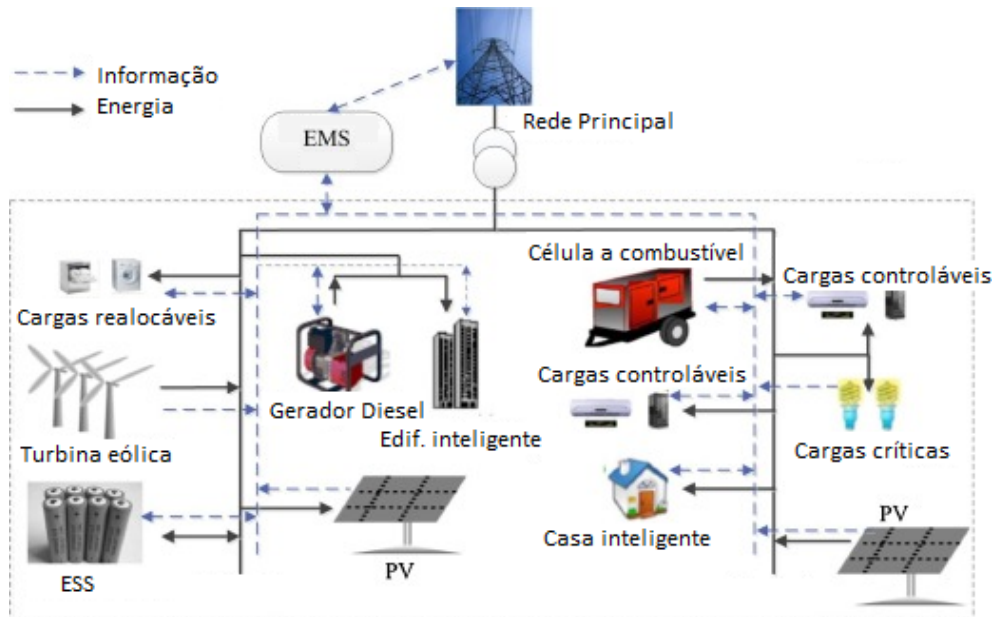
A.4	Controlador de Carga	145
A.5	Tarifas de Energia	146
A.6	Cargas Eléctricas	146
	APÊNDICE B – MATRIZES NUMÉRICAS MLD	149
B.1	Painéis Fotovoltaicos	149
B.2	Turbina Eólica	151
B.3	Banco de Baterias	155
B.4	Controlador de Carga	163
B.5	Tarifas de Energia	165
B.6	Cargas Eléctricas	167
	APÊNDICE C – MODELOS ALTERNATIVOS	169
C.1	Geração Fotovoltaica	169
C.2	Turbina Eólica com Controle Estol	172
C.3	Banco de Baterias	173
	APÊNDICE D – ALTURA DA TURBINA EÓLICA	177
	APÊNDICE E – ESTRATÉGIA BASEADA EM REGRAS (RBS)	179
	APÊNDICE F – CONJUNTO DE DADOS METEOROLÓGICOS PREVISTOS E MEDIDOS	181
F.1	Descrição dos Dados	181
F.1.1	Dados brutos	183
F.1.1.1	Base de dados diária	183
F.1.1.2	Base de dados meteorológicos medidos	183
F.1.2	Dado filtrados, processados e convertidos	184
F.1.2.1	Base de dados WRF	184
F.1.2.2	Base de dados meteorológicos	184
F.1.2.3	Base de dados de temperatura, irradiância e velocidade dos ventos	185
F.1.2.4	Base de dados das potências fotovoltaica e eólica	185
F.2	Metodologia de Obtenção dos Dados	185
	APÊNDICE G – DESCRIÇÃO DOS MODELOS DHA NO HYSDEL	187
G.1	Painéis Fotovoltaicos	187
G.2	Turbina Eólica	188
G.3	Banco de Baterias	190
G.4	Controlador de Carga	192
G.5	Tarifas de Energia	193
G.6	Cargas Eléctricas	194

	APÊNDICE H – PRODUÇÃO CIENTÍFICA	197
H.1	Artigo em Periódico Indexado Internacional Padrão Capes	197
H.2	Trabalhos Completos Publicados em Eventos Internacionais	197
H.3	Trabalhos Completos Publicados em Eventos Nacionais	197
H.4	Base de Dados Meteorológicos	197
H.5	Trabalhos Prontos para Submissão	198

1 Introdução

Tecnologias baseadas nas fontes de geração de energia renovável (RES - *Renewable Energy Resources*) tais como turbina eólica, painéis fotovoltaicos (PV - *Photovoltaic Panel*) e células a combustível tornaram-se essenciais para o desenvolvimento econômico do mundo a fim de atender à crescente demanda por energia sustentável. As energias renováveis registraram a maior participação na produção de energia primária na União Europeia em 2018 (28,4%) (EUROSTAT, 2019). Do total de energia renovável produzida, 57,0% correspondia à geração fotovoltaica e eólica. Os Estados Unidos produziram 4,18 trilhões de quilowatt-hora de eletricidade e a geração de RES correspondeu a 19 % da energia total produzida em 2019 (EIA, 2019). A geração de RES na China aumentou 6% em 2019 quando comparado a 2018 (RES WORLD, 2019). No Brasil, 9,9% de sua energia total produzida (467 GWh) em 2018 corresponde à geração eólica e fotovoltaica (ENERGETIC RESEARCH COMPANY, 2018). Esse crescimento no uso de energia renovável em todo o mundo aumentou as incertezas relacionadas aos sistemas de energia elétrica devido à geração intermitente de energia renovável. Neste cenário, a Microrrede (*Microgrid* - MG) é uma abordagem promissora (LIANG; ZHUANG, 2014; NOSRATABADI; HOOSHMAND; GHOLIPOUR, 2017) pela sua capacidade de funcionar com fluxo de potência bidirecional e podem operar de forma autônoma isolada ou conectada com a rede principal. Uma MG típica, mostrada na Figura 1.1, é formada por cargas elétricas críticas, realocáveis e controláveis, sistema de armazenamento de energia (*Energy Storage System* - ESS), edificações inteligentes, RES de diversos tipos e geração a combustível fóssil. Todos os componentes da MG são interligados por um ponto de conexão comum que é ligado à rede principal. A MG possui também uma rede de comunicação e automação capaz de adquirir dados dos equipamentos e componentes para proteção e gerenciamento através de um sistema de gerenciamento de energia (*Energy Management System* - EMS). Segundo Nosratabadi, Hooshmand e Gholipour (2017), as principais características das MG são descritas a seguir:

Figura 1.1 – Arquitetura típica de uma microrrede.



Fonte: Traduzido de (NOSRATABADI; HOOSHMAND; GHOLIPOUR, 2017)

- podem operar conectadas ou isoladas da rede principal, controlando a conexão;
- geralmente necessitam de um ESS;
- dependem de inovação especialmente em *hardware* e eletrônica de potência de inversores de frequência e sistemas de chaveamento;
- seus componentes são fixos e alocados em uma área física específica; e
- enfrentam obstáculos legais e políticos para sua conexão com a rede principal (BELLIDO et al., 2018). No Brasil, as normas do regulador do setor elétrico não permitem isolar as MG da rede principal (ANEEL, 2012).

Há várias configurações de MG, por exemplo, uma casa inteligente que possua geração distribuída e opere de forma autônoma; a estação brasileira Comandante Ferraz localizada na Antártida que possui geração térmica e elétrica, energia solar, energia eólica, caldeira e cargas elétricas que necessitam de gerenciamento (CHRISTO et al., 2019); o condomínio *Alphaville* em Fortaleza-CE que possui geração solar, geração eólica e ESS capazes de fornecer energia a 21 residências (MELO, 2016). Além dos benefícios econômicos e sustentáveis de se utilizar RES e plantas que combinam calor e potência (*Combined Heat and Power - CHP*), outras vantagens das MG incluem (LIANG; ZHUANG, 2014):

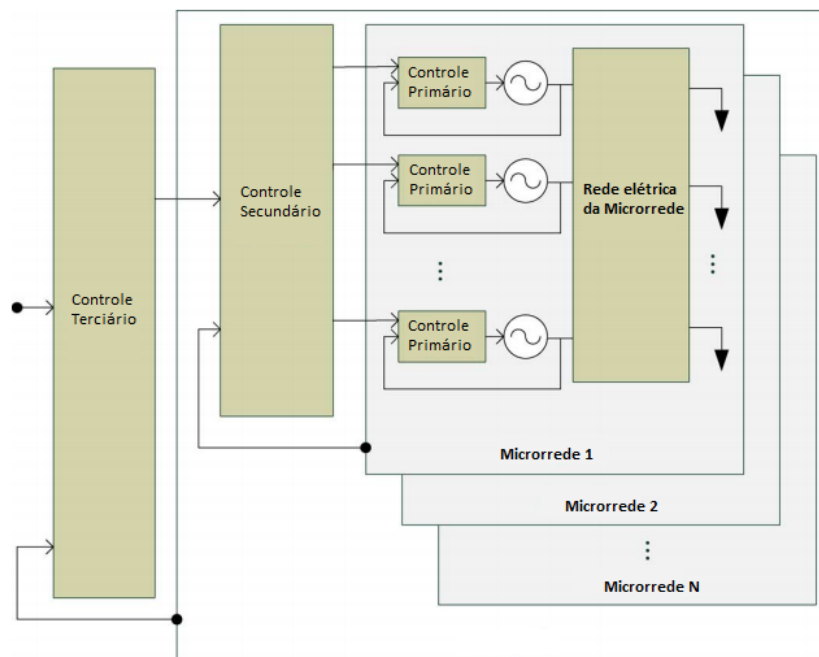
- redução das perdas elétricas por transmissão, pois as RES ficam no mesmo espaço geográfico que as cargas;
- maior confiabilidade, pois uma MG pode se isolar da rede principal caso haja uma falha da rede principal; e

- através de um gerenciamento eficiente, as MG podem vender energia para a rede principal e oferecer serviços ancilares de redução do pico de demanda nos sistemas de transmissão e distribuição.

O controle da MG advém de duas abordagens: controle centralizado e descentralizado. Olivares et al. (2014) definiram uma hierarquia de três níveis de controle da MG (ver Figura 1.2): primário, secundário e terciário. Cada nível se diferencia por:

- taxa de atualização dos dados de operação. Quanto mais alto for o nível de controle, menor será a velocidade e a taxa de atualização; e
- requisitos de infraestrutura tais como topologia, tipos de previsão, redes de comunicação para monitoramento e gerenciamento, perfil do consumidor, estabilidade de tensão e frequência, proteção dos sistemas elétricos, interface com o mercado de compra e venda de energia, entre outros.

Figura 1.2 – Estrutura hierárquica da microrrede.



Fonte: Traduzido de (OLIVARES et al., 2014).

O nível de controle primário tem como requisitos (OLIVARES et al., 2014):

- estabilizar a tensão e frequência;
- oferecer capacidades de conexão em tempo real (*plug and play*) entre gerações distribuídas de pequeno porte, compartilhando a energia ativa e reativa entre elas; e

- mitigar correntes circulantes que possam causar sobrecorrentes nos dispositivos de eletrônica de potência.

O nível de controle secundário compensa os desvios de tensão e frequência causados pelo nível de controle primário. Também referenciado como sistema de gerenciamento de energia da MG, o controle secundário é responsável pela confiabilidade, segurança e operação econômica das MG tanto em modo isolado como conectado à rede principal. Este controle é desafiador em redes isoladas com muitas fontes de energia intermitentes.

O nível terciário é o nível de supervisão com respostas mais lentas. Considera conceitos econômicos da operação ótima das MG e gerencia o fluxo de potência entre a MG e a rede principal. A MG conectada pode gerenciar o fluxo de potência pelo ajuste de amplitude e frequência das tensões das gerações distribuídas de pequeno porte. Em algumas abordagens o controle terciário faz parte da rede principal e não propriamente da MG (OLIVARES et al., 2014).

1.1 Estado da Arte

Para garantir os benefícios que as MG podem oferecer, um sistema de gerenciamento de energia eficaz deve ser previsto. Geralmente os objetivos do gerenciamento incluem minimização dos custos operacionais, maximização das gerações de energia das RES, redução das emissões e garantia da confiabilidade da MG. A operação da MG envolve duas funções primordiais (LIANG; ZHUANG, 2014):

- engajamento unitário (*Unit Commitment* - UC) geralmente é executado de um dia a uma semana para frente no tempo. UC geralmente é um problema de otimização inteira mista. O objetivo é determinar a escala ótima de geradores controláveis de modo a satisfazer uma série de restrições do sistema (JABBARI-SABET; MOGHADDAS-TAFRESHI; MIRHOSEINI, 2016); e
- despacho econômico: geralmente é executado de poucos minutos a uma hora a frente no tempo para tomar decisões rápidas de operação das fontes de energia controláveis, cargas e conexão com a rede principal, visando minimizar os custos de energia e de operação e manutenção (O&M).

Várias pesquisas sobre controle e gerenciamento de MG, com ênfase nos controles primário e secundário mostrados na Figura 1.2, estão sendo desenvolvidas com diversas abordagens. O controle terciário, por ser considerado parte da rede elétrica principal (OLIVARES et al., 2014), não será tratado neste trabalho. O restante desta Seção apresenta, sob a perspectiva da MG, um panorama geral dos níveis de controle primário e secundário.

1.1.1 Controle primário

1. Controle da saída do inversor. Consiste em uma realimentação externa para controle de tensão e uma realimentação interna para regulação de corrente. Abordagens típicas utilizam o controlador proporcional-integral com controle de alimentação direta (*feed-forward*).
2. Controle de potência compartilhada (*load sharing*). Esta abordagem pode ou não utilizar as técnicas de controle *droop*. Utiliza também um sistema de controle central que pode ser considerado como parte do controle centralizado.

1.1.2 Controle secundário

Atualmente no controle secundário são investigados as seguintes características da MG:

1. despacho ótimo. Todos os estados de operações possíveis são analisados *a priori* e o despacho ótimo é calculado e armazenado em uma tabela acessada em tempo real. Produz uma resposta instantânea quando as condições do sistema mudam;
2. ordem ou oferta (*bidding*). A informação sobre funções de custo e os limites das gerações distribuídas são transferidas para a central de controle com o intuito de otimizar as ordens de compra e venda de energia;
3. abordagem não baseada em modelos. Nem sempre os métodos de controle baseados em um modelo são adequados para promover uma operação flexível de modos de conexão. Neste caso as estratégias mais utilizadas são baseadas em lógica *fuzzy*;
4. ESS. Pode ser usado para manter as unidades de geração distribuída operando na sua máxima eficiência de despacho e evitar desperdícios de energia contra incertezas de geração RES intermitente (ZÉPHYR; ANDERSON, 2018), (GRILLO; PIEVATOLO; TIRONI, 2016);
5. comunicações. O novo padrão IEC 61850 pode ser aplicado no nível de Controle Secundário da MG. Pode ser implementado em redes TCP/IP. Este padrão define modelos abstratos que podem ser mapeados por diversos protocolos como *generic object oriented substation events* e *manufacturing message specification*;
6. controle preditivo baseado em modelo (*Model Predictive Control - MPC*). O MPC é uma técnica de controle avançada que se caracteriza por fazer um tratamento natural de processos com limitações físicas dos atuadores, restrições sobre variáveis controladas, característica multivariável e ação de controle antecipada sobre as perturbações do sistema (ALMEIDA; SALLES, 2016);
7. modelos de previsão e incertezas meteorológicas. As RES geram energia elétrica através de variáveis meteorológicas de natureza aleatória. Modelos de previsão estocásticos, algoritmos inteligentes ou uma abordagem híbrida são algumas das

- soluções para melhorar a exatidão dos modelos de previsão de dados meteorológicos para calcular a potência prevista das RES (MA; MA, 2017), (AGÜERA-PÉREZ et al., 2018);
8. modelos de previsão e incertezas de demanda. A demanda de energia elétrica é afetada por diversos fatores, tais como o comportamento humano e as condições meteorológicas. Os modelos de previsão de demanda são abordados com técnicas similares às de previsão meteorológica;
 9. otimização estocástica. Quando, em um sistema dinâmico, há variáveis e distúrbios que são aleatórios. O problema do controle ótimo estocástico consiste em minimizar o valor esperado de uma função custo sujeita a restrições de um modelo estocástico e uma formulação dos estados que incorpora a probabilidade de violação das restrições (HEIRUNG et al., 2018);
 10. Programação dinâmica aproximada (*Approximating Dynamic Programming - ADP*). Devido à sua natureza sequencial, problemas de agendamento de energia podem ser resolvidos via ADP, capazes de obter bons resultados de otimização com custo computacional menor em relação à programação dinâmica (ZÉPHYR; ANDERSON, 2018).

Dentro do controle secundário, Nosratabadi, Hooshmand e Gholipour (2017) fizeram uma revisão bibliográfica sobre o problema de agendamento de energia da MG e das plantas de potência virtual. Sob o ponto de vista do uso de técnicas de otimização, vários tipos de abordagens são classificadas:

- programação linear (HAWKES; LEACH, 2009);
- programação não linear (SHUAI et al., 2018);
- programação quadrática (GARCIA-TORRES; BORDONS, 2015);
- programação linear inteira mista (SILVENTE et al., 2015);
- métodos probabilísticos e séries temporais (AGÜERA-PÉREZ et al., 2018);
- decomposição de relaxamento lagrangiano (Logenthiran; Srinivasan, 2009);
- programação dinâmica (LIANG et al., 2013);
- árvore de decisão (MOUTIS; HATZIARGYRIOU, 2015);
- estrutura orientada a serviços baseado em eventos (SUCIC et al., 2011);
- método da convolução (Lo Prete et al., 2012);
- matriz de prioridades de conexão (BAE; KIM, 2008);
- malha de busca direta adaptativa (MOHAMED; KOIVO, 2010); e
- modelo de restrição ao acaso utilizando lógica *fuzzy* (FAN; AI; PIAO, 2016).

Os mesmos autores classificam os estudos de incertezas em MG para os seguintes parâmetros:

- programação de chegada e saída de veículos elétricos (HONARMAND; ZAKARIA-ZADEH; JADID, 2014);
- potência solar (AGÜERA-PÉREZ et al., 2018);
- potência eólica (AGÜERA-PÉREZ et al., 2018);
- dados meteorológicos (AGÜERA-PÉREZ et al., 2018);
- sistemas de armazenamento de energia (GARCIA-TORRES; BORDONS, 2015); e
- demanda (AGÜERA-PÉREZ et al., 2018).

Os autores também fizeram um estudo do estado da arte da confiabilidade da MG relacionada ao despacho econômico.

[...] A avaliação da confiabilidade nos problemas de agendamento é um procedimento que enfatiza a confiabilidade no gerenciamento do ciclo de vida da energia da geração distribuída. A confiabilidade no sistema de potência descreve a capacidade do sistema ou componente de agir sob condições estabelecidas por um determinado período de tempo. Este aspecto do sistema é expresso como a probabilidade de falha, a frequência de falha ou expresso em termos de uma probabilidade derivada de confiabilidade, disponibilidade e capacidade de manutenção (NOSRATABADI; HOOSMAND; GHOLIPOUR, 2017) (tradução nossa).

Assim estes autores resumem os tipos de índices de confiabilidades aplicados ao estudo do despacho econômico de MG:

- frequência média de interrupção do sistema (BELLIDO et al., 2018);
- duração média de interrupção do sistema (BELLIDO et al., 2018);
- índice de melhoria de confiabilidade (PRASAI et al., 2010);
- duração média de interrupção do consumidor (RESENDE; CARDOSO, 2019);
- índice de unidades consumidoras com tensão crítica (RESENDE; CARDOSO, 2019);
- probabilidade de desconexão das cargas; e
- custos de manutenção (PARISIO; RIKOS; GLIELMO, 2014).

O estado da arte do despacho econômico da MG contempla a formulação do problema de emissão de gases nocivos ao meio ambiente (MOGHIMI et al., 2013), a estabilidade da tensão e frequência (MOHAMED; MOHAMMED, 2013) e a potência reativa (BRACCO et al., 2014).

Do ponto de vista da abordagem baseada em modelos, Fontenot e Dong (2019) fizeram uma revisão bibliográfica do estado da arte da modelagem dos principais equipamentos da MG, a qual é descrita resumidamente a seguir:

- cargas térmicas modeladas pelo método do circuito RC (XUE et al., 2014);

- cargas residenciais modeladas de acordo com sua classificação: críticas, programáveis e descartáveis (ZAKARIAZADEH; JADID; SIANO, 2014);
- painéis fotovoltaicos modelados por equações lineares e não-lineares que dependem da irradiância e temperatura ambiente (LI; ROCHE; MIRAOU, 2017);
- turbinas eólicas modeladas por equações não lineares, modelos de aproximação linear e polinomial que dependem da velocidade dos ventos (JABBARI-SABET; MOGHADDAS-TAFRESHI; MIRHOSEINI, 2016);
- sistemas de armazenamento de energia são modeladas por equações lineares do estado da carga e equações não lineares que consideram o estado da carga e a tensão de circuito aberto (KRIETT; SALANI, 2012);
- veículos elétricos modelados de forma similar aos sistemas de armazenamento de energia. Notadamente, Igualada et al. (2014) apresentam um novo conceito chamado ansiedade de autonomia. A ansiedade de autonomia refere-se ao medo que os usuários de veículos elétricos sentem de ficar sem energia antes de chegar ao destino;
- sistemas de geração com biomassa modelados por equações que dependem da eficiência da planta e do volume de biomassa (WANG et al., 2016); e
- geradores a diesel e microturbinas modelados em termos de sua potência, a qual não pode exceder as capacidades mínima e máxima. Além disso a taxa de inclinação da potência (*droop*) dos geradores não pode ser excedida (ABEDINI; MORADI; HOSSEINIAN, 2016).

Na maioria dos casos tais modelagens contemplam restrições operacionais que estão associadas a um chaveamento de dinâmicas, como por exemplo a potência eólica onde as equações mudam em função do valor da velocidade do vento. Uma das técnicas usadas para se obter modelos dos equipamentos de uma MG é considerar todas as restrições físicas dos sistemas reais, representar o comportamento das variáveis contínuas (ex. corrente, energia, potência) e das variáveis lógicas ou binárias (ex. cargas ligadas/desligadas, MG conectada/isolada da rede principal). Tais modelos têm características de sistemas híbridos (ANTSAKLIS, 2000), ou seja, possuem dinâmicas representadas por variáveis reais e binárias. Por outro lado, as informações meteorológicas são de grande importância para o planejamento da MG. As RES são intermitentes por natureza devido às condições meteorológicas variantes no tempo. Erros de previsão meteorológica oriundas da dificuldade em modelar de forma precisa os dados atmosféricos são uma das causas das incertezas da operação de MG. Dentro da abordagem de modelagem e gerenciamento das MG, é feita, a seguir, uma revisão bibliográfica de publicações mais recentes sobre o assunto, apresentado abaixo.

1.1.3 Revisão bibliográfica - modelagem da microrrede

Magro et al. (2018) propõem um simulador em tempo real capaz de monitorar a MG através de um supervisor. Os circuitos de potência da MG são simulados e conectados ao sistema real (*hardware in the loop*). O simulador roda no *Simulink* e manda dados para o PLC. Durana e Barambones (2018) propõem uma modelagem simplificada (*technology-free*) de equipamentos de uma MG aplicada no gerenciamento pelo lado da demanda. Um modelo com várias MG é proposto por Zhang et al. (2018). Os autores formulam um modelo que considera a correlação estocástica entre geração e demanda de MG diferentes. Hanna et al. (2017) avaliam a modelagem e implementação de três diferentes tipos de MG do ponto de vista tecnológico e regulatório. Foram feitos estudos de viabilidade econômica das tarifas de energia, preço do gás natural e do custo de emissão de poluentes. Um comparativo entre as MG - grande edificação comercial, infraestrutura crítica para aquecimento e um *campus* universitário - mostra o impacto das políticas públicas e do mercado de energia na implementação de MG. Domenech et al. (2018) realizam um estudo de viabilidade para a implementação de um sistema de distribuição para interligar vários vilarejos isolados. Os autores avaliam a confiabilidade, estabilidade, eficiência e a redução de custos das MG interligadas. Marinelli et al. (2014) propõem o a estratégia MPC em uma MG. Os autores desenvolveram modelos PV e eólico no *Simulink* que utilizam dados meteorológicos. Zhu e Hill (2017) formulam um modelo matemático de MG composto por geração distribuída com cargas inteligentes denominadas *electric springs*. Os autores investigam a estabilidade do modelo proposto. Os barramentos das gerações e cargas inteligentes possuem controle *droop* de tensão e frequência do lado da demanda. A Tabela 1 mostra mais detalhes de cada artigo, exceto da publicação de Zhu e Hill (2017), no qual o modelo é puramente matemático e sem uso de *software* e equipamentos reais da MG.

Tabela 1 – Resumo literário sobre modelagem de MG.

REFERÊNCIAS	ABORDAGEM	SOFTWARES	OPERAÇÃO	CONTROLE	EQUIPAMENTOS ¹									
					WT	PV	CHP	PS	DG	GG	TH	MT	ESS	
(MAGRO et al., 2018)	Simulação em tempo real; Controle em tempo real através de um PLC	Matlab/ Simulink; ETAP; SCADA; HIL	Isolado	Secundário/ Terciário	X	X			X					X
(DURANA; BARAMBONES, 2018)	Gerenciamento pelo lado da demanda; Modelo Marcoviano; Tecnologia livre	Anylogic; Java; GRETA	Conectado	Secundário	X	X		X				X	X	
(ZHANG et al., 2018)	Método Par-Cópula; correlação; processos estocásticos.	Não informa	Conectado/ Isolado	Terciário	X	X						X	X	
(HANNA et al., 2017)	Otimização exata; DER-CAM ²	GAMS; CPLEX	Conectado/ Isolado	Secundário/ Terciário	X	X	X			X	X			X
(DOMENECH et al., 2018)	Otimização exata	CPLEX	Isolado	Secundário	X	X								X
(MARINELLI et al., 2014)	Previsões das RES;	MATLAB	Conectado	Secundário	X	X								X

¹ WT: Turbina Eólica; PV: Painéis Fotovoltaicos; PS: *Pumped Storage*; DG: Gerador a Diesel; GG: Gerador a Gás; TH: Térmico; MT: Microturbina; ESS: Sistema de Armazenamento de Energia.

² Modelo de adoção de consumidores de geração distribuída (*Distributed Energy Resources Customer Adoption Model*)

1.1.4 Revisão bibliográfica - gerenciamento da microrrede

As tomadas de decisão em um problema de otimização de despacho econômico visam obter a quantidade de energia renovável que pode ser fornecida para atender as cargas e determinar quando e qual a quantidade de energia pode ser vendida ou comprada da concessionária e quando a MG pode se conectar e desconectar da rede. Diversas técnicas de otimização foram usadas para resolver o problema do despacho econômico na MG nos últimos 5 anos (MAKHADMEH et al., 2019), podendo-se destacar o algoritmo genético (ELSIED et al., 2016; KUMAR; USHAKUMARI, 2018), os algoritmos evolucionários (WASILEWSKI, 2018), o algoritmo de mercado de câmbio (*exchange market algorithm*) (GAZIJAHANI; SALEHI, 2018), algoritmo de evolução diferencial (SHARMA; PANIGRAHI, 2018) e os algoritmos enxame de partículas *PSO - particle swarm optimization* (HERATH et al., 2019; HOSSAIN et al., 2019). Além destes, pode-se mencionar algoritmos de otimização exato através da Programação Linear Inteira Mista (*Mixed Integer Linear Programming - MILP*) (LIU et al., 2017; LI; XU, 2018), MILP com horizonte de rolagem, (SILVENTE et al., 2015; MARQUANT; EVINS; CARMELIET, 2015; SILVENTE GEORGIOS M. KOPANOS; PAPAGEORGIU, 2018) e o MPC.

Outros trabalhos na literatura sobre o problema do despacho econômico consideram a MG operando nos modos conectado e desconectado da rede principal. Alramlawi, Gabash e Li (2017) desenvolveram uma estratégia de gerenciamento ótimo de um sistema de bateria com painéis fotovoltaicos sob desligamentos programados da rede, usando um algoritmo genético multiobjetivo. Os instantes de falta de energia elétrica são conhecidos *a priori* e após as suas ocorrências realiza-se a desconexão forçada do sistema PV-bateria. No entanto, caso ocorressem falhas imprevisíveis seria mais eficaz e seguro fazer o gerenciamento automático da desconexão. Romero-Quete e Garcia (2019) apresentam um modelo computacional para auto-validação, usada para modelar incertezas chamada de aritmética afim (*Affine arithmetic*) baseada no MPC. O objetivo é gerenciar uma MG que combina calor e potência nos modos conectado ou desconectado da rede principal. Neste trabalho avaliam-se o desempenho da MG operando em cada um dos dois cenários (isolado ou conectado), porém não consideram o gerenciamento automático da conexão e desconexão da MG. Em locais onde a unidade consumidora possui uma alta probabilidade de interrupções na rede principalmente devido à baixa qualidade dos serviços (RESENDE; CARDOSO, 2019), é conveniente e viável que a MG permaneça no modo isolado da rede principal e que possua a autonomia de, eventualmente, se conectar à rede e oferecer serviços ancilares, como regulação de tensão, redução do pico de demanda e filtragem harmônica. Durante a conexão com a rede principal, a MG pode vender o excesso de geração de energia renovável para evitar o desperdício de energia na resistência de dissipação (*dump load*) (ISMAIL et al., 2015) quando o banco de baterias está carregado.

A previsão de dados meteorológicos é muito importante para o gerenciamento

ótimo da microrrede, pois estas informações meteorológicas determinam a potência gerada de energia renovável (SILVENTE GEORGIOS M. KOPANOS; PAPAGEORGIOU, 2018), e a demanda térmica e elétrica (KHAKIMOVA et al., 2015), (PARISIO et al., 2015). A associação de estratégias de controle realimentado e de técnicas de previsão nas variáveis de decisão no problema de despacho econômico são motivos para o sucesso do MPC no gerenciamento das microrredes. No entanto, alguns trabalhos que utilizam MPC como por exemplo (PARISIO; RIKOS; GLIELMO, 2014), ignoram os dados meteorológicos. Nestes trabalhos as soluções obtidas se baseiam em representações ideais das condições de trabalho da MG e não abordam possíveis contingências derivadas da operação em sequências reais de cenários meteorológicos. Alguns artigos que usam MPC comentam sobre a necessidade de se realizar a previsão, mas deixam em segundo plano as informações sobre as técnicas de previsão de dados meteorológicos e os efeitos dos erros de previsão nos resultados obtidos (KHAKIMOVA et al., 2015), (OLAMA; MENDES; CAMACHO, 2018), (BRUNI et al., 2016). Outros trabalhos, ao invés de usar dados meteorológicos, preferem lidar somente com dados históricos de potência para obter a geração de energia renovável (ROMERO-QUETE; GARCIA, 2019), (GU et al., 2017), (CLARKE; MANZIE; BREAR, 2017), (PEREIRA; Muñoz de la Peña; LIMON, 2017), (ZHENG; LI; TAN, 2017), (PARISIO; RIKOS; GLIELMO, 2016).

É difícil fazer a previsão de potência fotovoltaica somente através de dados históricos de potência devido ao efeito do sombreamento nos painéis fotovoltaicos. No entanto, melhores resultados de previsão de energia fotovoltaica são obtidos executando previsões de irradiância através de técnicas que detectam dias ensolarados, dias nublados e dias chuvosos (AGÜERA-PÉREZ et al., 2018) e por técnicas estocásticas utilizando, por exemplo, cadeia de Markov (GRILLO; PIEVATOLO; TIRONI, 2016). Outro fato desafiador é o efeito da saturação da potência eólica quando a velocidade do vento está abaixo da velocidade mínima (*cut-in*) ou excede a velocidade de corte (*cut-off*) durante um longo intervalo de tempo, causando uma forte não linearidade nas séries temporais de potência eólica. Portanto, os modelos de previsão da potência requerem o uso de técnicas não lineares, como por exemplo modelos baseados em máquinas de vetor de suporte (*support vector machine*) (ESEYE; ZHANG; ZHENG, 2018) ou de técnicas estocásticas. Zéphyr e Anderson (2018) geraram vários vetores de previsão de potência eólica, através de um modelo multivariável auto-regressivo, para resolver o problema de agendamento de potência via programação dinâmica estocástica aproximada. Assim estes modelos têm características específicas que dependem do gerador de energia renovável já instalado na MG. A vantagem da previsão de potência renovável usando dados históricos de potência, é que os modelos usando rede neurais podem fornecer previsões de potência renovável muito precisas (GAO et al., 2019).

Por outro lado, a vantagem em se utilizar dados meteorológicos para previsão de geração de energia renovável, de cargas elétricas e térmicas é a possibilidade de prever os distúrbios de variações bruscas de temperatura, irradiância e umidade, que podem

afetar no gerenciamento da MG. Outra vantagem é a possibilidade de utilização de modelos meteorológicos de mesoescala, como o *Weather Research and Forecasting Model* (WRF)(SKAMAROCK et al., 2019) para a geração de dados dinâmicos e termodinâmicos da atmosfera, sem a necessidade de instalação física de estações meteorológicas de superfície. Nesse caso, o WRF permite realizar estudos de viabilidade técnica aplicada em qualquer localidade, com base nas coordenadas geográficas da localização atual, ou de instalação futura da MG. Entretanto, a pura aplicação e uso indiscriminado de modelos numéricos podem produzir resultados distantes da realidade se a calibração do modelo e a representação dos processos físicos atuantes na região forem incorretos. Para evitar estas deficiências, o WRF deve ser ajustado corretamente. Para isto, pesquisas em andamento estão sendo realizadas reunindo conhecimentos que viabilizem uma análise crítica das simulações obtidas por este modelo de previsão.

A Tabela 2 mostra um resumo das pesquisas sobre gerenciamento de MG. Dentre as 18 publicações listadas:

- 72% das MG operam conectadas, 11% operam isoladas e 17% operam nos dois modos;
- somente 28% das publicações detalham as previsões; e
- 77% das publicações utilizam o MPC e suas variações.

Tabela 2 – Resumo literário sobre gerenciamento das MG.

Referências	Abordagem ³	Formulação Matemática ³	Operação	Controle	Detalhamento da previsão?
(PARISIO; GLIELMO, 2013)	SMPC de dois estágios com otimização exata.	SP, MILP	Conectado	Secundário	Não
(LIANG et al., 2013)	ADP, Monte Carlo, resposta em demanda	Equação de Bellman	Conectado	Terciário	Não
(PATINO; MARQUEZ; ESPINOSA, 2014)	EMPC	MIQP	Conectado	Secundário	Não
(PARISIO; RIKOS; GLIELMO, 2014)	EMPC, Modelagem MLD	MIQP	Conectado	Secundário	Não
(KHAKIMOVA et al., 2015)	HMPC, Modelagem MLD	MILP	Conectado e isolado	Secundário	Parcialmente
(SILVENTE et al., 2015)	Otimização exata com Horizonte de rolagem	MILP	Conectado	Secundário/Terciário	Não
(GARCIA-TORRES; BORDONS, 2015)	EMPC, Modelagem MLD	MIQP e MILP	Conectado	Secundário	Sim
(OLIVARES J. D. LARA; KAZERANI, 2015)	Controle de dois estágios com horizonte de rolagem	SMILP (1º estágio) NP (2 estágio)	Isolado	Secundário	Sim
(PARISIO; RIKOS; GLIELMO, 2016)	SMPC, Modelo de Markov	SP, MILP	Conectado	Secundário	Não
(BRUNI et al., 2016)	MPC e SMPC	MIQP e SMIQP	Isolado	Secundário	Parcialmente
(PEREIRA; Muñoz de la Peña; LIMON, 2017)	EMPC robusto	QP	Conectado	Secundário	Não
(GHANBARIAN et al., 2017)	MPC, Otimização exata	MIQP	Conectado e isolado	Primário	Não
(ZHENG; LI; TAN, 2017)	HCMPC MPC distribuído	NMIP	Conectado	Secundário/Terciário	Não
(GU et al., 2017)	MPC, Operação online	LP	Conectado	Secundário	Não
(CLARKE; MANZIE; BREAR, 2017)	EMPC	MILP	Conectado	Secundário	Não
(OLAMA; MENDES; CAMACHO, 2018)	LHMPC, HMPC Modelagem MLD	Função Lyapunov quadrática MIQCQP	Conectado	Secundário	Não
(SHUAI et al., 2018)	ADP, Monte Carlo	NP, Equação de Bellman	Conectado	Secundário	Não
(SILVENTE GEORGIOS M. KOPANOS; PAPAGEORGIOU, 2018)	Horizonte de rolagem estocástico Otimização exata	SP, MILP	Conectado	Secundário	Parcialmente
(ROMERO-QUETE; GARCIA, 2019)	MPC, Aritmética afim	MILP	Conectado e isolado	Secundário	Não

³ ADP: Programação Dinâmica Aproximada; EMPC: Controle Preditivo Econômico; HMPC: Controle Preditivo Híbrido; LHMPC: HMPC Lyapunov; SMPC: Controle Preditivo Estocástico; HCMPC: Controle Preditivo Cooperativo Híbrido; MLD: Sistemas Dinâmicos Lógicos Mistos; NP: Programação Não Linear; NP: Programação Estocástica; QP: Programação Quadrática; MIQP: Programação Quadrática Inteira Mista; SMILP: Programação Linear Inteira Mista Estocástica; NMILP: Programação

A Tabela 3 é um filtro da Tabela 2 e considera somente as referências sobre gerenciamento da MG que utilizam MPC e suas variações, as quais descrevem total ou parcialmente a previsão de dados meteorológicos.

Tabela 3 – Referências sobre gerenciamento da MG que utilizam MPC e descrevem as previsões de dados meteorológicos. Variáveis previstas: λ : Irradiância; v : Velocidade dos ventos; T : Temperatura; Dir : Direção do vento.

Referências	Np ⁴ (h)	Resolução (min)	Fonte dos dados	λ	T	v	Dir.	Processamento	Incerteza
(GARCIA-TORRES; BORDONS, 2015)	24	60	Arbitrária	x	x	x	x	ANN ⁴ , ARIMA ⁴	Menor que 15%
(OLIVARES J. D. LARA; KAZE- RANI, 2015)	24	60	Externa (v) e local (λ)	x		x		WRF (v), persistência (λ e índice de céu limpo)	
(KHAKIMOVA et al., 2015)	120	30	Local	x	x				Perfeita
(BRUNI et al., 2016)	1	1	Externa	x	x				Distribuição normal
(SILVENTE GEOR- GIOS M. KOPANOS; PAPAGEORGIU, 2018)	24	30	Arbitrária			x			Distribuição normal

1.2 Motivação e Justificativa

Considerando o estudo bibliográfico realizado, observa-se poucos artigos que usam o MPC no gerenciamento da MG e fazem a previsão de dados meteorológicos para obter a previsão de potência renovável. Garcia-Torres e Bordons (2015) fizeram o gerenciamento de uma MG conectada à rede através do controle preditivo híbrido (*Hybrid Model Predictive Control* - HMPC). Os autores utilizaram redes neurais artificiais em conjunto com modelos ARIMA para prever dados de irradiância, temperatura, velocidade do vento, umidade e direção do vento. Apesar deste artigo apresentar com detalhes o modelo MLD do sistema de armazenamento de energia, os modelos de energia solar e eólica para conversão de dados meteorológicos em potência não são detalhados e o HMPC não é capaz de conectar e desconectar a MG da rede principal. Silvente Georgios M. Kopanos e Papageorgiou (2018) consideraram a incerteza na previsão da velocidade do vento usando o método máximo-mínimo (AGÜERA-PÉREZ et al., 2018) e formularam o problema de otimização MILP combinado com o horizonte de rolagem e a programação estocástica. No entanto, os autores modelam somente a geração eólica usando dados meteorológicos e a MG estudada está sempre conectada na rede principal. Khakimova et al. (2015) desenvolveram o controle da temperatura de uma sala através do HMPC usando dados de irradiância

Não Linear Inteira Mista; MIQCQP: Programação Quadrática com Restrições Quadraticamente Inteira Mista.

⁴ Np: Horizonte de planejamento; ANN: Redes neurais artificiais; ARIMA: auto-regressivo integrado de média móvel.

e temperatura externa da localidade onde a MG está instalada. Os autores usam a programação estocástica para modelagem da previsão da irradiância afim de obter a potência solar. Porém, apresentam somente o modelo de potência solar usando dados de irradiância e não formulam o HMPC para gerenciar a conexão e desconexão da MG com a rede principal. Olivares J. D. Lara e Kazerani (2015) formularam o problema MILP estocástico que utiliza o algoritmo MPC para gerenciar uma MG isolada. O artigo descreve o modelo de previsão WRF combinado com técnicas estatísticas para prever a velocidade do vento e fazem a previsão de irradiância usando as técnicas persistente e índice de céu limpo para irradiância (PALMA-BEHNKE et al., 2013). Os autores obtêm os modelos de previsão das potências solar e eólica mas não fazem o gerenciamento de conexão e desconexão da MG com a rede de energia.

1.3 Objetivos e Contribuições da Tese

O objetivo geral deste trabalho é desenvolver um modelo original de otimização utilizando o controle preditivo econômico híbrido (*Hybrid Economic Model Predictive Control* - HEMPC) para a gestão de uma microrrede isolada que permita a conexão automática à rede para fornecer serviços ancilares à rede principal, como a venda do excedente de geração renovável e a compra de energia para carregar o banco de baterias. O despacho econômico da MG é formulado como um problema multiobjetivo utilizando o método da soma ponderada utilizando a abordagem *a priori*. O algoritmo utiliza dados meteorológicos para realizar previsão de potência das fontes renováveis.

O algoritmo proposto pressupõe que a MG tenha autonomia de decisão para realizar conexões e desconexões com a rede principal, oferecendo e recebendo serviços da concessionária, como carregar o banco de baterias. Além disso, esta abordagem pertence ao nível de controle secundário, mostrado na Figura 1.2, responsável pela confiabilidade, segurança e operação econômica das MG através do EMS. O EMS é uma estrutura de controle centralizado que otimiza o despacho econômico da MG de acordo com as informações do ESS, previsão de RES, tarifas de energia e cargas elétricas e térmicas (EL-HENDAWI et al., 2018).

1.3.1 Objetivos específicos

1. desenvolver modelos híbridos que podem ser aplicados a um determinado tipo de equipamento da MG, utilizando as classes autômato híbrido discreto (*Discrete Hybrid Automata* - DHA) e MLD. Estes modelos incluem os dois modos de operação da MG: isolado e conectado à rede principal;
2. Modelar as condições de conexão e desconexão da MG com a rede principal;

3. implementar uma plataforma de simulação de operação em malha aberta para validar a operação e o funcionamento de cada equipamento utilizando especificações de uma MG real;
4. formular a função objetivo considerando as restrições de capacidade, modos de operação dos equipamentos e as condições de conexão da MG com a rede principal;
5. propor dados de previsão meteorológicos utilizando dados históricos com erros de previsão hipotéticos com distribuição gaussiana;
6. gerar dados de previsão meteorológicos de duas localidades diferentes através do modelo WRF;
7. utilizar os modelos MLD das RES para converter dados meteorológicos em potência renovável;
8. comparar o algoritmo proposto com duas estratégias de gerenciamento da MG encontradas na literatura.

Para facilitar o entendimento do leitor sobre os objetivos específicos, são apresentadas as definições dos sistemas híbridos DHA e MLD. DHA (BEMPORAD; TORRISI; MORARI, 2001) é um sistema dinâmico que descreve a evolução temporal de um conjunto de variáveis binárias (ou discretas) e reais (ou contínuas). MLD é uma estrutura de modelagem que possibilita a descrição de várias classes de sistemas, como sistemas com entradas e estados mistos (discretos e contínuos), máquinas de estados a elementos finitos (autômatos) dirigidos por eventos relacionados a dinâmicas contínuas, sistemas com saídas qualitativas e sistemas afins por partes (*Piecewise Affine Systems - PWA*) (BEMPORAD; MORARI, 1999).

Considerando a revisão bibliográfica apresentada neste capítulo, enumera-se a seguir as principais contribuições originais desta Tese:

1. formulação da função objetivo considerando dois modos operacionais da MG, isto é, isolado e conectado com a rede principal, possibilitando a compra ou venda energia, evitando o desperdício do excesso de energia renovável na resistência de dissipação;
2. formulação de restrições associadas ao intervalo de tempo mínimo para a MG permanecer conectada à rede ou isolada e ao número máximo de conexões da rede durante um intervalo de tempo;
3. desenvolvimento do modelo híbrido PV usando a estrutura MLD com dados meteorológicos de irradiância e temperatura;
4. utilização de um modelo de previsão global WRF de dados meteorológicos para calcular as previsões de potência PV e eólica; e
5. detalhamento da modelagem da turbina eólica obtido através da abordagem DHA.

Em relação à originalidade, é importante observar que a modelagem híbrida do painel solar PV proposta nesta Tese é baseada na equação do circuito equivalente (KANG;

PARK, 2011). Porém, alguns modelos de painel PV encontrados na literatura calculam a potência através de equações teóricas que dependem da área dos painéis (YAN; ABBES; FRANCOIS, 2017), irradiância, temperatura, velocidade dos ventos, latitude e longitude (MARINELLI et al., 2014). No entanto, estes trabalhos não consideram a saturação de potência PV. A vantagem dos modelos híbridos em relação a equações teóricas que fornecem a potência é que podem converter alguns tipos de não linearidades em proposições lógicas, as quais podem incluir as restrições do modelo e considerar variáveis contínuas e binárias. Shi et al. (2014) propõem o modelo híbrido de uma turbina eólica e o controle preditivo híbrido para aprimorar o desempenho da turbina eólica em função do ângulo de passo e torque eletromecânico. Contudo, estes autores não apresentam a modelagem da turbina eólica com os detalhes apresentados nesta Tese. Outros modelos híbridos propostos nesta Tese (cargas, tarifa de energia) foram baseados em trabalhos anteriores (PARISIO; RIKOS; GLIELMO, 2014; OLAMA; MENDES; CAMACHO, 2018; PARISIO; RIKOS; GLIELMO, 2016) e foram detalhados usando a abordagem DHA e MLD. Considerando a originalidade do trabalho, esta Tese permitiu a publicação de artigos descritos no Apêndice H.

1.4 Organização do Trabalho

- No primeiro capítulo foi abordado uma contextualização do estudo ressaltando a relevância da MG no desenvolvimento sustentável através de fontes renováveis. São abordadas as particularidades e as problemáticas existentes sobre gerenciamento de MG. Por fim, são descritos os objetivos e as contribuições da Tese;
- o segundo Capítulo apresenta os conceitos elementares de sistemas híbridos com foco no DHA, sistemas MLD e no controle preditivo híbrido. Também são descritos a teoria básica de otimização multiobjetivo e métodos de solução. Por fim este Capítulo faz uma breve definição de previsão meteorológica com ênfase no modelo WRF;
- o terceiro Capítulo propõe a modelagem de cada equipamento da MG utilizando DHA e a modelagem das condições de conexão e desconexão da MG com a rede principal;
- o Capítulo 4 apresenta a formulação da função objetivo e a definição do controle preditivo econômico híbrido;
- o Capítulo 5 apresenta os resultados em três estudos de casos. No primeiro caso é proposta uma plataforma de simulação da MG em malha aberta. O segundo estudo apresenta o gerenciamento da MG através do HEMPC utilizando dados históricos com erros de previsão gaussianos e uma análise de sensibilidade entre a previsão perfeita e a previsão com erros de distribuição gaussiana. O terceiro estudo de caso trata do gerenciamento da MG utilizando o modelo WRF para a previsão dos dados meteorológicos em duas localidades distintas. Esse estudo apresenta uma análise de sensibilidade do HEMPC e o comparativo deste algoritmo com duas

estratégias de gerenciamento: MILP multi-período e uma heurística baseada em regras (*Rule-Based-Strategy* - RBS); e

- o Capítulo 6 descreve a conclusão da Tese.

2 Fundamentação Teórica

Neste capítulo, apresentam-se os fundamentos da teoria utilizada nesta Tese para desenvolver o algoritmo de simulação e gerenciamento da MG. Na primeira seção apresenta-se o conceito de sistemas híbridos e a ferramenta computacional usada na simulação. Na Seção 2.2 define-se o problema de controle preditivo clássico e as abordagens de controle preditivo de sistemas híbridos e controle preditivo econômico. Na seção 2.3 define-se a otimização multiobjetivo e apresenta os principais métodos de solução. Na seção 2.4 descreve-se as categorias de obtenção dos dados e apresenta a ferramenta computacional usada na previsão dos dados meteorológicos.

2.1 Sistemas Híbridos

A terminologia híbrida é associada a sistemas como forma de classificar aqueles que combinam o comportamento contínuo em tempo real de um sistema a eventos discretos (ANTSAKLIS, 2000). Uma definição simplificada deste tipo de sistema é empregada para caracterizar sistemas que possuem diversos modos de operação. Cada modo de operação representa uma dinâmica contínua do processo constituído por equações diferenciais ou a diferenças enquanto cada troca de modo de operação ocorre devido a presença de eventos particulares, caracterizando a dinâmica discreta do sistema. Os sistemas híbridos são encontrados em sistemas mecânicos com colisões, circuitos com diodos e interruptores, processos químicos controlados por válvulas e bombas e, sobretudo, sistemas embarcados de computação nos quais os dispositivos digitais interagem com um ambiente analógico (JOHANSSON; LYGEROS; SASTRY, 2004).

A modelagem de sistemas híbridos deve ser descritiva para que os modelos não determinísticos capturem incertezas e sejam capazes de explicar como a evolução dos modos discretos das variáveis de estados afetam e são afetadas pela evolução contínua destas variáveis. É necessário que a linguagem matemática permita a construção de grandes modelos através da combinação de pequenos modelos para componentes simples. A linguagem também deve possibilitar a composição de argumentos sobre o desempenho dos componentes individuais para avaliar o desempenho do sistema global e vice-versa, caracterizando a modelagem como combinável e desagregável (JOHANSSON; LYGEROS; SASTRY, 2004).

O amplo interesse no estudo de sistemas híbridos e suas aplicações implicaram o desenvolvimento de diversos formalismos na representação destes sistemas (HEEMELS; SCHUTTER; BEMPORAD, 2001). Algumas características apresentadas são consideradas importantes para classificar cada formalismo híbrido. São elas:

- amostragem: refere-se ao mecanismo de aquisição de informações do processo. A amostragem pode ser considerada contínua, na qual conhece-se todos os estados durante todo tempo, e discreta, caracterizando a pré-determinação de um período de amostragem para atualização das informações sobre os estados do processo;
- dinâmica contínua: é determinada pelo modelo linear ou não linear;
- determinismo da dinâmica contínua: a dinâmica do sistema é caracterizada de acordo com a evolução do sistema determinada pelos estados e entradas atuais; para uma mesma entrada o sistema pode levar a um único estado (determinístico) ou a diversos estados diferentes (não determinístico);
- determinismo da dinâmica discreta: de maneira semelhante à classificação da dinâmica contínua, uma ação discreta pode levar a um único estado ou a diversos estados diferentes;
- ações de controle: refere-se ao tipo de sinais de controle que podem ser usados na manipulação da planta. Estes sinais podem ser contínuos, discretos ou ambos; e
- especificações: são classificadas da mesma maneira que as ações de controle.

Assim, de acordo com estas categorias, existem diversas classes de sistemas híbridos presentes na literatura tais como autômatos híbridos (BORRELLI; BEMPORAD; MORARI, 2017), autômato híbrido discreto (BORRELLI; BEMPORAD; MORARI, 2017), sistemas afins por partes (CARLONI et al., 2004), sistemas por complementaridade (HEEMELS; SCHUTTER; BEMPORAD, 2001), sistemas max-min-adição-multiplicação (HEEMELS; SCHUTTER; BEMPORAD, 2001) e sistemas dinâmicos lógicos mistos (BEMPORAD; MORARI, 1999).

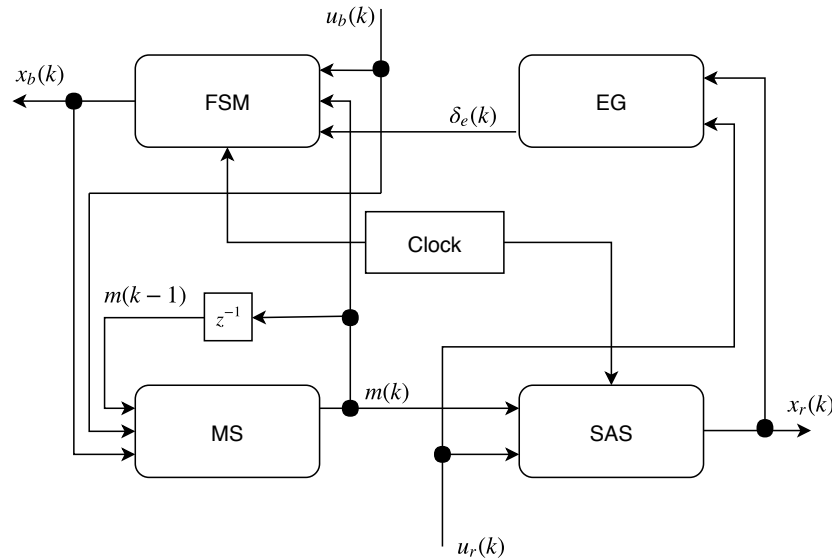
Nas subseções seguintes são discutidos as classes de sistemas híbridos propostos para a modelagem da microrrede: DHA e MLD. O texto foi baseado nos trabalhos de Bemporad e Morari (1999) e Borrelli, Bemporad e Morari (2017).

2.1.1 Autômato híbrido discreto - DHA

A dinâmica contínua do DHA da Figura 2.1 é representada pelo sistema comutado por partes (*Switched Affine System - SAS*). SAS é um conjunto de equações ordinárias diferenciais ou a diferenças que preservam o valor do estado quando ocorre um chaveamento. É possível implementar uma condição de reconfiguração (*reset*) no SAS pela adição de uma nova dinâmica (TORRISI; BEMPORAD, 2004). As dinâmicas de eventos discretos são representadas por uma máquina de estados finitos síncrona (*Finite State Machine - FSM*). A interação entre ambos é realizada por dois elementos de conexão: O gerador de eventos (*Event Generator - EG*) e o seletor de modos (*Mode Selector - MS*). O EG extrai e gera sinais lógicos a partir do SAS. Estas lógicas e entradas lógicas externas habilitam a transição de estados do FSM. O MS processa todos os sinais lógicos para escolher a dinâmica contínua do SAS. As variáveis de estado e entradas binárias são representadas

por $x_b(k) \in X_b \subseteq \{0, 1\}^{n_b}$ e $u_b(k) \in U_b \subseteq \{0, 1\}^{m_b}$ respectivamente. As variáveis de estado e entradas contínuas são representadas por $x_r(k) \in X_r \subseteq R^n$ e $u_r(k) \in U_r \subseteq R^m$ respectivamente. A seleção de modos é feita pela variável inteira $m(k) \in \mathcal{J} := \{1, \dots, s\}$ e os eventos discretos são representados por $\delta_e(k) = f_H(x_r(k), u_r(k), k)$.

Figura 2.1 – Autômato híbrido discreto.



Fonte: Traduzido de (BORRELLI; BEMPORAD; MORARI, 2017).

O DHA é formulado por dinâmicas de tempo discreto. Deste ponto em diante a terminologia tempo discreto é usada para declarar equações a diferenças e variáveis no instante $k \in \mathbb{N}^+$ para uma taxa de amostragem T_s . O DHA generaliza muitos modelos orientados a ferramentas computacionais para sistemas híbridos e representa o ponto de partida para solução de análises complexas e problemas de modelagem de sistemas híbridos.

2.1.2 Sistemas dinâmicos lógicos mistos - MLD

A forma geral do MLD é definida pela seguinte expressão:

$$\begin{aligned} \mathbf{x}(k+1) &= \mathbf{A}\mathbf{x}(k) + \mathbf{B}_1\mathbf{u}(k) + \mathbf{B}_2\boldsymbol{\delta}(k) + \mathbf{B}_3\mathbf{z}(k) \\ \mathbf{y}(k) &= \mathbf{C}\mathbf{x}(k) + \mathbf{D}_1\mathbf{u}(k) + \mathbf{D}_2\boldsymbol{\delta}(k) + \mathbf{D}_3\mathbf{z}(k) \\ \mathbf{E}_2\boldsymbol{\delta}(k) + \mathbf{E}_3\mathbf{z}(k) &\leq \mathbf{E}_1\mathbf{u}(k) + \mathbf{E}_4\mathbf{x}(k) + \mathbf{E}_5 \end{aligned} \quad (2.1)$$

em que $\mathbf{x} = [x_r \ x_b]^T \in R^{n_c} \times \{0, 1\}^{n_i}$ são estados contínuos e binários, $\mathbf{u} = [u_r \ u_b]^T \in R^{m_c} \times \{0, 1\}^{m_i}$ são entradas contínuas e binárias, $\mathbf{y} = [y_r \ y_b]^T \in R^{p_c} \times \{0, 1\}^{p_i}$ são as saídas, $\boldsymbol{\delta} \in \{0, 1\}^{r_i}$ e $\mathbf{z} \in R^{r_c}$ representam, respectivamente, variáveis auxiliares binárias e contínuas.

As variáveis auxiliares δ e z são introduzidas para a transformação de proposições lógicas em inequações lineares. Uma variável binária δ é associada a uma relação lógica X_i da seguinte maneira: $X_i = \text{"verdadeiro"}$ se, e somente se, $\delta_i = 1$. A lógica proposicional também é convertida em inequações lineares equivalentes. Um conjunto de declarações envolvendo literais X_1, \dots, X_n pode ser solucionado por meio de programação linear inteira através da tradução das declarações originais em inequações lineares envolvendo variáveis lógicas δ_i . A ligação entre declarações lógicas e variáveis dinâmicas contínuas de tempo discreto é alcançada pela aplicação das propriedades da Tabela 4, em que ε é um número muito pequeno positivo e M , n são os limites superior e inferior de f respectivamente. O leitor interessado pode saber mais detalhes em (BEMPORAD; MORARI, 1999).

Tabela 4 – Conversão de relações lógicas em inequações inteiras-mistas mais utilizadas.

Proposição	Lógica	Inequação
P1	$[f(x) \leq 0] \leftrightarrow [\delta = 1]$	$f(x) \leq M - M\delta$ $f(x) \geq \varepsilon + (n - \varepsilon)\delta$
P2	$z = \delta f(x)$	$z \leq M\delta$ $-z \leq -n\delta$ $z \leq f(x) - n(1 - \delta)$ $-z \leq -f(x) + M(1 - \delta)$

2.1.3 Modelos HYSDEL

A tarefa de tradução das propriedades da Tabela 4 é geralmente longa e desgastante. Neste trabalho, propõe-se o uso da ferramenta computacional HYSDEL (*HYbrid System DEscription Language*) (TORRISI; BEMPORAD, 2004). O compilador HYSDEL traduz o DHA em diversas classes de sistemas híbridos. Neste trabalho o foco é a tradução do DHA para a classe MLD. O compilador HYSDEL gera um simulador que roda como uma função no MATLAB. Uma descrição completa da sintaxe do HYSDEL está disponível em Torrisi et al. (2019).

Para a formulação do problema de otimização foi utilizado o MATLAB junto com o CPLEX. O HYSDEL foi utilizado para gerar as matrizes MLD de cada equipamento da MG (ver Apêndice C) e os códigos detalhados encontram-se no Apêndice G.

2.2 Controle Preditivo Baseado em Modelo - MPC

O MPC é uma técnica de controle avançada que permite o tratamento natural dos processos com limitações físicas dos atuadores, restrições de entrada e saída, considera múltiplas entradas e múltiplas saídas, atraso de transporte e ação de controle antecipada sobre as perturbações (ALMEIDA; SALLES, 2016). O MPC não é uma estratégia de controle

específica, mas é o nome dado a um conjunto muito grande de métodos de controle que foram desenvolvidos considerando algumas ideias comuns baseadas no conceito de predição. O MPC utiliza uma estratégia de controle com horizontes de rolagem de comprimento finito. O algoritmo MPC calcula primeiro a predição da saída futura do processo por meio do sinal de controle e erro atuais. Através da saída futura e uma trajetória de referência, é calculado o erro futuro previsto e aplicado a um módulo de otimização. Este módulo calcula o sinal de controle a ser aplicado ao processo no próximo passo considerando a minimização de uma função objetivo. O sinal de controle atual é aplicado ao processo enquanto que os sinais de controle futuros são descartados. A saída futura prevista é novamente comparada com a trajetória de referência e assim uma política de *feedback* é estabelecida.

Dentre as várias técnicas MPC, o presente trabalho propõe uma técnica que combina as características do HMPC - controle preditivo híbrido e do EMPC - controle preditivo econômico. Nesta seção é feito um resumo sobre a teoria de HMPC baseado nos trabalhos de Caetano (2011), Garcia (2009) e Villa et al. (2005). É apresentado um resumo teórico do EMPC baseado no trabalho de Sartori (2017). No capítulo 4 é apresentada a formulação da função objetivo e o algoritmo de controle preditivo econômico híbrido.

2.2.1 Controle preditivo híbrido - HMPC

Sistemas MLD possuem propriedades com características semelhantes a de sistemas não lineares devido à presença de variáveis binárias. Uma propriedade marcante está ligada ao estado estacionário do sistema MLD (CAETANO, 2011). Sistemas MLD além de possuírem equações diferenciais dos estados, possuem uma série de restrições contendo as variáveis auxiliares do processo. Uma forma de obter o estado estacionário é através da resolução do problema de otimização

$$\begin{aligned}
 & \min_{\mathbf{u}_e, \mathbf{x}_e} J(\mathbf{u}, \boldsymbol{\delta}, \mathbf{z}, \mathbf{x}) \\
 & \text{Sujeito às restrições,} \\
 & \mathbf{x}_e = \mathbf{A}\mathbf{x}_e + \mathbf{B}_1\mathbf{u}_e + \mathbf{B}_2\boldsymbol{\delta}_e + \mathbf{B}_3\mathbf{z}_e \\
 & \mathbf{y}_e = \mathbf{C}\mathbf{x}_e + \mathbf{D}_1\mathbf{u}_e + \mathbf{D}_2\boldsymbol{\delta}_e + \mathbf{D}_3\mathbf{z}_e \\
 & \mathbf{E}_2\boldsymbol{\delta}_e + \mathbf{E}_3\mathbf{z}_e \leq \mathbf{E}_1\mathbf{u}_e + \mathbf{E}_4\mathbf{x}_e + \mathbf{E}_5.
 \end{aligned} \tag{2.2}$$

Considerando que o índice e representa as variáveis estacionárias e \mathbf{r} a saída de referência, a função objetivo é da forma

$$J(\mathbf{u}, \boldsymbol{\delta}, \mathbf{z}, \mathbf{x}) = \|\mathbf{u}_e\|_{\mathbf{Q}_1}^p + \|\boldsymbol{\delta}_e\|_{\mathbf{Q}_2}^p + \|\mathbf{z}_e\|_{\mathbf{Q}_3}^p + \|\mathbf{x}_e\|_{\mathbf{Q}_4}^p + \|(\mathbf{y}_e - \mathbf{r})\|_{\mathbf{Q}_5}^p \tag{2.3}$$

onde $p = 1$, $p = 2$ ou $p = \infty$ e \mathbf{Q}_i , $i = 1, \dots, 5$ são as matrizes de ponderação positivas definidas com as dimensões adequadas. Baseado em (2.2) é possível e desejável saber se um sistema MLD pode ser estabilizado em um estado de equilíbrio ou pode seguir uma trajetória desejada de referência, via controle por realimentação.

O trabalho de Bemporad e Morari (1999) mostrou que sistemas MLD são bem postos, em outras palavras, significa que para todo \mathbf{x} , dado \mathbf{u} contido em um conjunto limitado, as variáveis $\boldsymbol{\delta}$ e \mathbf{z} são unicamente determinadas, isto é, existem funções F e G tais que em cada instante de tempo k , $\boldsymbol{\delta}(k) = F(\mathbf{x}(k), \mathbf{u}(k))$ e $\mathbf{z}(k) = G(\mathbf{x}(k), \mathbf{u}(k))$. O HMPC é uma abordagem interessante para o controle baseado no chaveamento de dinâmicas lineares, entradas binárias, estados lógicos, variáveis de estado com restrições (BORRELLI; BEMPORAD; MORARI, 2017). Khakimova et al. (2015) propuseram o HMPC aplicado a uma MG residencial composta por painéis PV, banco de baterias, cargas elétricas, sistema que combina calor e potência e a conexão com a rede principal. Assim como no MPC, o HMPC pode ser representado por (2.4) nas normas unitária, infinita e quadrática.

$$\begin{aligned}
\min_{\mathbf{u}} J(\mathbf{u}_0, \mathbf{x}(0)) &= \sum_{i=0}^{N-1} \|\mathbf{u}(k+i) - \mathbf{u}_e\|_{\mathbf{Q}_1}^p + \|\boldsymbol{\delta}(k+i) - \boldsymbol{\delta}_e\|_{\mathbf{Q}_2}^p \\
&+ \|\mathbf{z}(k+i) - \mathbf{z}_e\|_{\mathbf{Q}_3}^p + \|\mathbf{x}(k+i) - \mathbf{x}_e\|_{\mathbf{Q}_4}^p + \|\mathbf{y}(k+i) - \mathbf{y}_e\|_{\mathbf{Q}_5}^p \\
&\text{Sujeito às restrições,} \\
\mathbf{x}(0) &= \mathbf{x}_0 \\
\mathbf{x}(k+1) &= \mathbf{A}\mathbf{x}(k) + \mathbf{B}_1\mathbf{u}(k) + \mathbf{B}_2\boldsymbol{\delta}(k) + \mathbf{B}_3\mathbf{z}(k) \\
\mathbf{y}(k) &= \mathbf{C}\mathbf{x}(k) + \mathbf{D}_1\mathbf{u}(k) + \mathbf{D}_2\boldsymbol{\delta}(k) + \mathbf{D}_3\mathbf{z}(k) \\
\mathbf{E}_2\boldsymbol{\delta}(k) + \mathbf{E}_3\mathbf{z}(k) &\leq \mathbf{E}_1\mathbf{u}(k) + \mathbf{E}_4\mathbf{x}(k) + \mathbf{E}_5
\end{aligned} \tag{2.4}$$

sendo $\mathbf{x}(k)$ o vetor de estados no instante k obtido pelo estado inicial $x_0 = x(0)$ e aplicando a sequência de entradas $\mathbf{u}_0 = [u_0^T, u_1^T, \dots, u_{N-1}^T]^T$ no modelo do sistema. \mathbf{Q}_i para $i = 1, \dots, 5$ são matrizes de ponderação simétricas definidas positivas. Para as demais variáveis o raciocínio é análogo, porém deve-se enfatizar que os valores dos estados calculados são predições, portanto definidos com o deslocamento de um intervalo de tempo em relação a \mathbf{u}_k (sistema estritamente próprio) (CAETANO, 2011). Generalizando, para a sequência de entradas $\mathbf{u}_k = [u_k^T, u_{k+1}^T, \dots, u_{k+N-1}^T]^T$, as predições para os estados do sistema são $\mathbf{x}_k = [x_{k+1}^T, x_{k+2}^T, \dots, x_{k+N}^T]^T$ e de forma análoga para os vetores $\boldsymbol{\delta}_k$, \mathbf{z}_k e \mathbf{y}_k . Algumas formulações do MPC consideram o horizonte de controle $N_u < N$, fazendo $u(k) \equiv u(N_u - 1)$, $\forall k = N_u \dots N$. Em tais abordagens, utilizar o horizonte de controle menor que o horizonte de previsão reduz o custo computacional do algoritmo. Porém, no HMPC este ganho computacional é parcial pois todas as variáveis $\boldsymbol{\delta}(k)$ e $\mathbf{z}(k)$ permanecem no problema de otimização (BEMPORAD; MORARI, 1999). Logo, para o HMPC ao longo deste trabalho, considera-se que $N_u = N$. Características do HMPC:

- usa o modelo MLD para prever a evolução futura do sistema;
- a previsão é baseada em um horizonte de previsão N e feita em cada instante k ;
- a seleção da ação de controle ótima é feita através de um procedimento de otimização;
- somente as ações de controle do instante k são aplicadas; e
- o processo se repete para $k + 1$.

2.2.2 Controle preditivo econômico - EMPC

A estratégia HMPC, descrita na Seção 2.2.1, aplicada no gerenciamento de sistemas de energia possui algumas desvantagens:

- é baseado no MPC clássico onde a função objetivo deve minimizar o erro entre os *set-points* e as variáveis controladas. Estes *set-points*, são fornecidos antecipadamente ao MPC, resolvendo um problema de otimização. A solução do MPC, por outro lado, são *set-points* para os controladores primários (controle dos inversores, etc);
- os objetivos operacionais da MG tais como vender energia não possuem um ponto ótimo fixo, mas varia de acordo com as incertezas, variáveis contínuas do sistema, etc.. Portanto, o ótimo global pode não ser alcançado pelo HMPC; e
- a função objetivo do HMPC é formada por variáveis físicas, como potência, corrente, nível da bateria, modos operacionais e não inclui variáveis econômicas.

É possível contornar estes problemas através da estratégia de controle EMPC, onde o problema de otimização econômico é resolvido junto com o problema de controle preditivo dinâmico (SARTORI, 2017). A função objetivo integra as equações que relacionam os aspectos econômicos e os modelos dinâmicos físicos do sistema. O EMPC equivale resolver o nível secundário da MG de forma dinâmica. O problema de otimização pode ser formulado pela expressão (2.5)

$$\mathcal{V}_N(\mathbf{x}, \mathbf{u}) = \sum_{i=0}^{N-1} J_e(\mathbf{x}(k+i), \mathbf{u}(k+i)) \quad (2.5)$$

onde J_e é uma função que descreve o desempenho econômico do processo de forma dinâmica como custo de manutenção, custos de banco de baterias, entre outros. O problema de

controle ótimo P_N com horizonte de previsão N é definido:

$$\begin{aligned}
 P_N &= \min_u \mathcal{V}_N(\mathbf{x}, \mathbf{u}) \\
 &\text{Sujeito às restrições,} \\
 \mathbf{x}(k+1) &= \mathbf{A}\mathbf{x}(k) + \mathbf{B}\mathbf{u}(k) \\
 \mathbf{x}(0) &= \mathbf{x}_0 \\
 \mathbf{x} &\in \mathcal{X} \\
 \mathbf{u} &\in \mathcal{U}
 \end{aligned} \tag{2.6}$$

O EMPC contém uma função objetivo econômica sujeita às restrições da planta da mesma forma que o MPC clássico.

2.3 Otimização Multiobjetivo

Os custos econômicos e físicos que estão presentes na função objetivo do EMPC são geralmente conflitantes. Por exemplo, o custo de O&M de um ESS é conflitante com o custo de venda de energia. Por isso o EMPC tem características de um problema multiobjetivo. Nesta seção será apresentado o problema da otimização multiobjetivo, bem como os métodos que podem ser utilizados para a sua análise. Também será apresentado e discutido o método adotado para o desenvolvimento desta pesquisa. O texto foi baseado nos trabalhos de (ZITZLER, 1999), (EMMERICH; DEUTZ, 2018), (SCOLA, 2014) e (MACIEL, 2012).

A otimização mono-objetivo está baseada na minimização ou maximização de uma única função objetivo sujeita a um conjunto de restrições que define a factibilidade. A função objetivo e as restrições são funções matemáticas das variáveis de decisão, que são grandezas controláveis, e de parâmetros que são dados do problema. Essa estrutura vem sendo aplicada com sucesso a vários problemas das áreas de fluxo de potência ótimo (MACIEL, 2012), sistemas de transmissão com geração distribuída (RUEDA-MEDINA; PADILHA-FELTRIN, 2011) e logística (DUTTA et al., 2020), entre outros. Contudo, a formulação de problemas usando otimização mono-objetivo por vezes não trata de forma explícita ou mesmo ignora a existência de múltiplos objetivos que apresentam algum nível de conflito, o que se verifica frequentemente na realidade.

Definição 1 - Otimização Multiobjetivo: A otimização multiobjetivo consiste em minimizar ou maximizar simultaneamente um conjunto de objetivos sujeita a uma série de restrições. O conceito de otimização em um cenário multiobjetivo consiste em escolher, num conjunto de soluções, os valores dos objetivos que não podem ser melhorados

simultaneamente. Considerando o problema de minimização¹, um problema de otimização multiobjetivo tem a seguinte estrutura:


$$\begin{aligned}
 \min \mathbf{z} &= \mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_m(\mathbf{x})]^T \\
 &\text{Sujeito à restrições,} \\
 \mathbf{g}(\mathbf{x}) &= [g_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_p(\mathbf{x})] \leq 0 \\
 \mathbf{h}(\mathbf{x}) &= [g_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_q(\mathbf{x})] = 0 \\
 \mathbf{x} &= [x_1, x_2, \dots, x_r] \in \mathcal{X} \\
 \mathbf{z} &= [z_1, z_2, \dots, z_m] \in \mathcal{Z}
 \end{aligned} \tag{2.7}$$

em que:

- \mathbf{x} : vetor das variáveis de decisão de dimensão \mathbf{r} ;
- $\mathbf{z}, \mathbf{f}(\mathbf{x})$: vetor das funções objetivo de dimensão \mathbf{m} ;
- $\mathbf{g}(\mathbf{x})$: conjunto das restrições de desigualdade de dimensão \mathbf{p} ;
- $\mathbf{h}(\mathbf{x})$: conjunto das restrições de igualdade de dimensão \mathbf{q} .

As restrições dadas por $\mathbf{g}(\mathbf{x})$ definem em \mathbf{r} , o espaço das variáveis de decisão, a região factível \mathcal{X} e qualquer ponto $\mathbf{x} \in \mathcal{X}$ como uma solução factível. O espaço $\mathcal{Z} = \mathbf{f}(\mathcal{X})$ é a imagem de \mathcal{X} denominado região factível no espaço das funções objetivo. Esses conceitos estão apresentados na Figura 2.2 para 2 variáveis de decisão e 2 soluções, sendo $\mathcal{F} : \mathcal{X} \rightarrow \mathcal{Z}$.

Figura 2.2 – Mapeamento das variáveis de decisão no espaço das funções objetivo.



Fonte: Adaptado de (MACIEL, 2012).

¹ Em geral, os algoritmos de otimização tratam apenas da minimização de funções, convertendo um problema de maximização em um de minimização, simplesmente multiplicando a função objetivo por -1 .

Diferentemente da otimização mono-objetivo, onde a função objetivo é escalar, na otimização multiobjetivo ocorre um mapeamento de cada solução \mathbf{x} no espaço de variáveis de decisão, em um ponto no espaço vetorial de objetivos. Esse mapeamento leva um vetor \mathbf{r} -dimensional em outro vetor \mathbf{m} -dimensional. O propósito da otimização multiobjetivo é determinar um conjunto de soluções, denominado conjunto de Pareto ou conjunto Pareto-ótimo (EMMERICH; DEUTZ, 2018), que representa as soluções do problema (2.7). A seguir, apresentam-se algumas definições e conceitos para a melhor compreensão do conjunto Pareto-ótimo.

Definição 2 - Dominância de Pareto: Para definir o conceito de dominância, será utilizada a seguinte notação para comparação de vetores no espaço \mathfrak{R}^m

$$\begin{aligned} \mathbf{f}(\mathbf{x}) \leq \mathbf{f}(\mathbf{y}) &\Rightarrow \{f_k(\mathbf{x}) \leq f_k(\mathbf{y})\} \quad \forall k \in \{1, 2, \dots, m\} \\ \mathbf{f}(\mathbf{x}) \neq \mathbf{f}(\mathbf{y}) &\Rightarrow \{\exists k \mid f_k(\mathbf{x}) \neq f_k(\mathbf{y})\} \end{aligned} \quad (2.8)$$

Sejam \mathbf{x}_1 e \mathbf{x}_2 dois pontos no espaço. Diz-se que o ponto \mathbf{x}_1 domina o ponto \mathbf{x}_2 , $\mathbf{x}_1 \prec \mathbf{x}_2$ se ambas as condições se verificarem:


- i A solução \mathbf{x}_1 não é pior do que a solução \mathbf{x}_2 para nenhum objetivo, ou seja, $f_k(\mathbf{x}_1) \leq f_k(\mathbf{x}_2)$ para $k \in \{1, 2, \dots, m\}$.
- ii A solução \mathbf{x}_1 é estritamente melhor que a solução \mathbf{x}_2 em pelo menos um objetivo, ou seja, existe $k \in \{1, 2, \dots, m\} \mid f_k(\mathbf{x}_1) < f_k(\mathbf{x}_2)$.

Se alguma das condições for violada, então \mathbf{x}_1 não domina a solução \mathbf{x}_2 , o que não implica em \mathbf{x}_2 dominar \mathbf{x}_1 . Na verificação da relação de dominância podem ocorrer:

- \mathbf{x}_1 domina \mathbf{x}_2 ($\mathbf{x}_1 \prec \mathbf{x}_2$);
- \mathbf{x}_2 domina \mathbf{x}_1 ($\mathbf{x}_2 \prec \mathbf{x}_1$);
- não há dominância entre as soluções \mathbf{x}_1 e \mathbf{x}_2 .

A Figura 2.3a mostra um exemplo de curva de Pareto para as soluções A, B, C, D e E. A Figura 2.3b mostra as relações de dominância entre a solução B e as demais soluções. A solução B domina as soluções D e E. Não há relação de dominância entre as soluções B e C e a solução B é dominada pela solução A que se encontra na curva de Pareto.

Figura 2.3 – (a) Exemplo de optimalidade de Pareto; (b) Possíveis relações de dominância em relação à solução do ponto B.



Fonte: Adaptado de (ZITZLER, 1999).

Definição 3 - Ótimo de Pareto: Um ponto $\mathbf{x}_{opt} \in \mathcal{X}$ é ótimo de Pareto se e somente se não há $\mathbf{x} \in \mathcal{X}$ tal que \mathbf{x} domine \mathbf{x}_{opt} .

Uma solução ótima de Pareto também pode ser designada por solução não dominada, eficiente ou não inferior. A Definição 2 garante que \mathbf{x}_{opt} é ótimo de Pareto se não há outro vetor factível \mathbf{x} que reduza algum objetivo sem causar elevação simultânea em pelo menos um dos outros objetivos.

Definição 4 - Conjunto ótimo de Pareto: Conjunto único de todas as soluções não dominadas para um dado problema de otimização multiobjetivo.

Definição 5 - Fronteira de Pareto: A imagem do conjunto ótimo de Pareto no espaço das funções objetivo. Convém ainda apresentar outros conceitos e termos que serão utilizados. Durante o processo de otimização multiobjetivo é de fundamental importância o papel do agente humano identificado como decisor (*decision maker*). A definição das preferências do decisor ao longo do processo de otimização no sentido de escolher a solução final dentre as ótimas é chamada de tomada de decisão (*decision making*). Um outro conceito importante é compromisso (*trade-off*) entre objetivos em conflito ou ainda representa a quantidade de um objetivo que deve ser sacrificado de maneira a obter um ganho em outro objetivo. Considerando o(s) instante(s) no tempo em que o decisor interage ou fornece informações preferenciais, a seguir são apresentadas três abordagens gerais para otimização multiobjetivo (EMMERICH; DEUTZ, 2018):

1. *a priori*: O decisor deve declarar preferências adicionais, por exemplo, pesos dos objetivos, antes da otimização;

2. a *posteriori*: O usuário deve declarar suas preferências a *posteriori*, ou seja, após ser informado sobre os compromissos entre soluções não dominadas; e
3. interativo (também conhecido como progressivo): As funções objetivo, restrições e sua priorização são refinadas através de uma realimentação do decisor sobre as preferências em vários momentos durante a execução de um algoritmo.

2.3.1 Métodos de solução

Muitos métodos, têm sido propostos para a obtenção do conjunto de soluções eficientes para a otimização multiobjetivo. Estes são classificados em dois grupos fundamentais: métodos clássicos e métodos heurísticos.

2.3.1.1 Métodos clássicos

Os métodos clássicos para geração do conjunto Pareto-ótimo trabalham de forma similar à função objetivo parametrizada dos métodos de otimização a *priori*. Entretanto, os parâmetros que combinam linearmente os objetivos numa única função não são estabelecidos pelo decisor, como nos métodos a *priori*, mas variados sistematicamente pelo otimizador. Diversas execuções do algoritmo de otimização, para diferentes valores de parâmetros, são realizadas para alcançar um conjunto de soluções Pareto-ótimo aproximadas (ZITZLER, 1999). Pertencem a esta classe o método da soma ponderada, o método ε -restrito e a estratégia de programação por metas. No método da soma ponderada o problema original de múltiplos objetivos é transformando num problema de objetivo único, por intermédio de uma combinação linear dos objetivos

$$\begin{aligned} \min \mathbf{f}(\mathbf{x}) &= \sum w_i \cdot f_i(\mathbf{x}) \\ \text{Sujeito a: } \mathbf{x} &\in \mathcal{X} \end{aligned} \tag{2.9}$$

no qual w_i são os pesos de cada objetivo. Resolvendo-se o problema de otimização escalar acima para vários valores de pesos, tem-se um conjunto de soluções (ZITZLER, 1999). Esta metodologia é usada nesta Tese para formular o problema de controle preditivo econômico híbrido.

2.3.1.2 Métodos de solução evolutivos

São baseados em algoritmos evolutivos ou evolucionários. Algoritmos evolucionários são métodos de busca heurísticos inspirados em analogias com a evolução natural. A principal diferença dos algoritmos evolutivos em relação aos métodos clássicos é que múltiplas soluções do conjunto Pareto-ótimo podem ser encontradas em uma única execução do código, enquanto que a maioria dos métodos clássicos irão requerer múltiplas execuções (SCOLA, 2014). Além desta significativa diferença, os métodos clássicos devem superar a

cada execução as dificuldades relacionadas com regiões inefectivas, ótimos locais, regiões onde a função objetivo não varia ou pouco varia, etc, para convergir para o ótimo local daquela execução. Dado que as execuções dos métodos clássicos são independentes, nenhuma informação sobre o sucesso ou falha das execuções anteriores é utilizada para acelerar o processo de encontrar o conjunto de soluções não-dominadas (MACIEL, 2012). Atualmente, existem três paradigmas principais para os métodos de solução evolutivos. Esses são:

1. Métodos evolutivos baseados em Pareto: Os métodos baseados em Pareto usam um esquema de classificação de dois níveis. A relação de dominância de Pareto rege a primeira classificação e as contribuições de pontos para a diversidade é o princípio da classificação de segundo nível. A classificação de segundo nível se aplica a pontos que compartilham a mesma posição na primeira classificação. NSGA-II e SPEA2 são dois algoritmos populares que se enquadram nesta categoria.
2. Métodos evolutivos baseados em indicadores: Esses métodos são guiados por um indicador que mede o desempenho de um conjunto, por exemplo, o indicador de hiper volume ou o indicador R2. Os métodos evolutivos são concebidos de forma que as melhorias neste indicador determinem o procedimento de seleção ou a classificação dos indivíduos. O algoritmo SMS-EMOA (EMMERICH; DEUTZ, 2018) usa o indicador de hiper volume como indicador de desempenho.
3. Métodos evolutivos baseados em decomposição: aqui, o algoritmo decompõe o problema em vários subproblemas, cada um deles visando diferentes partes da frente de Pareto. Para cada subproblema, uma parametrização (ou ponderação) diferente de um método de escalarização é usada. MOEA/D e NSGA-III (EMMERICH; DEUTZ, 2018) são métodos bem conhecidos neste domínio.

2.4 Modelos de Previsão Meteorológicos

As informações meteorológicas são de alto valor no gerenciamento da MG, uma vez que as condições meteorológicas determinam a geração de RES e influenciam na demanda do sistema. Erros de previsão do tempo derivados das dificuldades em modelar com precisão os processos atmosféricos, também são responsáveis por uma parte relevante da incerteza na operação e gerenciamento da MG. As previsões meteorológicas podem ser classificadas em quatro categorias, dependendo da forma como são obtidas (AGÜERA-PÉREZ et al., 2018). A seguinte classificação será referenciada ao longo do texto:

- arbitrário: O teste é baseado em dados sintéticos projetados especificamente para o experimento, com diferentes graus de semelhança com a realidade;
- históricas: as previsões são simuladas a partir de séries históricas, que podem ser tratadas como previsões perfeitas ou modificadas pela introdução de alguma variabilidade para simular erros inerentes às previsões reais.

- previsões locais: são geradas pelo processamento das medições da operação do sistema, incluindo condições meteorológicas do local. Os modelos de previsão implementados são normalmente baseados em abordagens estatísticas ou de aprendizado de máquina. Os dados históricos geralmente são usados para ajustar ou treinar o modelo de previsão; e
- previsões externas: As previsões são recebidas diretamente de um serviço de previsão público ou comercial. Em alguns casos, é realizado um processamento adicional para um melhor ajuste.

Para o problema de gerenciamento da MG proposto nesta Tese os resultados foram obtidos utilizando as seguintes categorias:

- dados históricos com a inserção de ruído branco com distribuição gaussiana; e
- dados meteorológicos obtidos de estações automáticas e através de modelos de previsão externo.

A seguir é apresentado um modelo de previsão externa que foi utilizado nesta Tese.

2.4.1 Modelo WRF

O *Weather Research and Forecasting* (WRF) (SKAMAROCK et al., 2019) é um modelo atmosférico de mesoescala não hidrostático para previsão numérica de tempo e clima. É um modelo aberto e flexível, com código fonte disponibilizado livremente para uso operacional e de pesquisa, sendo a versão 4 usada neste trabalho. Por possuir um código estável, limpo e aprimorado, o WRF pode ser executado desde máquinas comuns, como um computador de mesa ou portátil, até em supercomputadores de grandes centros de pesquisa.

O modelo foi desenvolvido através da parceria entre diversos institutos dos Estados Unidos da América: *National Center for Atmospheric Research; Mesoscale & Microscale Meteorology; National Oceanic and Atmospheric Administration* (NOAA); *National Centers for Environmental Prediction; Naval Research Laboratory; Federal Aviation Administration* e Universidade de Oklahoma (SKAMAROCK et al., 2019). Os mesmos autores descrevem detalhadamente toda a sua estrutura física e computacional, além de outras informações específicas. Sua assimilação de dados é baseada em uma grande gama de tipos de aquisições tais como satélites, boias marinhas, sondagens atmosféricas e radares. Os domínios espaciais de execução podem ir desde alguns metros (microescala) até milhares de metros (escala planetária). Diversos tipos de resultados podem ser obtidos através de suas simulações, como análise de dispersão de poluentes (SUNNY LIM et al., 2020), parâmetros de interação oceano-atmosfera (VARLAS et al., 2020), sistemas sinóticos (XIAO; LOFGREN; WANG, 2018), previsão da velocidade e direção do vento para geração

de energia eólica (OLIVARES J. D. LARA; KAZERANI, 2015), previsão de irradiância para geração de energia solar (SILVA et al., 2020a), entre outros. Nesta Tese será utilizado o WRF para a previsão de irradiância, temperatura e velocidade dos ventos para o cálculo da previsão de potência PV e eólica.

2.5 Discussão

Neste capítulo foi apresentada a teoria básica sobre sistemas híbridos e controle preditivo híbrido. Tais abordagens foram utilizadas para a modelagem dos equipamentos da MG no Capítulo 3. Além disso, foram descritos alguns conceitos importantes sobre otimização multi-objetivo, abordagens com relação à tomada de decisão e alguns métodos de solução. No Capítulo 4 é proposto a formulação da função objetivo do problema do despacho econômico da MG utilizando o método da soma ponderada. Embora o método da soma ponderada não garanta atingir todos as soluções Pareto-ótimas em problemas com espaço de objetivos não-convexos (SCOLA, 2014), a formulação deste método no algoritmo de controle produz resultados satisfatórios, conforme será mostrado no Capítulo 5. Por fim, é apresentado um resumo teórico sobre quatro categorias de obtenção de dados para modelos de previsão e o modelo WRF, um modelo atmosférico de mesoescala ainda pouco explorado em pesquisas com gerenciamento de MG. Este modelo tem um papel importante na investigação do algoritmo proposto através dos resultados numéricos da seção 5.2.2.

3 Modelagem dos equipamentos e condições operacionais da Microrrede

A modelagem proposta considera as seguintes premissas:

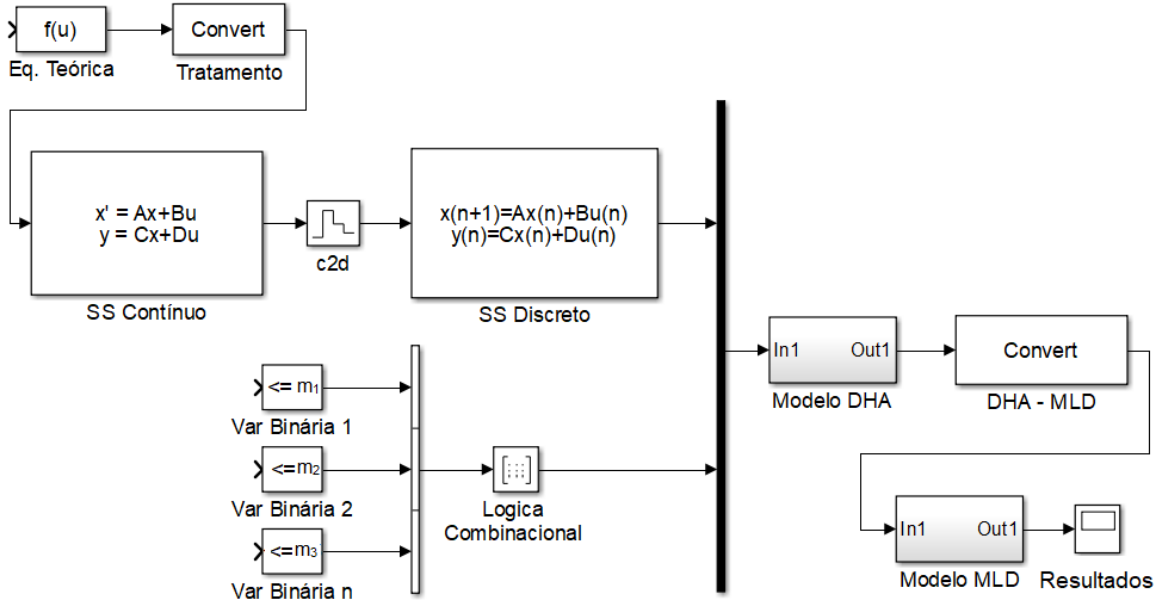
1. a existência dos seguintes equipamentos da MG: painéis solares, turbinas eólicas, ESS com banco de baterias, cargas elétricas e aquisição de dados meteorológicos através de estações meteorológicas;
2. o nível secundário da estrutura de controle hierárquico não é afetado pelos comportamentos transitórios da dinâmica do nível primário;
3. os tempos de duração da conexão e desconexão da MG para a rede principal são de alguns segundos e não interferem no segundo nível do sistema de controle, que é atualizado em minutos;
4. as operações de conexão e desconexão da MG à rede principal não afetam sua estabilidade;
5. todas as desconexões da microrrede da rede principal são intencionais, ou seja, não há desconexões devido a falhas;
6. o controle de passo e a frequência do gerador eólico rastreiam sua máxima potência; e
7. a eficiência de carga e descarga do banco de baterias é considerada constante e igual a 1.

Cada equipamento da MG é modelado através da metodologia descrita a seguir (ver Figura 3.1):

- é feito uma pesquisa bibliográfica das equações teóricas de cada equipamento;
- algumas equações são não lineares, sendo necessário fazer alguns tratamentos tais como: aproximações por funções lineares e aproximação da curva característica do modelo por um polinômio interpolador;
- o modelo linearizado é representado no espaço de estados (*Space State* - SS) contínuo e depois convertido para o modelo de SS discreto a uma taxa de amostragem compatível com a simulação;
- é feito uma investigação para definir quais são os limites e as saturações dos equipamentos. Para cada limite é definido uma variável binária ou uma lógica combinacional de várias variáveis binárias;
- o modelo SS discreto e as variáveis binárias são descritos no formalismo DHA; e
- o modelo DHA é convertido no modelo MLD através de um *software* que descreve o modelo DHA e o converte em matrizes de estados e equações de igualdades e

desigualdades. Estas matrizes são as informações mais revelantes de cada equipamento para o desenvolvimento do algoritmo de otimização mostrado no Capítulo 4.

Figura 3.1 – Fluxograma de modelagem da Microrrede.



Fonte: próprio autor.

Este capítulo dá ênfase na modelagem dos equipamentos da MG através da *modelagem DHA*. Os parâmetros dos modelos DHA propostos nesta tese dependem dos dados meteorológicos medidos em cada instante de tempo kT_s onde T_s é a taxa de amostragem. Para simplificação será omitido o termo T_s em todas as equações deste trabalho. Os detalhes da conversão MLD e das matrizes de cada modelo serão apresentados nos Apêndices A, B e C. Na seção 3.1, apresenta-se o modelo híbrido do painel fotovoltaico e na seção 3.2 descreve-se as equações híbridas que regem a geração eólica. Em seguida, na seção 3.3 descreve-se a modelagem DHA do banco de baterias. As seções 3.4, 3.5, 3.6 e 3.7 descrevem as equações dos modelos híbridos das cargas elétricas, controlador de carga, tarifas de energia e balanço de potência respectivamente. Por fim na seção 3.8 é apresentado a modelagem das condições de conexão e desconexão da MG.

3.1 Geração Fotovoltaica

O circuito equivalente do arranjo fotovoltaico (KANG; PARK, 2011) é representado por

$$I(k) = I_{sc} \cdot \lambda(k) - \frac{I_{sc}}{e^{\frac{qA}{nk_B T(k)}}} \cdot [e^{\frac{qA}{nk_B T(k)}} \cdot e^{\frac{V(k)}{V_{oc}}} - 1]. \quad (3.1)$$

Esta equação depende da variação de irradiância λ , da temperatura ambiente T , da tensão de circuito aberto V_{oc} , da corrente de curto-circuito I_{sc} , do fator de idealidade A , constante de Boltzmann k_B e outros parâmetros fornecidos pelos fabricantes de painéis voltaicos. Utiliza-se um algoritmo de rastreamento de ponto de máxima potência (*Maximum Power Point Tracking* - MPPT) para calcular a potência máxima ($P_{MPPT}(k)$) em cada instante kT_s , $k = 1, 2, 3, \dots$, de acordo com os seguintes passos:

1. inserir as especificações dos painéis fotovoltaicos (tensão de circuito aberto, corrente de curto-circuito) e as constantes físicas;
2. receber os dados medidos pelos sensores de irradiância e temperatura no instante atual;
3. variar a tensão dos painéis PV de 0 até V_{oc} e calcular a corrente *versus* tensão do painel da através da Eq. (3.1) e a curva de potência ($P_{pv}(k) = V(k) \cdot I(k)$); e
4. fazer a interpolação da curva de potência *versus* tensão do passo 3, usando o polinômio mostrado em (3.2).

$$P_{pv}(k) = d_n(k)V^n(k) + d_{n-1}(k)V^{n-1}(k) + \dots + d_1(k)V(k) + d_0(k) \quad (3.2)$$

onde $d_1, d_2 \dots d_n$ são parâmetros que variam em função da irradiância e temperatura.

O modelo DHA do painel fotovoltaico é representado pelas sentenças lógicas (3.3), (3.4) e (3.5). O modo seletor, fornecido por (3.3), seleciona uma dinâmica do SAS definida por (3.4) de acordo com a variável binária do gerador de eventos $\delta_{pv1}(k)$ fornecida por (3.5). Se a potência calculada ($P_{pv}(k)$) for maior que a potência nominal do painel PV ($\delta_{pv1}(k) = 1$) para uma dada irradiância e temperatura, a potência saturará no valor P_{pvsat} . O sistema afim por partes representado por (3.4) altera a potência máxima de geração entre o valor calculado pelo polinômio em (3.2) e a saturação da potência nominal, de acordo com o seletor de modos

$$MS : m_{pv}(k) = \begin{cases} 1 & \text{se } \neg\delta_{pv1}(k) \\ 2 & \text{se } \delta_{pv1}(k) \end{cases} \quad (3.3)$$

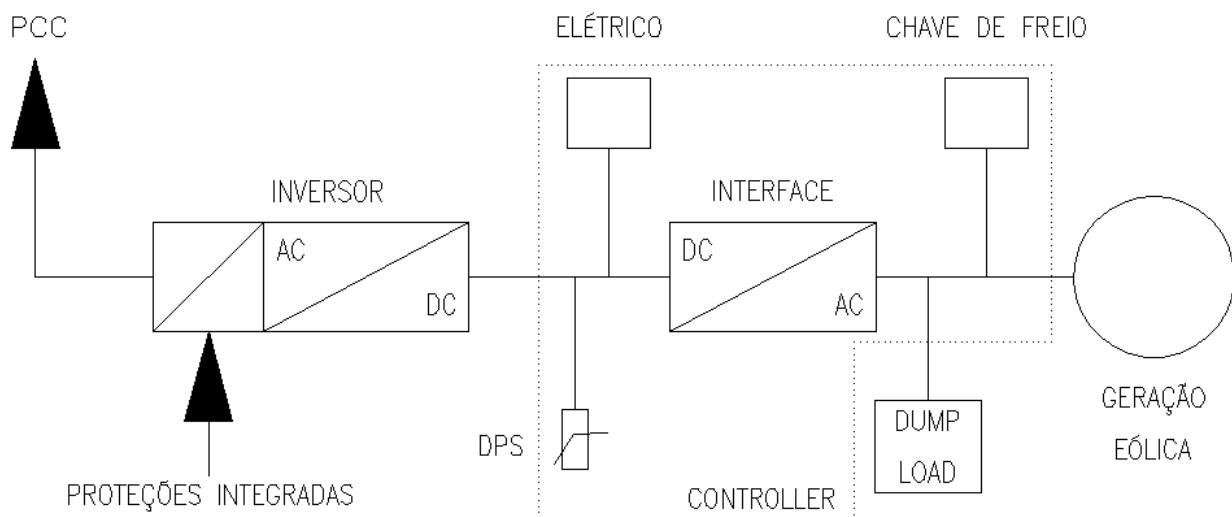
$$SAS : \begin{cases} \mathbf{x}_{pv}(k+1) = P_{pv}(k) & \text{se } m_{pv}(k) = 1 \\ \mathbf{x}_{pv}(k+1) = P_{pvsat} & \text{se } m_{pv}(k) = 2 \end{cases} \quad (3.4)$$

$$EG : \left\{ [\delta_{pv1}(k) = 1] \leftrightarrow [P_{pv}(k) \geq P_{pvsat}] \right\}. \quad (3.5)$$

3.2 Geração Eólica

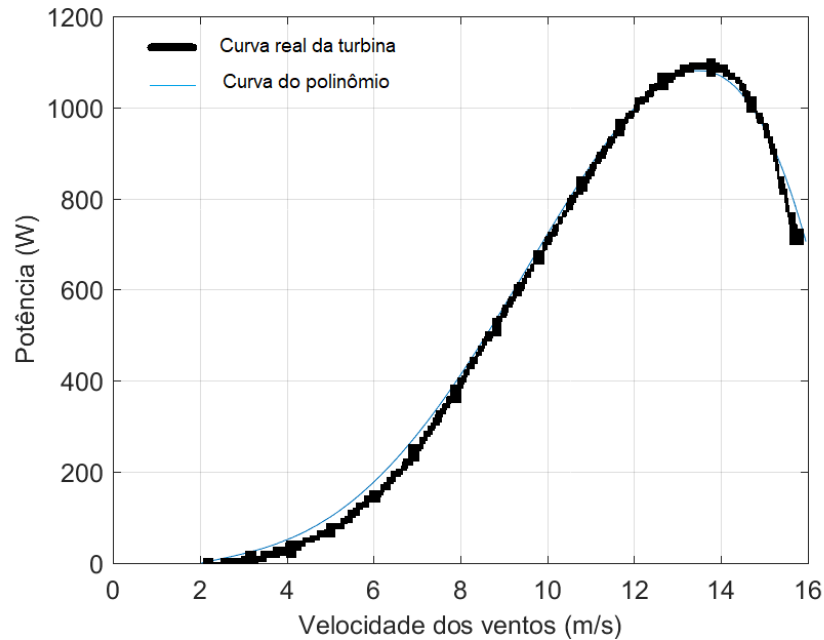
O conjunto do gerador eólico de baixa potência é composto por um inversor de frequência conectado à *rede principal através de um ponto de conexão comum (PCC)*, o controlador (*controller*) e resistores de amortecimento (*dump load*) para dissipar o excesso de energia. O *controller* faz a proteção da turbina eólica e interliga todos os componentes. O controlador possui dispositivo de proteção contra surtos, chave de freio, interface AC/DC e freio auxiliar elétrico. Na Figura 3.2, mostra-se em detalhes a configuração de um sistema eólico. Outra informação importante é a curva de potência *versus* velocidade dos ventos. Nessa curva é possível visualizar a velocidade mínima (*cut in*), o tipo de controle da turbina eólica e a velocidade de corte (*cut off*). Caso os dados da curva não sejam fornecidos, qualquer curva de potência pode ser extraída através de um algoritmo que lê os *pixels* da curva e os converte em pontos que representam os valores de potência *versus* velocidade dos ventos. Uma vez que a curva de potência foi convertida em pontos, uma função de interpolação pode ser criada para encontrar o polinômio que melhor se ajusta à curva de potência. A Figura 3.3 mostra um comparativo entre a curva extraída de uma turbina eólica e a curva de um polinômio interpolador. Esta técnica pode ser aplicada em qualquer turbina eólica. Basta que o fabricante forneça a curva de potência.

Figura 3.2 – Diagrama unifilar de um sistema eólico.



Fonte: Modificado de (ENERSUD, 2017).

Figura 3.3 – Comparativo entre a curva de potência real de uma turbina eólica e a curva de potência obtida por um polinômio interpolador do 4º grau com erro quadrático médio de $6,61 \cdot 10^{-5} \%$.




Fonte: próprio autor.

Em uma turbina eólica com controle de passo, a razão entre a energia eólica P_w e sua potência nominal P_n possui quatro estados lógicos definidos por quatro regiões operacionais (consulte a Figura 3.4):

- estado **sem geração** para velocidades menores que v_{cutin} ;
- estado **operando** na máxima eficiência para velocidades entre v_{cutin} e v_n ;
- estado **nominal** (eficiência reduzida) onde a turbina atinge a potência nominal quando a velocidade for maior que v_n ; e
- estado de corte (**cut off**) quando a velocidade do vento ultrapassa v_{cutoff} e a turbina para. A turbina ficará parada ou com velocidade muito baixa e com geração de P_{cutoff} .

Figura 3.4 – Curva de operação da turbina eólica com controle de passo.



Fonte: próprio autor.

Através dos pontos extraídos na região de máxima eficiência da Figura 3.4, determina-se a potência eólica através de um polinômio interpolador dado por:

$$P_w(k) = a_n v^n(k) + a_{n-1} v^{n-1}(k) + \dots + a_1 v(k) + a_0 \quad (3.6)$$

em que $a_0 \dots a_n$ são os coeficientes polinomiais. O modelo DHA de geração de vento proposto possui a máquina de estados finita (FSM) definida por (3.7). Essa FSM evolui através de eventos discretos entre estados operacionais: sem geração (x_{wb1}), máxima eficiência (x_{wb2}), operando na potência nominal (x_{wb3}) e *cut off* (x_{wb4}). Se a saída do gerador de eventos mostrado em (3.8) for a variável binária op , isto indica que o gerador eólico está operando abaixo da sua potência nominal e, se a saída for pn , isto indica que o gerador está operando na sua potência nominal. Cada estado gerado pelo FSM pode ser acessado por todos os outros estados, dependendo do evento de transição. As regras de seleção entre a dinâmica em (3.10) são definidas pelo seletor de modos em (3.9). Por exemplo, se a turbina eólica estiver no estado sem geração (x_{wb1}), então $m_w(k) = 1$ e, conseqüentemente, $x_w(k+1) = 0$ no SAS. Se apenas o evento δ_{w1} estiver ativado ($v(k) \geq v_{cutin}$), o FSM da turbina evolui do estado sem geração (x_{wb1}) para o estado operando na máxima eficiência (x_{wb2}) e o MS faz $m_w(k) = 2$ e seleciona $x_w(k+1) = P_w(k)$ no SAS.

$$FSM : x_{wb} = \begin{cases} x_{wb1} & \text{se } (x_{wb1} \wedge \delta_{w1}) \vee (x_{wb2} \wedge \delta_{w1}) \\ & \vee (x_{wb3} \wedge \delta_{w1}) \vee (x_{wb4} \wedge \delta_{w1}) \\ x_{wb2} & \text{se } (x_{wb1} \wedge op) \vee (x_{wb2} \wedge op) \\ & \vee (x_{wb3} \wedge op) \vee (x_{wb4} \wedge op) \\ x_{wb3} & \text{se } (x_{wb1} \wedge pn) \vee (x_{wb2} \wedge pn) \\ & \vee (x_{wb3} \wedge pn) \vee (x_{wb4} \wedge pn) \\ x_{wb4} & \text{se } (x_{wb1} \wedge \delta_{w3}) \vee (x_{wb2} \wedge \delta_{w3}) \\ & \vee (x_{wb3} \wedge \delta_{w3}) \vee (x_{wb4} \wedge \delta_{w3}) \end{cases} \quad (3.7)$$

$$EG : \begin{cases} [\delta_{w1}(k) = 1] \leftrightarrow [v(k) \leq v_{cutin}] \\ [\delta_{w2}(k) = 1] \leftrightarrow [v(k) \geq v_n] \\ [\delta_{w3}(k) = 1] \leftrightarrow [v(k) \geq v_{cutoff}] \\ [op(k) = \neg\delta_{w1}(k) \wedge \neg\delta_{w2}(k)] \leftrightarrow [v(k) > v_{cutin} \wedge v(k) < v_n] \\ [pn(k) = \delta_{w2}(k) \wedge \neg\delta_{w3}(k)] \leftrightarrow [v(k) \geq v_n \wedge v(k) < v_{cutoff}] \end{cases} \quad (3.8)$$

$$MS : m_w(k) = \begin{cases} 1 & \text{se } x_{wb1}(k) \\ 2 & \text{se } x_{wb2}(k) \\ 3 & \text{se } x_{wb3}(k) \\ 4 & \text{se } x_{wb4}(k) \end{cases} \quad (3.9)$$

$$SAS : \begin{cases} x_w(k+1) = 0 & \text{se } m_w(k) = 1 \\ x_w(k+1) = P_w(k) & \text{se } m_w(k) = 2 \\ x_w(k+1) = P_n & \text{se } m_w(k) = 3 \\ x_w(k+1) = P_{cutoff} & \text{se } m_w(k) = 4 \end{cases} \quad (3.10)$$

3.3 Banco de Baterias

O modelo DHA do banco de baterias representa dinâmicas distintas de acordo com o valor do SOC e o modo de operação da MG: isolada ou conectada com a rede principal. Nas equações lógicas apresentadas em (3.11), quando o SOC ($S(k)$) atingir seu valor máximo, o banco de baterias será carregado e $\delta_{s1}(k) = 1$. Caso contrário ($\delta_{s1}(k) = 0$), as baterias não atingiram seu máximo SOC. O evento $\delta_{s2}(k) = 1$ ocorre quando a MG estiver conectada e o banco de baterias não estiver carregado. O seletor de modos em

(3.12) escolhe a dinâmica do SAS representada por (3.13) de acordo com a variável $u_g(k)$ definida em (3.14) por

$$EG : \begin{cases} [\delta_{s1}(k) = 1] \leftrightarrow [S(k) \geq S_{max}] \\ [\delta_{s2}(k) = 1] \leftrightarrow [u_g(k) \vee \neg \delta_{s1}(k)] \end{cases} \quad (3.11)$$

$$MS : m_s(k) = \begin{cases} 1 & \text{se } \neg u_g(k) \\ 2 & \text{se } u_g(k) \end{cases} \quad (3.12)$$

$$SAS : \begin{cases} S(k+1) = S(k) - \frac{\eta T_s}{C_{max}} \cdot i_1(k) - x_b^s & \text{se } m_s(k) = 1 \\ S(k+1) = S(k) + \frac{\eta T_s}{C_{max}} \cdot i_2(k) - x_b^s & \text{se } m_s(k) = 2 \end{cases} \quad (3.13)$$

$$u_g(k) = \begin{cases} 1 & \text{se MG conectada} \\ 0 & \text{se MG isolada} \end{cases} \quad (3.14)$$

No sistema de equações (3.13), x_b^s representa a auto-descarga do banco de baterias. A corrente $i_1(k)$ refere-se à corrente de carga/descarga quando a MG está isolada, $i_2(k)$ é a corrente de carga do banco de baterias quando a MG está conectada à rede. O valor da corrente $i_1(k)$ é determinado a partir de (3.15a), ou seja,

$$i_1(k) = i_L(k) - i_{pv}(k) - i_w(k) \text{ se } \neg u_g(k) \quad (3.15a)$$

$$i_2(k) = i_{ch}(k) \delta_{s2}(k) \text{ se } u_g(k). \quad (3.15b)$$

O banco de baterias é carregado quando $i_1(k)$ é negativo; caso contrário, o banco de baterias está descarregado. A variável $i_2(k)$ em (3.15b) depende da corrente do controlador de carga ($i_{ch}(k)$) que carrega o banco de baterias quando a MG está conectada à rede. Se $u_g(k) = 1$ e $\delta_{s2}(k) = 0$ em (3.11), o banco de baterias está carregado. Nesse caso, o carregador para de fornecer energia ao banco de baterias, ou seja, $i_2(k) = 0$.

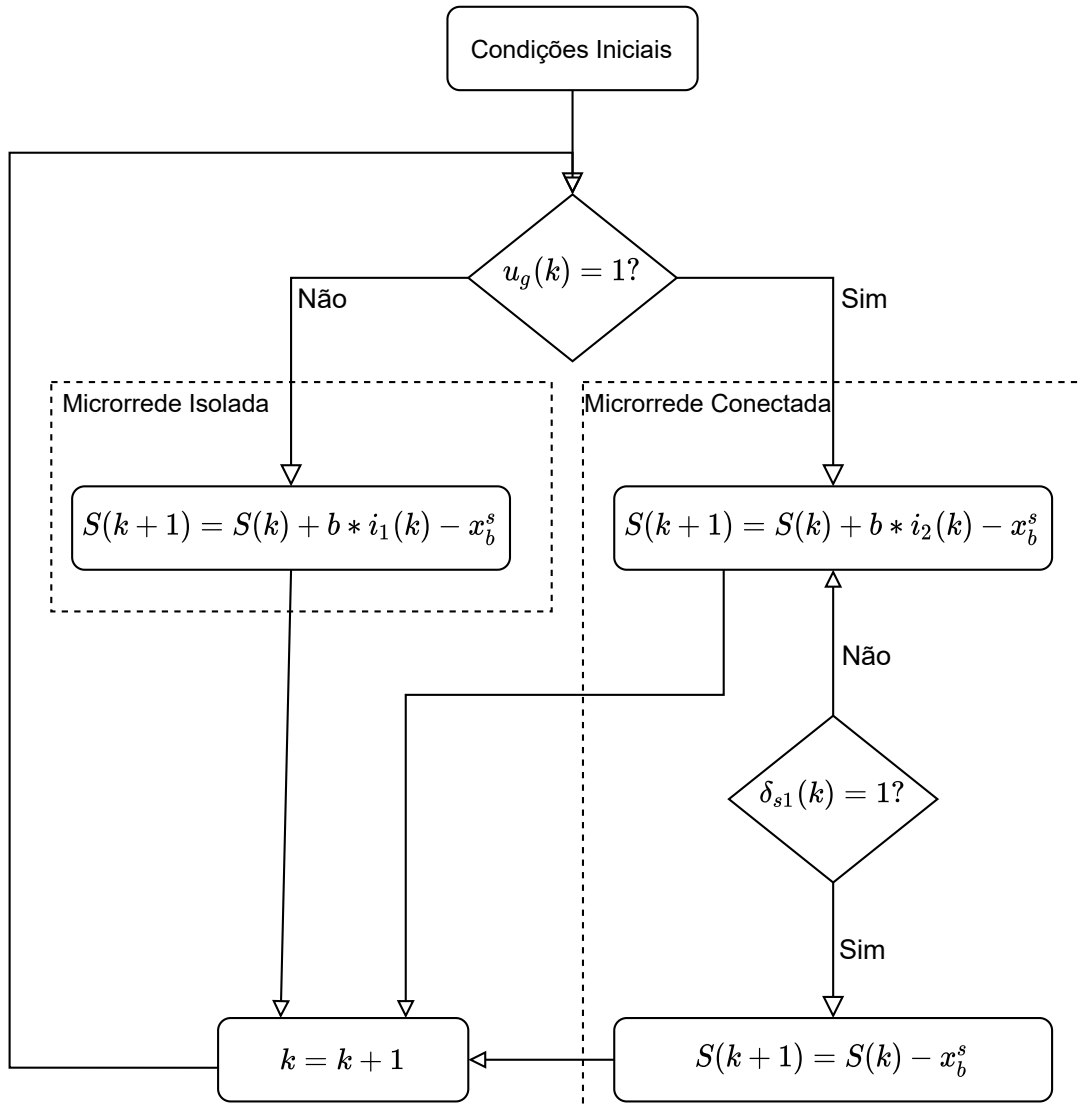
Quando a MG estiver conectada, a demanda do carregador do banco de baterias é representado por (3.16)

$$D_{ch}(k) = \delta_{s2}(k) \cdot D_{c2}(k) \quad (3.16)$$

em que $D_{c2}(k)$ é o produto de $i_{ch}(k)$ com a tensão V_b nos terminais do banco de baterias.

A Figura 3.5 mostra o fluxograma de operação do banco de baterias para cada modo de operação da MG, onde $b = \eta T_s / C_{max}$.

Figura 3.5 – Fluxograma de operação do banco de baterias. A equação do SOC é chaveada em função dos modos de operação da MG e se o banco de baterias está carregado ou não.



Fonte: próprio autor.

3.4 Cargas Eléctricas

Considere que há um número total de cargas eléctricas controladas (n_c) através de contadores. Cada contador é representado por uma variável binária $c_h(k)$, $h = 1, \dots, n_c$. Cada carga L_h tem uma demanda de energia D_h . As cargas controláveis DHA podem ser representadas pelas expressões (3.17), (3.18) e (3.19):

$$EG : \begin{cases} [c_1(k) = 1] \leftrightarrow [L_1 = D_1] \\ [c_2(k) = 1] \leftrightarrow [L_2 = D_2] \\ \vdots \\ [c_{n_c}(k) = 1] \leftrightarrow [L_{n_c} = D_{n_c}] \end{cases} \quad (3.17)$$

$$MS : m_l(k) = \begin{cases} 1 & \text{se } g_{l1}(c_1, c_2, \dots, c_n) = 0 \dots 01 \\ 2 & \text{se } g_{l1}(c_1, c_2, \dots, c_n) = 0 \dots 10 \\ 3 & \text{se } g_{l1}(c_1, c_2, \dots, c_n) = 0 \dots 11 \\ \vdots & \\ \varrho & \text{se } g_{l\varrho}(c_1, c_2, \dots, c_n) = 1 \dots 11 \end{cases} \quad (3.18)$$

$$SAS : D_c(k) = \begin{cases} 0 & \text{se } m_l(k) = 1 \\ D_{c2} & \text{se } m_l(k) = 2 \\ \vdots & \\ D_{c\varrho} & \text{se } m_l(k) = \varrho \end{cases} \quad (3.19)$$

no qual $\varrho = 2^{n_c}$ e $g_l(\cdot)$ é uma função que representa um número binário de tamanho n_c tal que $g_l(c_1, c_2, \dots, c_{n_c}) = c_{n_c} \dots c_2 c_1$. A demanda total das cargas controláveis é a soma de todas as cargas ligadas representadas por

$$D_c(k) = \sum_{h=1}^{n_c} c_h(k) D_h(k). \quad (3.20)$$

Por exemplo, se temos duas cargas controláveis com demandas D_1 e D_2 , o SAS da Eq. (3.19) terá 4 dinâmicas: $D_c = \{0, D_1, D_2, D_1 + D_2\}$. Geralmente uma MG possui também cargas críticas, isto é, cargas que não são controláveis e permanecem sempre ligadas. A demanda total das cargas elétricas, incluindo as cargas críticas, é definida por

$$D_L(k) = \sum_{h=1}^{n_c} c_h(k) D_h(k) + \sum_{i=1}^{n_l} D_i(k) \quad (3.21)$$

em que n_l é o número de cargas críticas e D_i é a i -ésima carga crítica.

3.5 Controlador de Carga

O controlador de carga tem a função de carregar o banco de baterias e desabilitar as cargas elétricas quando o SOC do banco de baterias estiver em um nível crítico enquanto


a MG opera no modo isolado. Também é possível monitorar a tensão e corrente do banco de baterias. O controlador monitora o nível crítico do banco de baterias que é S_{crt} . Neste patamar todas as cargas elétricas são desabilitadas para conservar o banco de baterias. O nível seguro para habilitar as cargas elétricas é chamado de S_{safe} . O gerador de eventos do controlador de carga é descrito por (3.22)

$$EG : \begin{cases} [\delta_{c1}(k) = 1] \leftrightarrow [S(k) \leq S_{crt}] \\ [\delta_{c2}(k) = 1] \leftrightarrow [S(k) \geq S_{safe}] \end{cases} \quad (3.22)$$

sendo que o evento $\delta_{c1}(k)$ desabilita as cargas elétricas e o evento $\delta_{c2}(k)$ as habilita. Através desses eventos foi proposto uma FSM do controlador de carga com dois estados discretos: estado inicial E para cargas elétricas habilitadas (x_{cb1}) e o estado D para cargas elétricas desabilitadas (x_{cb2}). A Figura 3.6 e a expressão (3.23) mostram a FSM do controlador de carga.

$$FSM : x_{cb}(k+1) = \begin{cases} x_{cb1} & \text{se } (x_{cb1} \wedge \neg\delta_{c1}) \vee (x_{cb2} \wedge \delta_{c2}) \\ x_{cb2} & \text{se } (x_{cb1} \wedge \delta_{c1}) \vee (x_{cb2} \wedge \neg\delta_{c2}) \end{cases} \quad (3.23)$$

Figura 3.6 – Máquina de estados finita do controlador de carga.



Fonte: próprio autor.

3.6 Tarifas de Energia

A MG pode comprar ou vender energia elétrica com preços de compra ($c_p(k)$) e venda ($c_s(k)$) respectivamente, quando estiver conectada à rede. O modelo DHA de preço da eletricidade usado nesta Tese foi proposto por (PARISIO; RIKOS; GLIELMO, 2014). As seguintes expressões 3.24, 3.25 e 3.26, descrevem este modelo:

$$EG : \left\{ [\delta_g(k) = 1] \leftrightarrow [P_g(k) \geq 0] \right. \quad (3.24)$$

$$MS : m_p(k) = \begin{cases} 1 & \text{se } \neg\delta_g(k) \\ 2 & \text{se } \delta_g(k) \end{cases} \quad (3.25)$$

$$SAS : C_g(k) = \begin{cases} c_s(k)P_g(k) & \text{se } m_p(k) = 1 \\ c_p(k)P_g(k) & \text{se } m_p(k) = 2 \end{cases} \quad (3.26)$$

onde $C_g(k)$ é o custo total de energia e $P_g(k)$ é o balanço instantâneo de potência da MG conectada, definido em (3.27).

3.7 Balanço de potência

O balanço de potência em (3.27) representa a diferença entre o consumo e a geração de energia, ou seja, é a soma de todas as demandas de carga da MG, incluindo o carregador do banco de baterias, menos a soma das potências solar e eólica.

$$\begin{aligned} P_g(k) &= D_L(k) + \delta_{s2}(k)D_{c2}(k) - P_w(k) - P_{pv}(k) \\ &= \sum_{i=1}^{n_l} D_i(k) + \sum_{h=1}^{n_c} c_h(k)D_h + \delta_{s2}(k)D_{c2}(k) - P_w(k) - P_{pv}(k) \end{aligned} \quad (3.27)$$

A segunda igualdade na expressão acima separa as cargas controláveis das cargas críticas. O balanço de potência depende da política operacional da MG, conforme explicado a seguir:

- se o balanço de potência $P_g(k)$ tiver um sinal negativo, a geração será maior que o consumo. Caso contrário, o consumo é maior que a geração;
- se a microrrede estiver isolada, $P_g(k)$ é a potência de carga ou descarga do banco de baterias (ver Figura 3.7); e
- se a MG estiver conectada à rede, $P_g(k)$ é a troca de potência com a rede principal (ver Figura 3.8).

Figura 3.7 – O balanço de potência da MG isolada define se o banco de baterias irá carregar ou descarregar.

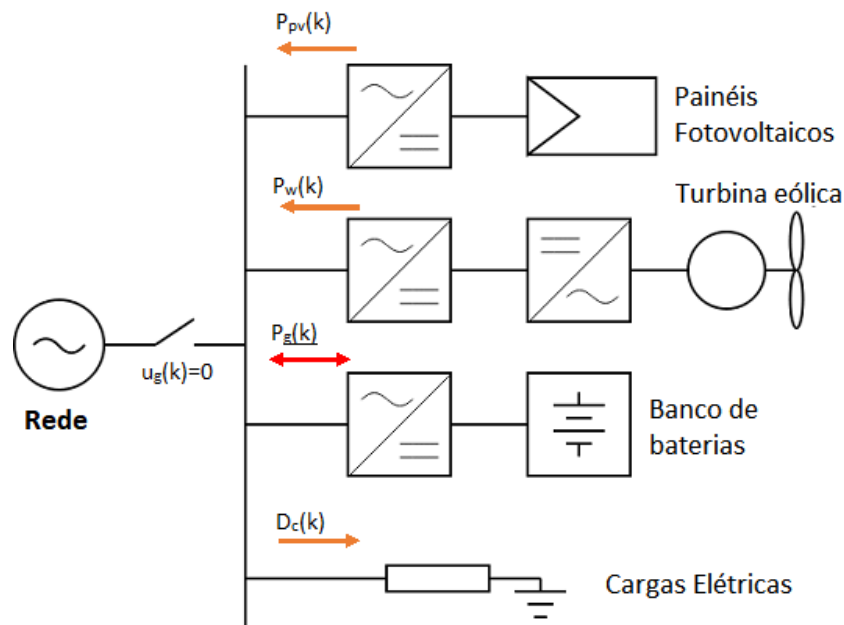
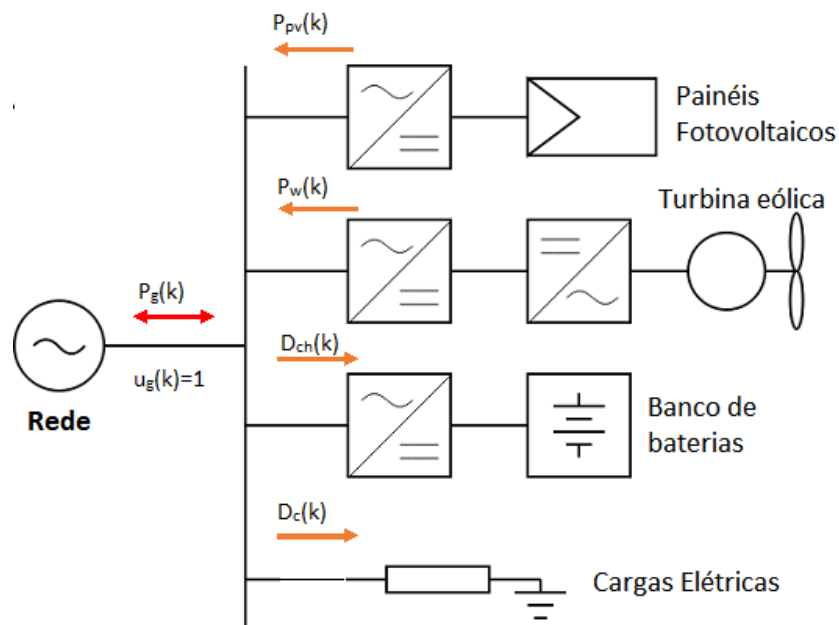


Figura 3.8 – O balanço de potência da MG conectada define se a MG compra ou vende energia da rede principal.



3.8 Condições Operacionais de Conexão e Desconexão da MG


Assume-se que a concessionária de energia elétrica permita a conexão/desconexão da MG à rede principal durante os intervalos mínimos de tempo τ_c e τ_i , respectivamente. As seguintes expressões determinam esses intervalos de tempo

$$\tau_c = \min(T_{up}, N)T_s \quad (3.28)$$

$$\tau_i = \min(T_{down}, N)T_s \quad (3.29)$$

em que T_{up} e T_{down} são o número mínimo de amostras necessárias para que a microrrede permaneça conectada e isolada respectivamente; T_s é o tempo da amostragem e N é o horizonte de previsão. A Figura 3.9 mostra que o sinal de $u_g(k)$ deve, após a conexão ou desconexão da MG, segurar a MG no modo conectado até τ_c (3.28) e no modo isolado até τ_i (3.29) respectivamente.

Figura 3.9 – Intervalo de tempo máximo de conexão e desconexão da MG.



Define-se por $\xi_{hon}(k)$ e $\xi_{hoff}(k)$ as variáveis que contam o número de amostras restantes, necessárias para permitir a conexão ou desconexão da MG no instante atual. A última conexão e desconexão de MG ocorre nas amostras k_c e k_i , respectivamente. Esses contadores satisfazem às equações

$$\xi_{hon}(k+1) = \xi_{hon}(k) - 1, \text{ para } k \geq k_c \text{ e } \xi_{hon}(k_c) = \frac{\tau_c}{T_s} \quad (3.30)$$

$$\xi_{hoff}(k+1) = \xi_{hoff}(k) - 1, \text{ para } k \geq k_i \text{ e } \xi_{hoff}(k_i) = \frac{\tau_i}{T_s}. \quad (3.31)$$

Para garantir valores positivos para esses contadores, define-se as variáveis binárias $\delta_{hon}(k)$ e $\delta_{hoff}(k)$ pelas expressões

$$EG : \begin{cases} [\delta_{hon}(k) = 1] \leftrightarrow [\xi_{hon}(k) \geq 0] \\ [\delta_{hoff}(k) = 1] \leftrightarrow [\xi_{hoff}(k) \geq 0]. \end{cases} \quad (3.32)$$

Define-se os estados binários $holdon(k)$ e $holdoff(k)$ que indicam qual contador $\xi_{hon}(k)$ e $\xi_{hoff}(k)$ estão ativados, respectivamente. Esses estados atendem ao FSM (3.33), que detecta os tempos de conexão e desconexão da MG e verifica se $\delta_{hon}(k)$ e $\delta_{hoff}(k)$ estão ativados

$$FSM : \begin{cases} holdon(k+1) = ((u_g(k) \wedge \neg u_g(k-1)) \vee holdon(k)) \wedge \delta_{hon}(k) \\ holdoff(k+1) = ((\neg u_g(k) \wedge u_g(k-1)) \vee holdoff(k)) \wedge \delta_{hoff}(k). \end{cases} \quad (3.33)$$

Quando os estados binários $holdon(k)$ e $holdoff(k)$ são desabilitados, os contadores $\xi_{hon}(k)$ e $\xi_{hoff}(k)$ são redefinidos pelo MS em (3.34) e o SAS em (3.35)

$$MS : m_{clk}(k) = \begin{cases} 1 & \text{se } holdon(k) \\ 2 & \text{se } \neg holdon(k) \\ 3 & \text{se } holdoff(k) \\ 4 & \text{se } \neg holdoff(k) \end{cases} \quad (3.34)$$

$$SAS : \begin{cases} \xi_{hon}(k+1) = \xi_{hon}(k) - 1 & \text{se } m_{clk}(k) = 1 \\ \xi_{hon}(k+1) = \min(T_{up}, N) & \text{se } m_{clk}(k) = 2 \\ \xi_{hoff}(k+1) = \xi_{hoff}(k) - 1 & \text{se } m_{clk}(k) = 3 \\ \xi_{hoff}(k+1) = \min(T_{down}, N) & \text{se } m_{clk}(k) = 4. \end{cases} \quad (3.35)$$

Por exemplo, se a MG estiver conectada à rede ($u_g(k) = 1$), o estado $holdon(k)$ será ativado e a variável $m_{clk}(k) = 1$, selecionará a dinâmica do SAS que diminui $\xi_{hon}(k)$ do valor τ_c/T_s . Quando $\xi_{hon}(k)$ for menor que zero, o estado $holdon(k)$ se torna inativo e o contador altera sua dinâmica do SAS de acordo com o seletor de modos $m_{clk}(k) = 2$. Nesta situação, a MG atingiu seu tempo mínimo de conexão e pode permanecer conectada ou não.

MG não pode ser desconectada da rede enquanto o estado binário $holdon(k)$ estiver habilitado, ou seja, enquanto $\xi_{hon}(k)$ estiver contando, portanto, temos:

$$u_g(k) = 1 \text{ se } holdon(k) = 1 \quad (3.36)$$

e, analogamente, a relação booleana em (3.37) descreve que a MG não pode ser conectada à rede enquanto $\xi_{hoff}(k)$ estiver ativado, isto é,

$$u_g(k) = 0 \text{ se } holdoff(k) = 1. \quad (3.37)$$

Assume-se que a concessionária de energia possui um número máximo (nc_{max}) de conexões da MG com a rede principal durante um intervalo de tempo $[iT_c, (i+1)T_c]$, $i = 0, 1, 2$, em que T_c é um período especificado pela empresa de distribuição de energia. Esses intervalos têm o período de amostragem T_s , para que o número máximo de amostras em cada um desses intervalos seja $ns_{max} = T_c/T_s$. O intervalo de tempo de iT_c até $kT_s \in [iT_c, (i+1)T_c]$ é indicado pela variável real $\xi_s(k) \in [0, T_c]$. Seja $\delta_\xi(k)$ a variável binária, que sempre redefine $\xi_s(k)$ de acordo com o seguinte sistema lógico e dinâmico:

$$SAS : \begin{cases} \xi_s(k+1) = \xi_s(k) + T_s & \text{se } m_c(k) = 1 \\ \xi_s(k+1) = 0 & \text{se } m_c(k) = 2 \end{cases} \quad (3.38)$$

$$MS : m_c(k) = \begin{cases} 1 & \text{se } \neg\delta_\xi(k) \\ 2 & \text{se } \delta_\xi(k). \end{cases} \quad (3.39)$$

Indica-se por $\xi_c(k)$ o número de conexões da MG para a rede principal no instante $t = iT_c$ até o instante $t = kT_s \in [iT_c, (i+1)T_c]$. A transição do modo isolado para o modo conectado no instante $t = kT_s$ é detectada pela variável binária $\delta_c(k)$. Esta transição faz o seletor de modos $m_{count}(k) = 1$ selecionando a dinâmica correspondente em (3.41). Caso não haja transição do modo isolado para o modo conectado, $\delta_c(k) = 0$ e o seletor de modos vai para $m_{count}(k) = 2$ selecionando a dinâmica correspondente em (3.41). O número máximo de conexões dentro de cada intervalo de tempo $[iT_c, (i+1)T_c]$ é indicado pela variável binária $\delta_{cmax}(k)$. A partir dessas definições, determinamos o sistema lógico e dinâmico tal que

$$EG : \begin{cases} [\delta_c(k) = 1] \leftrightarrow [ug(k) \wedge \neg ug(k-1)] \\ [\delta_{cmax}(k) = 1] \leftrightarrow [\xi_c(k) > nc_{max}] \\ [\delta_\xi(k) = 1] \leftrightarrow [\xi_s(k) > T_c] \end{cases} \quad (3.40)$$

$$SAS : \begin{cases} \xi_c(k+1) = \xi_c(k) + 1 & \text{se } m_{count}(k) = 1 \\ \xi_c(k+1) = \xi_c(k) & \text{se } m_{count}(k) = 2 \\ \xi_c(k+1) = 0 & \text{se } m_{count}(k) = 3 \end{cases} \quad (3.41)$$

$$MS : m_{count}(k) = \begin{cases} 1 & \text{se } \delta_c(k) \wedge \neg\delta_\xi(k) \\ 2 & \text{se } \neg\delta_c(k) \wedge \neg\delta_\xi(k) \\ 3 & \text{se } \delta_\xi(k). \end{cases} \quad (3.42)$$

Garante-se que a MG não pode ser conectada à rede se $\xi_c(k)$ exceder o número máximo de conexões ($n_{c_{max}}$). Portanto

$$u_g(k) = 0 \text{ se } \delta_{c_{max}}(k) = 1. \quad (3.43)$$

Quando o temporizador $\xi_s(k)$ atingir seu período máximo ($T_{c_{max}}$), as variáveis $\xi_c(k)$ e $\xi_s(k)$ serão redefinidas e a variável binária $\delta_c(k)$ será desativada, permitindo que MG execute $n_{c_{max}}$ conexões no próximo período.

3.9 Discussão

Neste capítulo apresentou-se a modelagem híbrida através do DHA de diversos equipamentos da MG. Os modelos DHA da MG podem ser convertidos em desigualdades lineares inteira mista através da conversão para o modelo MLD, convertendo cada condição lógica $[f(x) \leq 0] \leftrightarrow [\delta = 1]$ nas desigualdades

$$f(x) \leq M - M\delta \quad (3.44)$$

$$f(x) \geq \varepsilon + (n - \varepsilon)\delta \quad (3.45)$$

em que ε é um escalar positivo arbitrariamente pequeno. As equações dos modelos da MG serão convertidas através do HYSDEL (ver Apêndice G). A saída do compilador HYSDEL são matrizes contendo as restrições para o problema de otimização que será apresentado no Capítulo 4.

4 Problema de Otimização

Nesta Tese, o problema proposto para despacho econômico da MG é formulado como um problema de otimização multiobjetivo cujo método de solução é o da soma ponderada. É um problema de curto prazo, ou seja, possui um horizonte de previsão de até 6 horas (AGÜERA-PÉREZ et al., 2018). A formulação proposta leva em consideração não apenas os níveis de armazenamento do banco de baterias a serem gerenciados pela microrrede, mas também a possibilidade de realizar conexões com a rede principal para venda e compra de energia. A cada instante k , o sistema de gerenciamento de energia deve tomar decisões de alto nível, como: carregamento e descarregamento do banco de baterias, quantidade de energia que pode ser vendida ou comprada na rede principal e as cargas que podem ser deslocadas ou desconectado. A formulação matemática proposta inclui as seguintes decisões:

- quando o banco de baterias pode ser carregado ou descarregado;
- quando e qual a quantidade de energia pode ser vendida ou comprada da concessionária; e
- quais cargas podem ser realocadas ou desligadas e em qual momento.

Primeiramente, na Seção 4.1, apresenta-se a função objetivo não linear e os seus respectivos termos. Nesta mesma seção, mostra-se como transformá-la em uma função objetivo linear. Na Seção 4.2, apresenta-se o controle preditivo econômico híbrido baseado nas abordagens HMPC e EMPC (ver Seções 2.2.1 e 2.2.2 respectivamente).

4.1 Formulação da Função Objetivo

A função objetivo, mostrada em (4.1), representa os custos operacionais e econômicos da microrrede em um horizonte de previsão de N amostras. O termo $J_{bat}(k)$ são os custos operacionais e de manutenção do banco de baterias, $J_p(k)$ representa os custos de compra e venda de eletricidade e $J_{dis}(k)$ é o custo de desconforto para desligar as cargas não previstas, $\delta_{crt}(k)$ é uma variável binária ativada quando o SOC do banco de baterias é menor que seu nível crítico (S_{crt}) e $\delta_{dump}(k)$ é uma variável binária ativada quando a MG está isolada, as baterias carregadas ($S(k) = 1$) e a geração de energia renovável é maior que o consumo.

$$J_N(k) = \sum_{i=0}^{N-1} [q_{bat} J_{bat}(k+i) + J_p(k+i) + q_h J_{dis}(k+i) + q_{crt} \delta_{crt}(k+i) + q_{dump} \delta_{dump}(k+i)] \quad (4.1)$$

Para aumentar o ciclo de vida do banco de baterias, $J_{bat}(k)$ é penalizado pelo peso q_{bat} e o nível crítico do SOC é penalizado pelo termo $q_{crt}\delta_{crt}(k)$. O conforto do usuário é penalizado pelo peso q_h se as cargas elétricas controláveis forem desconectadas. Quando a MG está isolada e as baterias estiverem carregadas, o excesso de geração é dissipado em uma carga de dissipação (*dump load*), isto é, esta energia é desperdiçada. O desperdício do excesso de geração de energia renovável é penalizado pelo termo $q_{dump}\delta_{dump}(k)$. As principais decisões da função objetivo proposta são:

- minimizar o frequência de carga e descarga do banco de baterias;
- minimizar os desconforto causado pelo desligamento de cargas não previstas;
- no momento que a microrrede estiver conectada, maximizar a venda de energia enquanto se carrega o banco de baterias;
- evitar que o banco de baterias atinja níveis críticos de estado da carga, comprometendo sua vida útil e a segurança operacional da MG; e
- minimizar o desperdício do excesso de geração RES na carga de dissipação.

As variáveis de decisão envolvidas na otimização da função objetivo são: modo de operação da MG ($u_g(k)$) as variáveis binárias c_h , $h = 1, \dots, n_c$ que ligam e desligam as cargas controláveis. A função objetivo em (4.1) é não linear, pois existem multiplicações entre variáveis binárias e funções de valor real. Ao definir algumas variáveis auxiliares como $z(k) = \delta(k)f(k)$, onde $\delta(k)$ é uma variável binária, é possível transformar a expressão (4.1) em uma função objetivo linear com as seguintes restrições lineares inteiras mistas (BEMPORAD; MORARI, 1999)

$$\begin{aligned} z &\leq M\delta & (4.2) \\ -z &\leq -n\delta \\ z &\leq f(x) - n(1 - \delta) \\ -z &\leq -f(x) + M(1 - \delta) \end{aligned}$$

onde f é uma função real, M e n são os limites superior e inferior. Posteriormente, essa transformação é apresentada de acordo com cada termo de função objetivo.

4.1.1 Banco de baterias

O custo de operação e manutenção (O&M) do banco de baterias(OM_b) está relacionado à frequência de operação de carga e descarga. Quando a MG está isolada a frequência de carga e descarga está relacionada com $P_g(k)$ em (3.27) . Quando a MG está

conectada e o banco de baterias não estiver completamente carregado, o carregador do banco de baterias é visto como uma carga de demanda $D_{c2}(k)$, isto é,

$$J_{bat}(k) = OM_b[-u_g(k)[(-2(\delta_{dex}(k)P_g(k)) + P_g(k)) - \delta_{s2}(k)D_{c2}(k)] + \delta_{s2}(k)D_{c2}(k)]. \quad (4.3)$$

Na expressão (4.3), o custo OM_b dado em U\$/ KWh e suas variáveis binárias atendem às equações lógicas (3.11) e (4.4)

$$[\delta_{dex} = 1] \leftrightarrow [P_g(k) < 0]. \quad (4.4)$$

As expressões $\delta_{s2}(k)D_{c2}(k)$ e $\delta_{dex}(k)P_g(k)$ são substituídas pelas seguintes variáveis auxiliares

$$\begin{aligned} z_{ch}(k) &= \delta_{s2}(k)D_{c2}(k) \\ z_{dex}(k) &= \delta_{dex}(k)P_g(k) \end{aligned} \quad (4.5)$$

em que a variável $z_{ch}(k)$ indica que o banco de baterias deve ser carregado quando MG estiver conectado à rede e o nível SOC não for máximo. A variável $z_{dex}(k)$ habilita o balanço de potência quando a geração das fontes renováveis for maior que o consumo das cargas. Substituindo as variáveis auxiliares definidas em (4.5) na Eq. (4.3) obtemos a expressão

$$J_{bat}(k) = OM_b[-u_g(k)[(-2z_{dex}(k) + P_g(k)) - z_{ch}(k)] + z_{ch}(k)]. \quad (4.6)$$

Como ainda existem termos não lineares em (4.6), é necessário definir outra variável auxiliar pela expressão

$$z_{bat}(k) = \neg u_g(k)[(-2z_{dex}(k) + P_g(k)) - z_{ch}(k)] \quad (4.7)$$

e, substituindo z_{bat} in (4.6), tem-se o a função objetivo linear da do banco de baterias

$$J_{bat}(k) = OM_b[z_{bat}(k) + z_{ch}(k)]. \quad (4.8)$$

A Tabela 5 relata os custos da bateria O&M para diferentes modos de operação da MG e do balanço de potência, considerando a suposição de que o banco de baterias não está cheio ($\delta_{s1}(k) = 0$).

Tabela 5 – Custo de O&M do banco de baterias para diferentes balanços de potência e modos de operação da MG.

Modos de operação	Balanço de potência	J_{bat}
Isolado ($u_g = 0$)	Positivo ($\delta_{dex} = 0$)	$OM_b[P_g - \delta_{s2}D_{c2} + \delta_{s2}D_{c2}]$ $= OM_bP_g$
Isolado ($u_g = 0$)	Negativo ($\delta_{dex} = 1$)	$OM_b[-2P_g + P_g - \delta_{s2}D_{c2} + \delta_{s2}D_{c2}]$ $= -OM_bP_g$
Connectado ($u_g = 1$)	Positivo ($\delta_{dex} = 0$)	OM_bD_{c2}
Connectado ($u_g = 1$)	Negativo ($\delta_{dex} = 1$)	OM_bD_{c2}

Quando a MG estiver isolada, o custo operacional do banco de baterias vai depender do balanço de potência. Quando a MG estiver conectada, o custo operacional do banco de baterias vai depender somente do ciclo de carga de demanda $D_{c2}(k)$. O peso OM_b é sempre positivo. Se o balanço de potência é negativo ($P_g < 0$), o resultado da equação $J_{bat} = -OM_bP_g$ será sempre positivo.

4.1.2 Tarifas de energia

No modo conectado à rede ($u_g(k) = 1$), a microrrede pode vender e comprar eletricidade da rede principal. A MG pode vender eletricidade a um preço de venda $c_s(k)$ quando o balanço de potência em (3.27) é negativo. Caso contrário, a MG pode comprar eletricidade a um preço de compra $c_p(k)$. O termo da função objetivo 4.9 que representa a compra e venda de energia é definido por

$$J_p(k) = u_g(k)[(c_s(k) - c_p(k))\delta_{dex}(k)P_g(k)] + c_p(k)u_g(k)P_g(k). \quad (4.9)$$

Para transformar os termos não lineares da expressão (4.9) em termos lineares, define-se as seguintes variáveis auxiliares pela expressão

$$\begin{aligned} z_{p1}(k) &= (c_s(k) - c_p(k))\delta_{dex}(k)P_g(k) \\ z_{p2}(k) &= u_g(k)z_{p1}(k) \\ z_{bal}(k) &= c_p u_g(k)P_g(k). \end{aligned} \quad (4.10)$$

Substituindo essas variáveis auxiliares pelos respectivos termos em (4.9), obtêm-se a seguinte função linear:

$$J_p(k) = z_{p2}(k) + z_{bal}(k) \quad (4.11)$$

4.1.3 Desconforto causado pelo corte de cargas

Nesta Tese, considera-se o programa de resposta à demanda (MAZIDI et al., 2014), onde os clientes podem especificar o corte das cargas controláveis para um melhor gerenciamento de energia. Este procedimento pode ocorrer em situações operacionais críticas, por exemplo, quando MG está isolada e há baixa geração de energia renovável. As cargas controláveis, no entanto, seguem a demanda prevista quando há geração de energia suficiente. O programa de resposta à demanda geralmente leva ao desconforto do usuário, representado por uma penalidade associada ao corte/desligamento de carga. A quantidade de cargas elétricas não atendidas pela MG devido ao descarte de carga é dado por

$$J_{des}(k) = \sum_{h=2}^{nc} q_h(1 - c_h(k))D_h \quad (4.12)$$

onde D_h foi definido em (3.20), q_h é a penalidade da h -ésima carga e nc é o número de cargas elétricas controláveis.

4.1.3.1 Restrições

As restrições dos equipamentos da MG estão relacionadas aos limites superior e inferior do SOC, ao balanço de potência em (3.27) e ao balanço de corrente, veja as três primeiras restrições em (4.13), respectivamente. A quarta restrição apresentada em (4.13) depende da curva de previsão de demanda $D_c^f(k)$. A última restrição descreve que a energia gerada é limitada pela previsão de soma das gerações eólica ($P_w^f(k)$) e solar fotovoltaica ($P_{pv}^f(k)$).

$$\begin{aligned} S_{min} &\leq S(k) \leq S_{max} \\ P_g^{min} &\leq P_g(k) \leq P_g^{max} \\ i_g^{min} &\leq i_g(k) \leq i_g^{max} \\ 0 &\leq D_c(k) \leq D_c^f(k) \\ 0 &\leq P_w(k) + P_{pv}(k) \leq P_w^f(k) + P_{pv}^f(k) \end{aligned} \quad (4.13)$$

Todas as restrições que contêm as variáveis reais e binárias podem ser transformadas em sistema dinâmico lógico misto (MLD) (BEMPORAD; MORARI, 1999) representado por (2.1). Assim, as igualdades e desigualdades dos modelos MLD serão restrições para problemas de otimização.

4.2 Controle Preditivo Econômico Híbrido

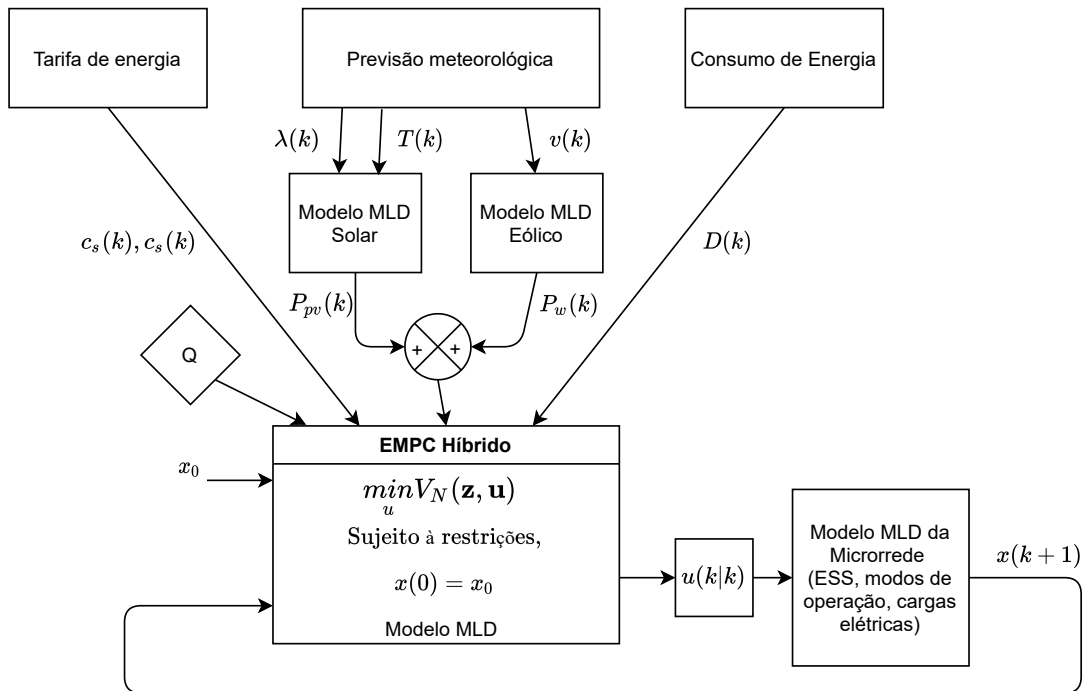
O EMPC, formulado na Seção 2.2.2, contém uma função objetivo econômica sujeito as restrições da planta da mesma forma que o MPC clássico, isto é, sem considerar as

variáveis binárias e auxiliares descritas por sistemas híbridos. A MG proposta foi modelada como um sistema híbrido da classe DHA e convertido para o modelo MLD. Além disso, o gerenciamento da MG no curto prazo não prevê seguir *setpoints* e pontos ótimos de operação. Uma nova abordagem para o problema de controle dinâmico e econômico de processo vem sendo bastante estudada (GARCIA-TORRES; BORDONS, 2015), (PARISIO; RIKOS; GLIELMO, 2014). O controle preditivo econômico híbrido (*Hybrid Economic Model Predictive Control* - HEMPC) proposto consiste na junção das técnicas do HMPC e do EMPC para a resolução do problema econômico ótimo sujeito as restrições do modelo MLD. A abordagem proposta HEMPC resolve o problema de controle ótimo apresentado em (4.14), sujeito às restrições MLD em (2.1) no instante k , dado uma condição inicial $x_0 = x(k+1)$ e um horizonte de previsão N . O vetor de solução ótimo \mathbf{u} contém os controles $u(k), \dots, u(k+N-1)$, no entanto, com o princípio do horizonte de rolagem, aplicamos apenas $u(k)$ e descarta-se as ações de controle restantes. Na próxima amostra $k+1$, atualizam-se as condições iniciais $x_0 = x(k+1)$ e calcula-se uma nova sequência de ações de controle $u(k+1), \dots, u(k+N)$. Este procedimento é repetido em tempo real até que o horizonte de planejamento N_p seja alcançado.

$$\begin{aligned}
 P_N &= \min_u V_N(\mathbf{x}, \mathbf{u}) \\
 &\text{Sujeito às restrições,} \\
 \mathbf{x}(0) &= \mathbf{x}_0 \\
 \mathbf{x}(k+1) &= \mathbf{A}\mathbf{x}(k) + \mathbf{B}_1\mathbf{u}(k) + \mathbf{B}_2\delta(k) + \mathbf{B}_3\mathbf{z}(k) \\
 \mathbf{y}(k) &= \mathbf{C}\mathbf{x}(k) + \mathbf{D}_1\mathbf{u}(k) + \mathbf{D}_2\delta(k) + \mathbf{D}_3\mathbf{z}(k) \\
 \mathbf{E}_2\delta(k) + \mathbf{E}_3\mathbf{z}(k) &\leq \mathbf{E}_1\mathbf{u}(k) + \mathbf{E}_4\mathbf{x}(k) + \mathbf{E}_5
 \end{aligned} \tag{4.14}$$

Na Figura 4.1, descreve-se o procedimento de despacho econômico proposto. Primeiro, o HEMPC recebe os preços da eletricidade ($c_s(k)$ e $c_p(k)$), velocidade do vento ($v(k)$), irradiância ($\lambda(k)$), temperatura ($T(k)$) e previsões de demanda de carga ($D(k)$). A geração de energia eólica é calculada a partir do modelo MLD da turbina eólica apresentado nas equações (3.7), (3.8), (3.9) e (3.10) e a geração de energia PV é determinada a partir do modelo MLD em (3.5), (3.3) e (3.4). A soma das fontes renováveis é denominada $P_{RES}(k)$. O HEMPC também recebe as penalidades da função objetivo e a condição inicial, x_0 . O problema de otimização é resolvido de forma exata e o sinal de controle atual vai atuar no modo de operação da MG e nas cargas elétricas, controlando o SOC do banco de baterias. A seguir, a estratégia de horizonte de rolagem é aplicada a cada período de amostragem T_s com os novos estados medidos/estimados $\mathbf{x}(k+1|k+1) = \mathbf{x}_{k+1}$. Ao fazer isso, uma política de *feedback* é projetada.

Figura 4.1 – Diagrama de blocos do HEMPC.



Fonte: próprio autor.

4.2.1 Algoritmo HEMPC

No algoritmo a seguir, descreve-se a implementação do HEMPC na MG. A otimização é feita *online* a cada período de amostragem.

```

input :  $q_i, N, N_p, T_s, T(k), D(k), \lambda(k), v(k), x_0, c_s(k), c_p(k)$  parâmetros
1 Gera o modelo MLD do sistema ;
2 for  $i \leftarrow 1$  step  $T_s$  to  $N_p$  do
3   Calcula  $P_{pv}(k)$  e  $P_w(k)$ 
4   if  $\text{mod}(i, 10 \text{ min}) = 0$  then
5     Calcula as previsões meteorológicas, de demanda e das tarifas de energia
       para horizonte  $N$ 
6     Resolve o problema MILP para obter  $u_c(k)$ 
7     Implementa  $u_c(k|k)$  no sistema MLD da planta e atualiza as equações de
       estados
8   end
9   Volte para o passo 2
10 end

```

4.3 Discussão

No presente capítulo foi descrito a formulação da função objetivo baseado no método da soma ponderada *a priori*, isto é, as penalidades são definidas antes da resolução da função objetivo. Mostrou-se que esta função possui termos não lineares e que através do uso de proposições lógicas e de variáveis auxiliares foi possível converter a função objetivo em linear com o acréscimo de restrições no problema de otimização. Foi proposto a formulação do HEMPC que possui as restrições características do HMPC e a função objetivo econômica como no EMPC. No Capítulo 5, apresentam-se os resultados numéricos e análises de três estudos de casos, com destaque da aplicação do HEMPC no gerenciamento do despacho econômico da MG utilizando previsões meteorológicas gaussianas e previsões com modelos de mesoescala com características não gaussianas.

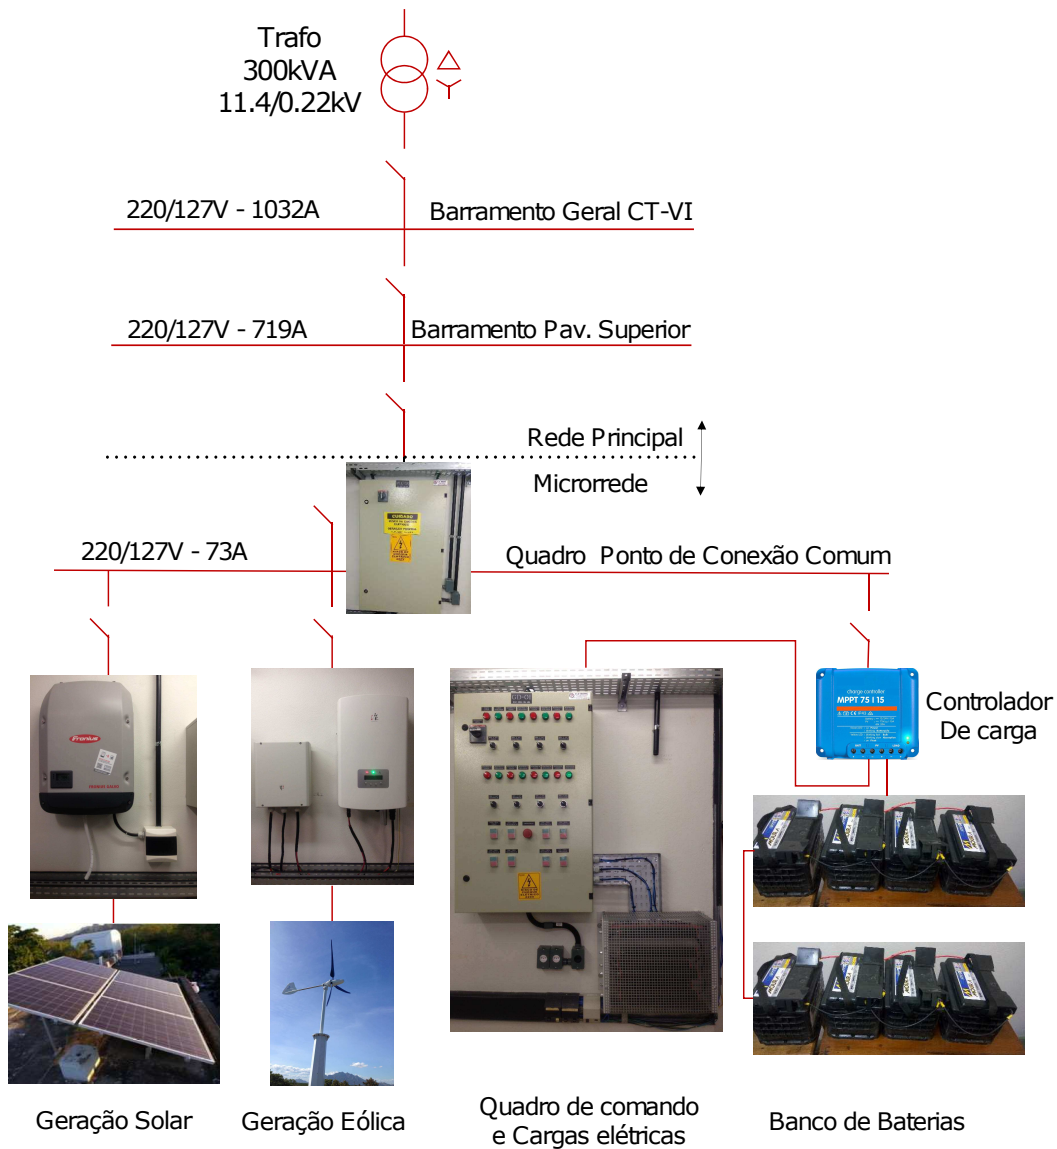
5 Resultados Numéricos e Análises

No presente Capítulo, apresentam-se três estudos de caso aplicados em uma mesma MG. Uma plataforma de simulação que integra os modelos híbridos dos equipamentos, apresentados no Capítulo 3, é o primeiro estudo de caso. A simulação deste caso é feita em malha aberta, ou seja, sem o gerenciamento. O objetivo é mostrar que os modelos propostos são coerentes com a operação de uma microrrede real. Nesta simulação são usados dados meteorológicos reais situados em diferentes localidades. No segundo estudo de caso a mesma MG é gerenciada através do HEMPC, que considera a previsão perfeita acrescida de incertezas gaussianas. O objetivo é analisar a sensibilidade do algoritmo proposto quando a variância do ruído é modificada a partir de zero (previsão perfeita) até um valor finito. No terceiro estudo de caso, o gerenciamento da MG é feito utilizando o modelo de previsão global e um comparativo entre três estratégias de gerenciamento: HEMPC, MILP-multiperíodo e estratégia baseada em regras que simula as decisões de um operador da microrrede (RBS). Estas duas últimas estratégias são comuns na literatura, conforme verifica-se em (de Oliveira Junior; PENA; SALLES, 2016), (BRUNI et al., 2016). Serão comparados a eficiência da MG em relação aos custos de O&M do banco de baterias, lucro com a venda de energia, desconforto do usuário devido ao descarte não programado de cargas e a operação segura da MG.

5.1 Integração dos Modelos e Simulação da MG

Os modelos híbridos do Capítulo 3 foram aplicados utilizando as especificações de uma MG real. Esta MG encontra-se instalada no Centro Tecnológico da Universidade Federal do Espírito Santo (UFES) em Vitória-ES Brasil. A Figura 5.1 mostra o diagrama unifilar simplificado. Os equipamentos consistem em uma fonte solar fotovoltaica, uma turbina eólica e uma carga com seis resistências ligadas individualmente. O quadro de comando das resistências está ligado a um controlador de carga. Este quadro além de efetuar a proteção das cargas, possui contadores, botoeiras e sinalizadores para que as cargas sejam ligadas de forma independente. O sistema de armazenamento de energia consiste em oito baterias ligadas em série e monitoradas pelo controlador de carga. A MG tem um quadro de conexão comum que faz a proteção e a interligação de todos os equipamentos. Do quadro de conexão comum vai para o ponto de conexão com a rede principal trifásica, 220 V, 60 Hz. Esta alimentação vem do barramento geral de um dos edifícios do centro tecnológico da UFES. A Tabela 6 mostra as principais especificações dos equipamentos elétricos.

Figura 5.1 – Diagrama Unifilar da conexão da MG com a rede da UFES.



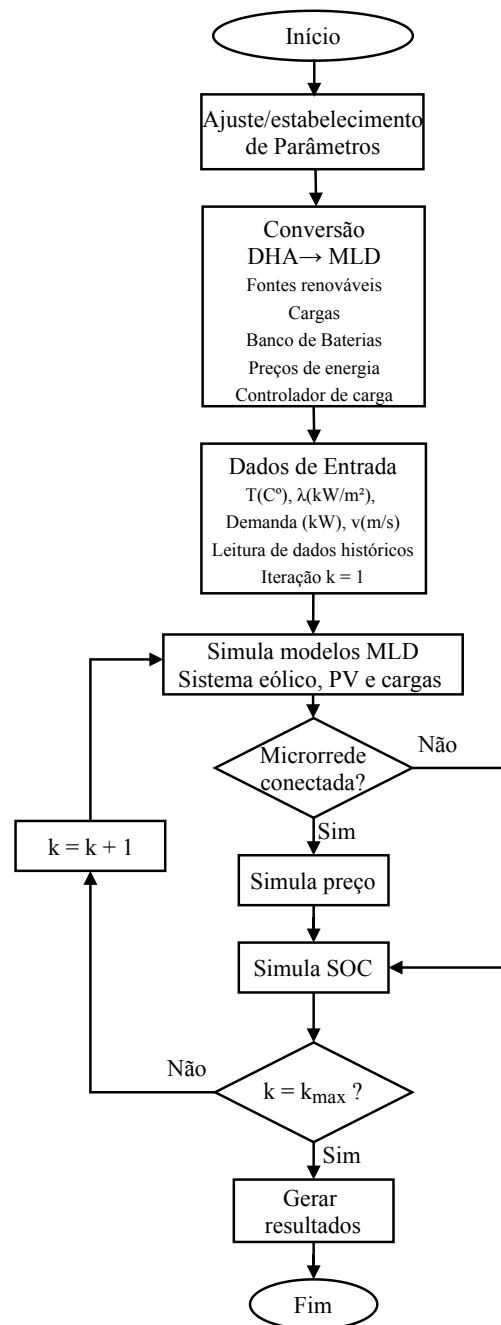
Fonte: próprio autor.

Tabela 6 – Principais especificações dos equipamentos elétricos da MG.

Especificação dos equipamentos	
Painéis PV	Seis painéis de 250 Wp de potência cada, modelo AC-250P/156-60S da Axitec. (AXITEC, 2009)
Inversor PV	2,0 kW de potência, tensão de saída 220 V, modelo <i>Fronius Galvo</i> 1.1-5 da Fronius. (FRONIUS, 2016)
Turbina Eólica	Aerogerador com 2,46 m de diâmetro de pá, 1,0 kW de potência, tensão de saída de 220 V, modelo <i>GERAR246</i> da Enersud. (ENERSUD, 2017)
Inversor Eólico	1,5 kW de potência, tensão de saída 220 V, modelo CO.LTD GCI-1.5kW da Ginlong. (GINLONG, 2014)
ESS	Oito baterias chumbo-ácida ventiladas, tensão de 12 V, 55 AH, modelo 12MF55 da Moura. (MOURA, 2016)
Cargas	Banco de seis resistores com 500 W de potência cada, 127 V, modelo BR6-500/127 da Denkhtherm.

A simulação proposta consiste em integrar os modelos MLD de cada equipamento da MG. Por exemplo, ao simular um instante de tempo do sistema de geração solar fotovoltaico, a potência de saída será uma entrada para o modelo do banco de baterias e para o modelo das tarifas de energia. É proposto um algoritmo que simula a operação da MG em malha aberta, sem gerenciamento ou controle, apenas as operações básicas de funcionamento inerentes a cada equipamento. O algoritmo associa todas as entradas e saídas de cada modelo e gera os gráficos da operação em tempo real. O fluxograma da Figura 5.2 representa o algoritmo proposto.

Figura 5.2 – Fluxograma do algoritmo da plataforma de simulação da microrrede.



Fonte: próprio autor.

Os resultados foram implementados utilizando códigos feitos no MATLAB e no HYSDEL. Foi utilizado um computador com processador Pentium i5-7400 CPU 3,00 GHz, 8 Gb de memória RAM e placa de vídeo NVIDIA Geforce GT 1030 de 2 Gb de memória. O tempo total de simulação da operação da MG é de 24 h e a taxa de amostragem é de 1 segundo. Os dados históricos reais de irradiância, temperatura, velocidade dos ventos e perfil de demanda foram utilizados das seguintes localidades:

- Laboratório de energias alternativas (LEAL) em Vitória-ES, Brasil: dados de irradiância, temperatura e velocidade dos ventos extraídos no dia 25 de março de 2017 da meia-noite até as 23:59h com taxa de amostragem de 1 minuto.
- Centro Nacional de Administração Oceânica e Atmosférica do Estados Unidos (NOAA): dados de irradiância, temperatura e velocidade dos ventos extraídos no dia 25 de março de 2007 da meia-noite até as 23:59h com taxa de amostragem de 1 minuto.
- Residência localizada em Aracruz-ES, Brasil: dados da curva de demanda extraída no dia 19 de setembro de 2014 das da meia-noite até as 23:59h com taxa de amostragem de 5 minutos.

As bases de dados do LEAL, NOAA e da curva de carga residencial foram reamostradas para rodar em uma taxa de amostragem de um segundo utilizando a interpolação linear (OPPENHEIM; SCHAFER; BUCK, 1999). Três Cenários de simulação foram propostos para validar a plataforma de simulação. Nos dois primeiros cenários foram utilizados os dados históricos do LEAL. No último cenário foram utilizados dados históricos do NOAA. A curva de carga é a mesma para todos os cenários. O controlador de carga atua da seguinte forma: quando o SOC do banco de baterias atingir 25%, todas as cargas elétricas são desabilitadas e a demanda vai a zero. As cargas elétricas só serão novamente habilitadas, cada uma podendo ou não estar ligada, quando o nível do banco de baterias atingir 80%. A turbina eólica, ao atingir a velocidade de corte, não para completamente. A rotação das pás é reduzida drasticamente e a geração permanece em um nível menor (ENERSUD, 2017). Neste caso, $P_{cutoff} = 50W$. A Tabela 7 mostra os valores numéricos utilizados na simulação.

Tabela 7 – Valores numéricos dos parâmetros utilizados na simulação.

Parâmetros	Valor	Unidade	Parâmetros	Valor	Unidade
v_{cutin}	2,0	m/s	P_{vmax}	1500	W
v_{cutoff}	16,0	m/s	S_{min}	0	-
v_n	12,0	m/s	S_{max}	1	-
P_n	1000	W	$S_{critical}$	0,25	-
P_{cutoff}	50	W	S_{save}	0,80	-
a_0	-80,20	W	S_{low}	0,005	-
a_1	72,43	-	S_{up}	0,995	-
a_2	-24,30	-	η	1,0	-
a_3	4,31	-	C_{max}	198000	A.s
a_4	-0,18	-	a_n	1,0	-
T_s	1,0	s			

5.1.1 Cenários de simulação


A plataforma de simulação em malha aberta proposta possui três cenários de simulação:

- Cenário 1: a MG opera no modo isolado e as condições iniciais são: SOC em 30%, controlador de carga no modo cargas habilitadas, potência gerada pela energia solar e eólica iguais a zero e cargas desligadas;
- Cenário 2: a MG opera conectada das 18:00h as 21:00h e isolada nos intervalos restantes. As condições iniciais são: SOC em 80%, controlador de carga no modo cargas habilitadas, potência gerada pela energia solar e eólica iguais a zero e cargas desligadas; e
- Cenário 3: a MG opera no modo isolado utilizando os dados históricos do NOAA. As condições iniciais são: SOC em 80%, controlador de carga no modo cargas habilitadas, potência gerada pela energia solar e eólica iguais a zero e cargas desligadas.

5.1.2 Discussão dos resultados da simulação em malha aberta


O Cenário 1 é mostrado na Figura 5.3 e conta com um SOC inicial do banco de baterias de 30%. Assim que a simulação se inicia as cargas são ligadas. Quando o SOC atingiu níveis menores que 25%, o controlador de carga atuou desabilitando todas as cargas por volta das 01:20h (ver Figura 5.3). O SOC das baterias permaneceu constante pela madrugada e começou a carregar com o início da geração fotovoltaica mostrado na Figura 5.4 .

Figura 5.3 – Cenário 1: SOC, modo de conexão da MG e o evento que habilita as cargas.



Fonte: próprio autor.


Figura 5.4 – Cenário 1: Geração de potência fotovoltaica e eólica.



Fonte: próprio autor.

A Figura 5.5 confirma que o controlador de carga desabilitou todas as cargas elétricas e o balanço de potência ficou zerado entre 01:20h e 7:00h. Sem demanda das cargas elétricas, as baterias começaram a carregar (balanço de potência negativo) com o início da geração PV (ver Figuras 5.4 e 5.5). Quando o SOC do banco de baterias atingiu 80%, o controlador de carga habilitou todas as cargas elétricas. Note que as cargas elétricas são chaveadas através do acionamento de contatores. O carregamento das baterias continuou de forma mais lenta até atingir o SOC máximo por volta das 15:55h.


Figura 5.5 – Cenário 1: Demanda das cargas e balanço de potência.



Fonte: próprio autor.

A transição entre estados do modelo do banco de baterias é mostrado na Figura 5.6. Por volta das 17:00h, a geração fotovoltaica começou a diminuir, o balanço de potência ficou positivo e conseqüentemente as baterias voltaram a descarregar.


Figura 5.6 – Cenário 1: Estados discretos de operação do banco de baterias. Note que o estado *reset* carregado gera um pulso para a transição entre os estados carregado e cíclico isolado.



Fonte: próprio autor.

A Figura 5.7 mostra que, devido a baixa velocidade dos ventos, os estados discretos da turbina eólica chaveiam entre sem geração (x_{wb1}) e operando abaixo da potência nominal (x_{wb2}). Neste Cenário tem-se o grande inconveniente do desconforto de não usufruir das cargas elétricas por mais de 10 horas. Por questões de segurança da MG, o controlador de cargas desabilita as cargas através da variável binária $\delta_L(k)$ para evitar que o banco de baterias descarregue e a operação da MG seja interrompida (ver Figura 5.3).


Figura 5.7 – Cenário 1: Estados discretos de operação da turbina eólica.



Fonte: próprio autor.


O Cenário 2 consiste em desconectar a MG da rede principal somente no horário de ponta compreendido entre as 18:00h e 21:00h. Os perfis de geração de energia das RES foram os mesmos do Cenário 1 (ver Figura 5.4). A Figura 5.8 mostra o SOC inicial em 80%. As baterias carregaram completamente por volta das 3:30h e permaneceram carregadas até as 18:00h. A Figura 5.9 mostra que a transição entre os estados discretos do banco de baterias foi ocasionada pela desconexão da MG da rede principal as 18:00h. Sem a geração solar após as 18:00h, o balanço de potência da Figura 5.10 está positivo e por isso o banco de baterias começou a descarregar. As 21:00h a MG se conectou com a rede principal e as baterias iniciaram o carregamento com a mudança do estado discreto cíclico isolado (x_{sb2}) para o estado cíclico conectado (x_{sb3}).

Figura 5.8 – Cenário 2: estado da carga do banco de baterias.




Fonte: próprio autor.

Figura 5.9 – Cenário 2: Estados discretos de operação do banco de baterias.



Fonte: próprio autor.


Figura 5.10 – Cenário 2: Demanda das cargas e balanço de potência.



Fonte: próprio autor.

A indicação de habilitação das cargas, modo de conexão da MG e o evento de compra e venda de energia são mostrados pela Figura 5.11. Na Figura 5.11a mostra que o modo de conexão vai a 0 entre 18:00h e 21:00h, indicando que a MG se desconectou da rede principal neste horário e as cargas elétricas não foram desabilitadas (ver Figura 5.11b). Quando a variável de compra e venda ($\delta_g(k)$) da Figura 5.11c foi para 1 significa que a MG vendeu o excesso energia para rede principal.


Figura 5.11 – Cenário 2: Variáveis binárias do modo de conexão da MG, habilitação das cargas e compra e venda de energia (0 é compra e 1 é venda de energia).



Fonte: próprio autor.

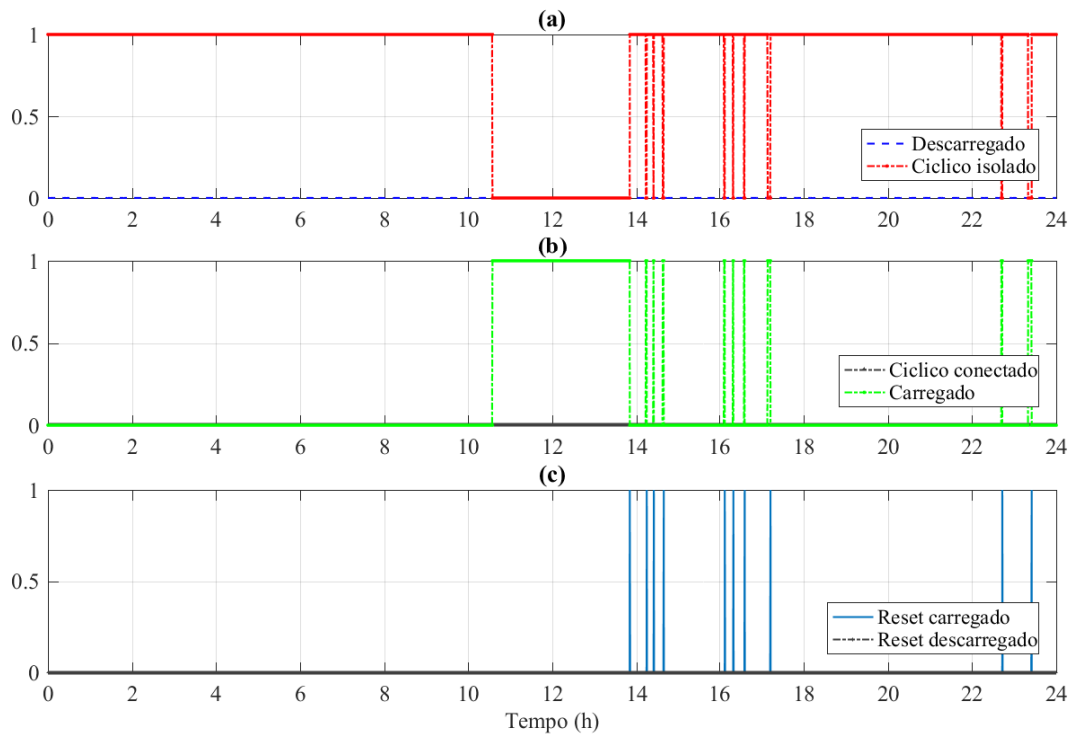
O Cenário 3 utilizou dados históricos de velocidade dos ventos, irradiância e temperatura do NOAA. O perfil de carga foi o mesmo do Cenário 2 e inicialmente as baterias estão 80% carregadas. A Figura 5.12 mostra a evolução do SOC das baterias e a Figura 5.13 mostra que o modelo da bateria operou, durante todo o período de simulação, entre os estados cíclico isolado e carregado.

Figura 5.12 – Cenário 3: SOC, modo de conexão da MG e o evento que habilita as cargas.



Fonte: próprio autor.


Figura 5.13 – Cenário 3: Estados discretos de operação do banco de baterias.



Fonte: próprio autor.

Na madrugada o balanço de potência da Figura 5.14 estava predominantemente positivo e o banco de baterias estava descarregando até as 07:00h. Neste horário a geração das RES se torna maior que o consumo de energia (balanço de potência negativo) fazendo o banco de baterias recarregar. O banco de baterias foi carregado completamente a partir das 10:30h da manhã e permaneceram próximos a este valor até o final do dia. O excesso de geração após o carregamento das baterias é perdido pela dissipação de energia nas resistências de amortecimento (*Dump load*) da turbina eólica.


Figura 5.14 – Cenário 3: Demanda das cargas e balanço de potência.



Fonte: próprio autor.

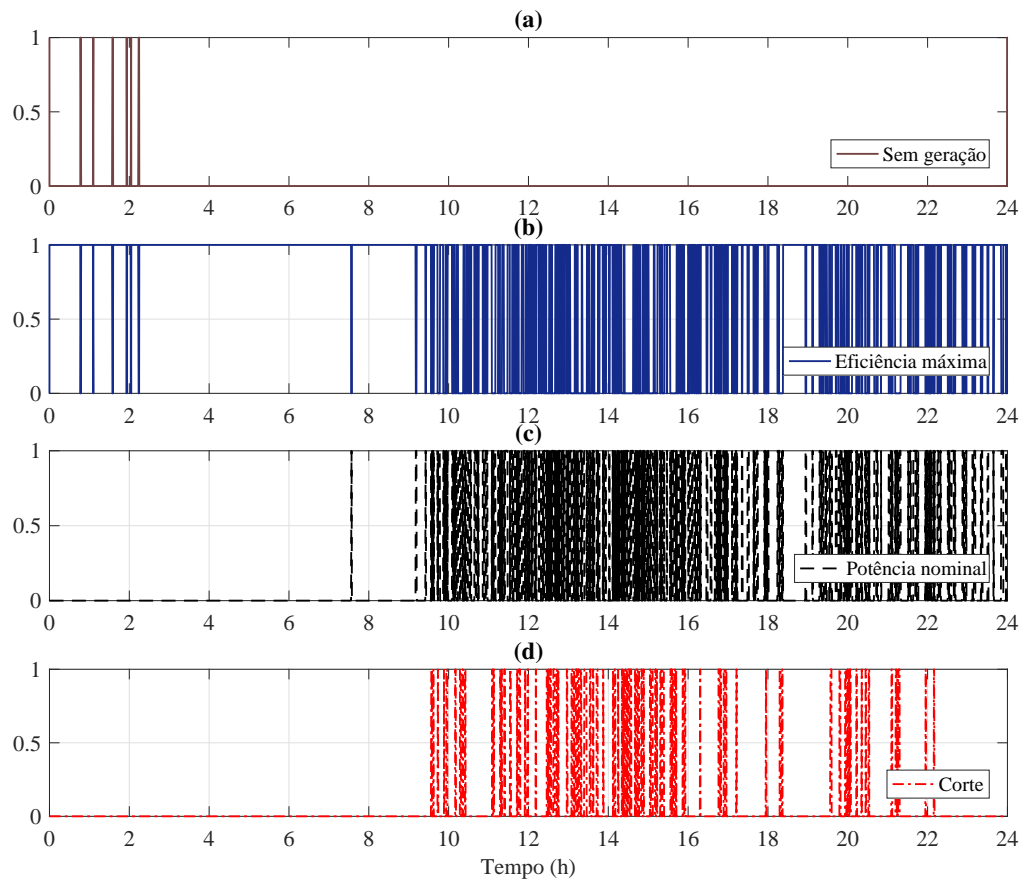
O balanço de potência, a potência consumida pelas cargas elétricas e a potência das RES são mostradas nas Figuras 5.14 e 5.15 respectivamente. Vale ressaltar que a curva solar foi retirada em março de 2007, no final do inverno nos EUA. Neste período o sol nasceu antes das 06:00h e se pôs por volta das 16:30h. Como o regime de ventos obtidos no NOAA apresenta velocidade dos ventos maiores que o regime de ventos do LEAL, a turbina eólica operou em todos os estados discretos possíveis (ver Figura 5.16), com predominância no regime nominal gerando potência máxima. A turbina também operou no regime de corte devido a rajadas de vento que superaram suas condições de segurança. A Figura 5.12 mostra que as cargas permaneceram habilitadas ao longo do dia bem como a MG permaneceu isolada nesse período. Este Cenário comprovou que um bom regime de ventos aliado a um dia ensolarado permite a MG operar no modo isolado com níveis de SOC seguros para o banco de baterias.

Figura 5.15 – Cenário 3: Geração de potência fotovoltaica e eólica.



Fonte: próprio autor.

Figura 5.16 – Cenário 3: Estados discretos de operação da turbina eólica.



Fonte: próprio autor.


5.2 Gerenciamento da MG

Na Seção 5.1 foi apresentado a modelagem integrada da MG e os resultados de simulação para diversos Cenários de operação. Esta modelagem foi feita em malha aberta e a MG operou somente com as especificações técnicas de cada equipamento. Neste estudo de caso o objetivo é aplicar o algoritmo HEMPC para resolver o problema de operação da MG a curto prazo enquanto satisfaz restrições operacionais e variantes no tempo. Nas subseções seguintes são apresentados os resultados numéricos através de uma previsão com dados arbitrários com incerteza gaussianoa e na seção 5.2.2 são apresentados os resultados numéricos do HEMPC considerando incertezas de previsão utilizando o modelo global WRF e o comparativo do HEMPC com as estratégias RBS e MILP-multiperíodo (MILPm).

5.2.1 HEMPC com incertezas meteorológicas gaussianas

Nesta seção analisa-se a sensibilidade do algoritmo de controle proposto em relação aos erros de previsão de dados meteorológicos gaussianos. Supõe-se que o erro de previsão de temperatura consiste em um ruído branco gaussiano de média zero e variância constante. O erro de previsão da irradiância consiste em um ruído branco com variância proporcional ao valor médio da irradiância. Supõe-se que o erro de previsão de velocidade dos ventos consiste em um ruído branco gaussiano de média zero e variância constante. Um exemplo de curvas reais e previstas de irradiância, temperatura e velocidade dos ventos utilizados neste estudo de caso são mostrados na Figura 5.17. Neste caso, a irradiância tem sua faixa de pico entre 09:00h e 14:00h, com média em torno de 550 W/m^2 . A temperatura mínima é de $1 \text{ }^\circ\text{C}$ e máxima de $7,4 \text{ }^\circ\text{C}$. Baixas temperaturas favorecem a geração fotovoltaica. A velocidade do vento média é de $6,3 \text{ m/s}$ com rajadas de vento superando os 18 m/s .

Figura 5.17 – (a) Irradiância, (b) temperatura e (c) curva da velocidade dos ventos em 24 h.




Fonte: próprio autor.

5.2.1.1 Análise dos dados meteorológicos previstos

Uma forma de se analisar as curvas de previsão é através da correlação entre os dados meteorológicos e a potência prevista das fontes renováveis. Neste estudo, esta correlação foi obtida através da função *corr2* do MATLAB. A correlação entre irradiância e potência prevista PV é de 0,95 e a correlação entre temperatura e potência PV é de 0,64. Estes valores indicam que a potência PV prevista tem uma dependência maior da irradiância do que da temperatura. Há técnicas descritas na literatura (GAO et al., 2019), (ZHENG et al., 2020) que são capazes de estimar a irradiância a partir das condições meteorológicas através de meta-heurísticas juntamente com séries temporais. Considere outros exemplos de dados reais de irradiância em um dia nublado mostrado na Figura 5.18. Supondo que o dia anterior seja de céu limpo. Aplicando uma técnica de previsão de irradiância que considera dias com sol, parcialmente nublados e dias com chuva é possível obter a previsão de potência PV com alta correlação com a irradiância. Porém, se somente os dados históricos de potência PV forem utilizados para previsão, considerando que o dia anterior é céu limpo e o dia atual está nublado, a potência PV prevista terá uma baixa correlação com a irradiância e conseqüentemente um erro maior que a previsão de potência obtida através de dados meteorológicos.


Figura 5.18 – Curva da irradiância em um dia nublado.



Fonte: próprio autor.

A potência eólica prevista possui um coeficiente de correlação de 0,56 com a velocidade dos ventos prevista. A baixa dependência entre velocidade dos ventos e potência prevista é causada pelos valores de saturações da potência da turbina com elevadas velocidades do vento. Por exemplo, dada uma turbina eólica que possui uma potência nominal de 1000 W entre 12 e 16 m/s de velocidade dos ventos, para uma velocidade prevista de 13 m/s com incerteza de ± 1 m/s vai gerar a mesma potência eólica prevista. Este fenômeno é confirmado na Figura 5.19 que mostra a potência eólica prevista em comparação com uma reta que representa uma distribuição gaussiana normal. Embora o erro de previsão da velocidade dos ventos possua distribuição gaussiana, o erro de previsão na potência eólica não possui distribuição gaussiana.

Figura 5.19 – Potência eólica prevista em comparação com uma distribuição gaussiana normal. Os pontos azuis fora da reta indicam que a potência eólica não tem distribuição Gaussiana




Fonte: próprio autor.

5.2.1.2 Curva das tarifas de energia

A Figura 5.20 mostra um exemplo de curva diária das tarifas de compra e venda de energia considerado neste estudo de caso. A tarifa de venda de energia é uma curva hipotética e se caracteriza por ter valores mais atrativos entre as 12:00h e 15:00h. A tarifa de compra é uma curva similar à tarifa branca da ANEEL (ANEEL, 2012). A tarifa de energia aumenta no horário de ponta compreendido entre 18:00h e 22:00h.

Figura 5.20 – Tarifas de compra e venda de energia elétrica em 24 h.



Fonte: próprio autor.

5.2.1.3 Curva de demanda

A demanda da MG tem uma característica semelhante a uma residência típica onde há cargas controláveis do tipo *on/off* e uma carga crítica de 0,25 kW que permanece sempre ligada. A demanda das cargas controláveis é apresentada em (5.1) e a curva de demanda é mostrada na Figura 5.21. Tais cargas podem ser desligadas a qualquer momento pelo algoritmo proposto, gerando uma demanda atendida.


$$\begin{aligned}
 [c_2(k) = 1] &\leftrightarrow [D_2 = 0.15 \text{ kW}] \\
 [c_3(k) = 1] &\leftrightarrow [D_3 = 0.20 \text{ kW}] \\
 [c_4(k) = 1] &\leftrightarrow [D_4 = 0.20 \text{ kW}] \\
 [c_5(k) = 1] &\leftrightarrow [D_5 = 0.30 \text{ kW}]
 \end{aligned} \tag{5.1}$$

Para avaliar o desempenho da formulação matemática em relação às cargas controláveis, foi criado o índice de conforto do usuário (CI) através da equação

$$CI = \frac{D_L^r}{D_L^s} 100 \% \tag{5.2}$$

em que D_L^r é a demanda atendida e D_L^s é a demanda real durante o horizonte de planejamento. A demanda atendida difere da demanda real quando o algoritmo de gerenciamento da MG descarta cargas para minimizar os custos operacionais. A demanda prevista (D_L^f) pode ser agendada com antecedência e representa um deslocamento temporal da demanda real e estes perfis se repetem a cada 24 h (consulte a Figura 5.21).

Figura 5.21 – Curvas da demanda real e da demanda prevista que considera que a programação das cargas foi adiantada em 2 horas.



Fonte: próprio autor.

5.2.1.4 Cenários de simulação

O algoritmo HEMPC proposto nesta seção possui três cenários de simulação:

1. Cenário 1: prioriza a conservação do banco de baterias através da penalidade q_{bat} em (4.1). Os dados meteorológicos de irradiância, temperatura e velocidade dos ventos foram extraídos do NOAA (NOAA, 2019);
2. Cenário 2: prioriza a venda de energia diminuindo o valor de q_{bat} em 10 vezes em relação ao Cenário 1. Os dados meteorológicos foram extraídos do NOAA;
3. Cenário 3: Assim como no Cenário 1, o Cenário 3 prioriza a conservação do banco de baterias. Os dados meteorológicos foram extraídos do LEAL da Universidade Federal do Espírito Santo.

O algoritmo proposto foi implementado usando MATLAB com os *toolboxes* do CPLEX e HYSDEL. O computador utilizado possui processador Intel Core i7-7700, 3,6Ghz, 16Gb RAM, Linux Unbutu 18.10 64 bits. A Tabela 8 mostra os parâmetros comuns usados em todos os cenários de simulação. O custo de O&M foi estimado através do número de ciclos e da autonomia de vida (em kWh) do banco de baterias especificado na Tabela 6 em função da profundidade de descarga de 0,5 que representa a diferença entre S_{max} e S_{crt} . Para o estado da carga do banco de baterias operando entre o SOC crítico e o SOC máximo, a eficiência de carga e descarga é considerada unitária. O SOC crítico baseia-se nas recomendações do fabricante para manter a profundidade da descarga mais baixa possível e para aumentar a vida útil das baterias. Nos dois primeiros Cenários o horizonte de previsão N é de 1 hora. A MG deve permanecer conectada por pelo menos 50 minutos ($T_{up} = 5$ amostras). Quando a MG desconectar, deve permanecer isolada por até 40 minutos ($T_{down} = 4$ amostras). Os tempos de conexão e desconexão da MG com a rede principal atendem aos limites da norma (IEEE. . . , 2018). A MG pode se conectar no máximo 3 vezes ($nc_{max} = 3$) a cada 24 h ($T_c = 144$ amostras). A corrente nominal do carregador do banco de baterias é de 3 A e as condições iniciais de operação são: SOC de 60% para o Cenário 1, SOC de 75% para o Cenário 2 e demais condições iniciais nulas.

Tabela 8 – Parâmetros comuns para todos os resultados.

Parâmetros	Valor	Unidade
N_p	24	h
η	1,0	pu
OM_b	0,28	U\$/kWh
P_g^{min}	-2,5	kW
P_g^{max}	2,5	kW
S_{min}	0,0	pu
S_{crt}	0,5	pu
T_s	10	min

No Cenário 3 o horizonte de previsão N é de 2 horas. A MG deve permanecer conectada por pelo menos 1 hora e 50 minutos ($T_{up} = 11$ amostras). Quando a MG desconectar, deve permanecer isolada por até 50 minutos ($T_{down} = 5$ amostras). A MG pode se conectar no máximo 3 vezes ($nc_{max} = 3$) a cada 24 horas ($T_c = 144$ amostras). A corrente nominal do carregador do banco de baterias é de 4,5 A e as condições iniciais de operação são: SOC de 75% e demais condições iniciais nulas.

Para todos os Cenários, os gráficos apresentados consideram erros de previsão meteorológica de 15% e uma demanda prevista com a programação adiantada em 2 h em relação à demanda real (consulte a Figura 5.21). Este deslocamento temporal representa um erro de previsão médio de 10%. As penalidades da função objetivo apresentadas na Tabela 9 foram definidas a *priori* de acordo com a prioridade estabelecida para cada cenário de simulação. O Cenário 2 que prioriza a venda de energia tem o menor q_{bat} em relação aos demais cenários. As penalidades $q_2 \cdots q_5$ se referem às cargas controladas pelos contadores $c_2 \cdots c_5$ mostrado em (4.12). No Cenário 1 a carga 3 possui maior prioridade em se manter ligada. No Cenário 2 as cargas têm a mesma prioridade e no Cenário 3 as cargas 2 e 5 têm maior prioridade que as cargas 3 e 4.

Tabela 9 – Valores dos pesos, definidos a *priori*, para cada Cenário de simulação.

Cenário →	1	2	3
q_{bat}	1	0,1	4
q_2	0,01	0,01	10
q_3	20	0,01	0,01
q_4	0,01	0,01	0,01
q_5	0,01	0,01	10
q_{crt}	100	100	100

5.2.1.5 Discussão dos resultados da simulação

A análise de sensibilidade é realizada em relação aos seguintes termos da função objetivo: custo global de otimização (J_N), índice de conforto (CI), custo do banco de baterias (C_{bat}), lucro da venda de energia (J_s) e custo da compra de energia (J_{pur}). Estes três últimos termos são definidos por:


$$C_{bat} = \sum_{k=1}^{N_p} J_{bat}(k) \quad (5.3)$$

$$J_s = \sum_{k=1}^{N_p} c_s(k)P_g(k), \text{ quando } u_g(k) = 1 \text{ e } \delta_g(k) = 0 \quad (5.4)$$

$$J_{pur} = \sum_{k=1}^{N_p} c_p(k)P_g(k), \text{ quando } u_g(k) = 1 \text{ e } \delta_g(k) = 1 \quad (5.5)$$

A Figura 5.22 mostra os resultados de simulação do Cenário 1. A evolução do SOC do banco de baterias e o modo de conexão da MG é mostrado na Figura 5.22a. No início da simulação o SOC diminuiu até atingir o SOC crítico. Para evitar uma descarga do banco de baterias abaixo do SOC crítico, a MG se conectou as 04:40h por 1 h e 30 minutos carregando as baterias. Às 06:00h a geração PV foi iniciada, a MG se isolou e o SOC aumentou e atingiu 80% às 14:00h. Após às 18:00h o SOC diminuiu em função da ausência de geração PV durante a noite. A demanda atendida e a demanda prevista são mostradas na Figura 5.22b. Os desligamentos de carga ocorreram durante os picos de geração RES para tornar a curva do SOC o mais suave possível, isto é, quanto menor a variação do SOC, menor será os custos do banco de baterias. A Figura 5.22c mostra a potência das RES e o balanço de potência durante as 24h de simulação. O balanço de potência iniciou positivo indicando que a demanda das cargas é maior que a geração RES. Quando a MG se conectou o balanço permaneceu positivo e a MG comprou energia da rede principal. Às 06:00h o balanço de potência se tornou negativo e o excesso de geração RES foi armazenado no banco de baterias. Esta tendência foi invertida às 18:00h quando a geração PV cessou.

Figura 5.22 – Cenário 1: ênfase na minimização do custo do banco de baterias.



Fonte: próprio autor.

Neste mesmo cenário foram realizados testes de desempenho do algoritmo HEMPC comparando diversos casos com erros de previsão com diversos valores percentuais. A Tabela 10 mostra o comparativo de valores entre o custo global (J_N), o custo da baterias

(C_{bat}), o lucro de venda de energia (J_s), o custo de compra de energia (J_p) e o índice de conforto do usuário (CI). Observe que os custos tiveram valores similares para diferentes valores do MAPE. Nas simulações com erros de previsão a MG se conectou à rede principal para comprar energia devido ao SOC crítico do banco de baterias. Este fenômeno não ocorre com a previsão perfeita, ou seja, quando não há erro de previsão. O índice de conforto do usuário foi significativamente maior nas simulações com erros de previsões meteorológicas. O custo de carga e descarga do banco de baterias está diretamente relacionado com o balanço entre geração e demanda. Quanto maior a diferença entre geração e demanda, maior será o custo da bateria. Se a prioridade em minimizar o custo do banco de baterias é maior do que o conforto do usuário, nos momentos de baixa geração algumas cargas necessitam ser desligadas para que a diferença entre geração e demanda seja mínima. Por isso a previsão perfeita possui um baixo custo do banco de baterias e um baixo índice de conforto em relação aos resultados com erros de previsão. Observa-se um aumento médio de 70% do custo do banco de baterias e um aumento médio de 37% do índice de conforto dos cenários com MAPE maiores que 0%. Além disso observa-se que o aumento do MAPE, a partir de 15%, pouco afetou os termos da função objetivo.

Tabela 10 – Sensibilidade dos termos da função objetivo para diferentes valores de MAPE para o Cenário 1.

MAPE (%)	J_N	C_{bat} (U\$)	J_s (U\$)	J_{pur} (U\$)	CI (%)
15%	3088,3	2,76	0,00	0,09	89,31
25%	3087,8	2,70	0,00	0,09	91,28
35%	3087,2	2,75	0,00	0,09	89,76
0%	1990,0	1,61	0,00	0,00	66,00

A Tabela 11 mostra uma análise de sensibilidade do HEMPC para erros de previsões dos dados meteorológicos e deslocamento temporal da demanda das cargas de forma individual. Esta análise consiste em simular o erro de previsão em apenas uma variável e utilizar dados históricos nas demais variáveis. As primeiras três linhas da Tabela 11 se referem a erros de previsões dos dados meteorológicos de temperatura, irradiância e velocidade dos ventos, respectivamente com MAPE de 15%. Na quarta linha se refere apenas a análise da demanda prevista (D_L^f) adiantada em duas horas em relação à demanda real. Isto equivale a um erro de previsão de 10%. Os números mostram que o HEMPC possui maior sensibilidade com o deslocamento temporal nas cargas do que com as incertezas dos dados meteorológicos. Observa-se um aumento médio de 104% do custo do banco de baterias e um aumento médio de 18% do índice de conforto do MAPE com erros de previsão em relação ao MAPE de 0%. Além disso observa-se que o erro de previsão de demanda teve um custo global 2% maior que os cenários com erros de previsão das variáveis meteorológicas, porém os demais termos da função objetivo não são muito sensíveis à mudança do erro de previsão em cada variável meteorológica.

Tabela 11 – Análise de sensibilidade da previsão meteorológica individual e do deslocamento da demanda em 2 horas para o Cenário 1.

Erro individual de previsão	J_N	C_{bat} (U\$)	J_s (U\$)	J_{pur} (U\$)	CI (%)
MAPE(T) = 15%	1990,4	3,30	0,09	0,00	77,90
MAPE(λ) = 15 %	1990,4	3,30	0,00	0,09	77,90
MAPE(v) = 15 %	1990,6	3,25	0,09	0,00	78,86
MAPE(D_L^f) = 10 %	2030,5	3,29	0,00	0,00	78,05
0%	1990,0	1,61	0,00	0,00	66,00

No Cenário 1 foi feita uma análise inserindo uma tendência no ruído branco. O teste consiste em obter a média de cada variável meteorológica de uma amostra de 24 h, multiplicar este valor da média pelo percentual de tendência e o resultado somar ao ruído branco. Neste caso a tendência é positiva de 15% em relação à média. A Tabela 12 mostra que os resultados obtidos foram bem próximos dos resultados da Tabela 11, sem tendência. Observa-se um aumento médio de 73% do custo do banco de baterias e um aumento médio de 34% do índice de conforto dos cenários com variância em relação ao MAPE de 0%. Além disso observa-se que a tendência de 15% pouco afetou os termos da função objetivo.


Tabela 12 – Sensibilidade dos termos da função objetivo para diferentes valores de MAPE para o Cenário 1 com uma tendência positiva de 15%.

MAPE	J_N	C_{bat} (U\$)	J_s (U\$)	J_{pur} (U\$)	CI (%)
15%	3088,3	2,71	0,00	0,09	89,36
25%	3087,9	2,79	0,00	0,09	88,85
35%	3087,5	2,79	0,00	0,09	88,85
0 %	1990,0	1,61	0,00	0,00	66,00

No Cenário 2 a prioridade de conservar o banco de baterias foi reduzida em 10 vezes, permitindo que a conexão da MG para vender energia à rede principal seja atrativo. A Figura 5.23a mostra os resultados do Cenário 2 para erros de previsão meteorológicos de 15% com adiantamento de 2 horas na previsão de demanda. O SOC diminuiu até amanhecer e aumentou após às 06:00h, quando iniciou a geração PV. Às 11:15h a geração das RES está próxima dos valores de pico do dia e a MG se conecta para vender energia e carregar o banco de baterias. Além disso, a tarifa de venda da Figura 5.20 é muito atrativa no intervalo de tempo que a MG permaneceu conectada. Após as 15:00h a MG se isolou e o SOC flutuou de acordo com o balanço entre geração RES e demanda das cargas. A Figura 5.23b mostra que alguns desligamentos de carga ocorreram durante o dia e no final da noite para evitar que o SOC do banco de baterias ultrapasse o SOC crítico. A Figura 5.23c mostra que o balanço de potência, durante a conexão da MG com a rede principal, se torna positiva. Isto ocorreu pois o banco de baterias está carregando e se torna uma carga adicional vista pela rede principal. Mesmo a MG comprando energia, o lucro com

venda de energia ocorreu devido ao alto preço de venda neste intervalo. Observa-se que os termos da função objetivo não são muito sensíveis a variância diferente de zero.

Figura 5.23 – Cenário 2: prioriza a venda de energia utilizando dados do NOAA.



Fonte: próprio autor.

A Tabela 13 mostra a comparação de desempenho do algoritmo entre a previsão perfeita e a previsão com erros gaussianos. O índice de conforto do usuário foi bem próximo aos 100% o que acarretou em menos penalizações e um custo global bem menor em relação ao Cenário 1. Além disso, os números mostram resultados similares para diferentes erros de previsão, com melhor desempenho no custo das baterias e menor custo de compra de energia.


Tabela 13 – Sensibilidade dos termos da função objetivo para diferentes valores de MAPE para o Cenário 2.

MAPE (%)	J_N	C_{bat} (U\$)	J_s (U\$)	J_{pur} (U\$)	CI (%)
15%	44,16	2,45	0,01	0,12	99,75
25%	44,22	2,52	0,02	0,14	99,75
35%	44,10	2,54	0,02	0,14	99,75
0%	41,83	2,38	0,02	0,03	93,06

O Cenário 3 estuda o caso de um dia nublado em uma região com baixa velocidade dos ventos. A Figura 5.24a mostra que o SOC do banco de baterias sempre diminuiu com

a MG isolada e quando o SOC atingiu o valor crítico, a MG se conectou três vezes em períodos de 2 horas para comprar energia. A demanda das cargas atendidas foi praticamente a mesma que a demanda real e não gerou desconforto ao usuário (ver Figura 5.24b). A Figura 5.24c mostra que a geração renovável foi muito baixa, forçando a MG se conectar à rede principal para carregar o banco de baterias.

Figura 5.24 – Cenário 3: conservação do banco de baterias utilizando os dados do LEAL.



Fonte: próprio autor.

A Tabela 14 mostra que custos globais de bateria e de compra de energia são bem superiores aos dos Cenários 1 e 2. Nas regiões com baixo potencial de geração solar e eólica, uma MG com estas configurações teria problemas com a viabilidade econômica. O custo de operação e manutenção com o banco de baterias é alto. Além disso, a MG precisa comprar energia periodicamente para garantir sua autonomia. Em comparação com os testes para diversas variâncias do erro de previsão gaussiano, houve um aumento médio de 64% do custo do banco de baterias e um aumento médio de 140% do custo de compra de energia das variâncias de 15% a 35% em relação ao MAPE de 0%. No entanto, o aumento da variância a partir de 15% pouco influenciou os termos da função objetivo.

Tabela 14 – Sensibilidade dos termos da função objetivo para diferentes valores de MAPE para o Cenário 3.

MAPE (%)	J_N	C_{bat} (U\$)	J_s (U\$)	J_{pur} (U\$)	CI (%)
15%	3065,2	4,71	0,00	0,12	99,14
25%	3065,2	4,71	0,00	0,12	99,14
35%	3065,7	4,71	0,00	0,12	99,14
0%	3065,1	2,88	0,00	0,05	99,54

Em todos os cenários foram feitos testes com horizontes de previsão mais longos, porém não houve mudança significativa nos resultados. Isto acontece devido à estabilidade e controlabilidade da MG por meio das cargas ou pela possibilidade da MG se conectar/-desconectar com a rede principal. Além disso, a estabilidade nos resultados do HEMPC proposto para horizontes previsão curtos gera menores custos computacionais. Por fim em todos os cenários o desempenho do HEMPC com diferentes erros variâncias dos erros de previsão gerou resultados similares. Isto mostra que o algoritmo HEMPC possui robustez a incertezas meteorológicas com distribuição gaussiana e estável para horizontes de previsão curtos. Vale ressaltar que a MG proposta, onde as fontes são renováveis e intermitentes, apresenta melhor desempenho quando o local possui bom potencial de geração solar e eólico.

5.2.2 HEMPC com incertezas utilizando modelo meteorológico não gaussiano

Nesta seção, o desempenho da estratégia HEMPC foi comparado com as seguintes técnicas de gerenciamento de microrredes:

1. RBS. Consiste em um conjunto de regras lógicas que simula um operador humano controlando a MG. A descrição deste algoritmo se encontra no Apêndice E.
2. MILPm. Consiste na solução de sucessivos problemas MILP com horizonte de previsão de 6 horas (4.1) até alcançar o horizonte de planejamento de 168 horas. A estratégia proposta resolve problema MILP a uma taxa de amostragem de 10 minutos e a atualização de dados é feita de 6 em 6 horas. Períodos maiores de horizonte de previsão levariam à explosão de memória computacional.

As estratégias HEMPC e MILPm são baseadas em horizonte de rolagem, porém o HEMPC atualiza os dados meteorológicos a cada período de amostragem e aplica a primeira solução do problema MILP no gerenciamento da MG (estratégia em malha fechada). No MILPm a atualização dos dados é feita após a solução de cada problema MILP e todas soluções obtidas são usadas no gerenciamento da MG (malha aberta ou estratégia míope (de Oliveira Junior; PENA; SALLES, 2016)).

Os dados meteorológicos reais de irradiância, temperatura e velocidade dos ventos foram extraídos do Instituto Nacional de Meteorologia (INMET) (INMET, 2020). O modelo *Weather Research and Forecasting* (WRF) (SKAMAROCK et al., 2019) é usado para estimativas de velocidade e direção do vento, temperatura do ar e radiação global. O modelo consiste em quatro telescópicos aninhados, com resoluções horizontais de 27 km no domínio mais externo (d01), 9 km no primeiro ninho (d02), 3 km no segundo ninho (d03) e 1 km no ninho mais interno (d04). A grade numérica foi configurada com 31 níveis verticais que seguem o terreno, com os seis primeiros níveis a aproximadamente 25 m, 58 m, 74 m, 89 m, 110 m e 141 m acima do solo. O WRF inicia automaticamente todos os dias às 02:00h (horário local), usando os dados das condições de contorno do *Global Forecast System* (GFS) (CAPLAN et al., 1997). O modelo é executado duas vezes, gerando previsão meteorológica no horizonte de previsão de 24 h com resolução de 10 minutos (10, 20, 30 . . . 1440 min) para Natal-RN (20,19 ° S e 40,2 ° W) e depois para Santa Vitória do Palmar-RS (33,742297 ° S e 53,372218 ° W). Para mais detalhes sobre a descrição dos dados de aquisição e previsão e como foram obtidos ver Apêndice F. A seguir é apresentado uma breve descrição de cada localidade.

1. Natal-RN. Situado na região nordeste do Brasil, possui um clima quente e úmido com temperaturas médias em torno de 28°C e velocidade dos ventos com média de 3,4 m/s. Em Natal, o verão é quente e de céu parcialmente encoberto; o inverno é curto, morno e de céu quase sem nuvens. Durante o ano inteiro, o tempo é opressivo, com precipitação e ventos medianos a fortes. A irradiância média é de 248 W/m².
2. Santa Vitória do Palmar-RS. Situado no extremo sul do Brasil, na fronteira com Uruguai. Possui clima ameno com temperaturas médias em torno de 18° C. A velocidade dos ventos tem média superior a 6,5 m/s, considerado bom para instalação de turbinas eólicas. Em Santa Vitória do Palmar, o verão é morno e abafado; o inverno é ameno. Durante o ano inteiro, o tempo é com precipitação, de ventos fortes e de céu parcialmente encoberto.

O desempenho do HEMPC é analisado para dois cenários de simulação.

1. Cenário 1: prioriza a conservação do banco de baterias através da penalidade q_{bat} em (4.1).
2. Cenário 2: prioriza a venda de energia diminuindo o valor de q_{bat} em 10 vezes em relação ao Cenário 1.

Além disso, os cenários propostos devem minimizar o custo de energia, o desperdício de energia renovável e o descarte de cargas, permitindo que a MG continue oferecendo serviços à rede principal e atenda às necessidades dos usuários.

A Tabela 15 mostra os valores dos parâmetros comuns para todos os Cenários de simulação. O valor da corrente $i_{ch}(k)$ do banco de baterias foi escolhido dentro de uma faixa de valores definida em (MOURA, 2016) para obter uma maior eficiência de carga e descarga. O valor do horizonte de previsão foi escolhido de forma a garantir o menor custo computacional sem comprometer a estabilidade do HEMPC. A operação da MG foi testada com horizonte de planejamento de uma semana para atender às recomendações de (AGÜERA-PÉREZ et al., 2018) que recomendaram testes de no mínimo 4 dias avaliando condições meteorológicas bem distintas, isto é, dias nublados e dias ensolarados, altas temperaturas e temperaturas amenas, baixa velocidade dos ventos e alta velocidade dos ventos. O custo O&M do banco de baterias foi estimado através relação do custo de compra do banco de baterias especificado na Tabela 6 dividido pelo tempo de vida útil. Para o estado da carga do banco de baterias operando entre o SOC crítico e o SOC máximo, a eficiência de carga e descarga são iguais a 0,95 de acordo com (ALRAMLAWI; GABASH; LI, 2017). O SOC crítico baseia-se nas recomendações do fabricante para manter a profundidade da descarga mais baixa possível e para aumentar a vida útil das baterias.

Tabela 15 – Parâmetros comuns para todos os resultados.

Parâmetros	Valor	Unidade
i_{ch}	3,5	A
N	1	h
N_p	168	h
η	0,95	pu
OM_b	0,078	U\$/kWh
P_g^{min}	-2,5	kW
P_g^{max}	2,5	kW
S_{min}	0,0	pu
S_{crt}	0,5	pu
T_s	10	min

As penalidades da função objetivo apresentadas na Tabela 16 foram escolhidas de acordo com a prioridade estabelecida para cada cenário de simulação. O Cenário 2 que prioriza a venda de energia tem o menor q_{bat} em relação ao Cenário 1. As penalidades $q_2 \cdots q_5$ referem-se às cargas controladas pelos contadores $c_2 \cdots c_5$ mostrado em (4.12). No Cenário 1 a carga 3 possui maior prioridade em se manter ligada e no Cenário 2 as cargas têm a mesma prioridade. As penalidades q_{crt} e q_{dump} estão com valores elevados para evitar ultrapassar o SOC crítico do banco de baterias e desperdiçar o excesso de geração renovável respectivamente.

Tabela 16 – Valores numéricos dos pesos para cada Cenário de simulação.

Parâmetros	Cenário		Unidade
	1	2	
q_{bat}	1	0,1	-
q_2	0,01	0,01	-
q_3	20	0,01	-
q_4	0,01	0,01	-
q_5	0,01	0,01	-
q_{crt}	100	100	-
q_{dump}	50	50	-

A Tabela 17 mostra os valores dos parâmetros de restrição da conexão da MG com a rede principal nc_{max} , T_{down} , T_{up} , T_c para cada local com sua condição meteorológica específica. Valores conservativos foram escolhidos para garantir que a tensão e a frequência no estado estacionário estejam dentro dos intervalos especificados em (IEEE. . . , 2018). Os intervalos mínimos de tempo τ_c e τ_i em (3.28) e 3.29 devem ser maiores que 600 s (10 min).

Tabela 17 – Valores numéricos dos parâmetros para cada localização com sua condição meteorológica específica.


Parâmetros	Santa Vitória	Natal	Unidade
nc_{max}	3	5	-
T_{down}	4	5	amostras
T_{up}	5	6	amostras
T_c	144	144	amostras

A curva diária de preço de energia elétrica e a curva de demanda são as mesmas apresentadas pelas Figura 5.20 e 5.21 respectivamente.

5.2.2.1 Análise dos dados meteorológicos

A Figura 5.25(a) mostra o valor atual da temperatura de uma localidade com média de 19,34°C e a temperatura prevista em uma semana. A temperatura mínima é de 12,0°C e máxima de 26,0°C. A Figura 5.25(b) mostra a curva do erro de previsão da temperatura com erro absoluto médio (MAE) de 1,51°C e erro relativo médio (MAPE) de 7,81%.


Figura 5.25 – (a) Curvas de temperatura real e prevista; (b) Erros de previsão de temperatura em uma semana.



Fonte: próprio autor.

A Figura 5.26(a) mostra o perfil de irradiância atual e a irradiância prevista. Neste caso, a irradiância tem sua faixa de pico entre 07:00h e 18:00h, com média em torno de $264,0 \text{ W/m}^2$. A Figura 5.26(b) mostra a curva do erro de previsão da irradiância com MAE de $60,0 \text{ W/m}^2$ e MAPE de 22,83%.


Figura 5.26 – (a) Curvas de irradiância real e prevista; (b) Erros de previsão de irradiância em uma semana.



Fonte: próprio autor.

O perfil da velocidade dos ventos é mostrado na Fig 5.27(a). A velocidade do vento média é de 6,71 m/s com rajadas de vento superando os 15,0 m/s. A Figura 5.27(b) mostra a curva do erro de previsão da velocidade dos ventos com erro absoluto médio de 1,78m/s e erro relativo médio de 26,60%.

Figura 5.27 – (a) Curvas de velocidade dos ventos real e prevista; (b) Erros de previsão de velocidade em uma semana.



Fonte: próprio autor.

Os dados meteorológicos obtidos através do modelo de previsão WRF foram convertidos em potência fotovoltaica e eólica através dos modelos matemáticos das subseções 3.1 e 3.2 respectivamente. Devido à diferença de altura entre a estação meteorológica e a turbina eólica, foi recalculado o vento real na turbina a partir de uma técnica de extrapolação apresentada no Apêndice D.

A Tabela 18 mostra as baixas correlações entre os erros de previsão de potência renovável e os dados meteorológicos obtidos nas estações de Santa Vitória-RS e Natal-RN.

Tabela 18 – Coeficientes de correlação entre potência e dados meteorológicos.

	Erros de potência PV vs erros de temperatura	Erros de potência PV vs erros de irradiância	Erros de potência eólica vs erros de velocidade dos ventos
Santa Vitória	0,03	0,71	0,64
Natal	0,14	0,53	0,65

Considerando a baixa correlação entre potência e dados meteorológicos das estações de Santa Vitória-RS e Natal-RN, conclui-se, através das estatísticas apresentadas nas Tabelas 19 e 20, que os erros de previsão das potências fotovoltaica e eólica são piores que os erros de previsão dos dados meteorológicos

Tabela 19 – Valores estatísticos da potência renovável e erros de previsão meteorológica em Santa Vitória do Palmar-RS.

Santa Vitória-RS		Média	MAE	MAPE (%)
Potência	Fotovoltaica	388,4 W	93,9 W	24,17
	Wind	482,0 W	248,6 W	51,58
Dados meteorológicos	Temperatura	19,31°C	1,51°C	7,81
	Irradiância	264,0 W/m ²	60,0 W/m ²	22,83
	Velocidade dos ventos	6,71 m/s	1,78 m/s	26,60


Tabela 20 – Valores estatísticos da potência renovável e erros de previsão meteorológica em Natal-RN.

Natal-RN		Média	MAE	MAPE (%)
Potência	Fotovoltaica	399,4 W	96,8 W	24,22
	Wind	96,7 W	67,3 W	69,58
Dados meteorológicos	Temperatura	28,31 °C	1,08 °C	3,82
	Irradiância	272,0 W/m ²	62,0 W/m ²	22,61
	Velocidade dos ventos	3,32 m/s	0,95 m/s	28,54

5.2.2.2 Simulação dos cenários

A seguir é discutido os resultados obtidos para cada cenário, considerando a previsão dos dados meteorológicos obtida pelo modelo WRF. A Figura 5.28(a) mostra a evolução do SOC do banco de baterias e o modo de conexão da MG para o Cenário 1 em Santa Vitória do Palmar durante uma semana de operação. Observa-se na Figura 5.28(b), que o balanço de potência em (3.27) é satisfeito porque é negativo quando há excesso de geração de energia. No caso de baixa geração de energia, o balanço tende a ser positivo ou próximo da origem do gráfico. Nas primeiras 72 h, há uma grande quantidade de energia renovável, como mostra a Figura 5.28 (b), que mantém o SOC da bateria em seu nível máximo durante a maior parte desse período. Quando o SOC atinge seu valor máximo, não há carregamento e descarregamento do banco de baterias, de modo que há um custo menor de O&M. Além disso, a MG vende energia durante a maior parte das primeiras 72 horas uma vez que o balanço de potência da Figura 5.28(b) é negativo. Entre o 4º e 6º dias (entre 72h e 144h) há baixa geração renovável o que faz a MG se conectar à rede principal para comprar energia e evitar que o banco de baterias atinja o SOC crítico. No final do 6º dia em diante a geração renovável é boa e o SOC aumenta devido a conexão da microrrede com a rede principal para vender o excesso de energia renovável, evitando que este excesso seja desperdiçado nas resistências de dissipação (*load dump*). Em todos os dias o algoritmo de otimização proposto não violou o número máximo de conexões nem o tempo mínimo que a MG deve permanecer conectada/desconectada da rede principal.


Figura 5.28 – Cenário 1: (a) Estado da carga, modo de conexão da MG; (b) Balanço de potência e potência das RES em uma semana.



Fonte: próprio autor.

A Figura 5.29 mostra a demanda real e a demanda atendida associado ao gráfico da Figura 5.28. A demanda atendida seguiu a curva da demanda real indicando que o HEMPC praticamente não descartou cargas.

Figura 5.29 – Cenário 1: Demanda real e atendida em uma semana.




Fonte: próprio autor.

A Figura 5.30 mostra o resultado de simulação para o Cenário 2 na localidade de Santa Vitória do Palmar. Neste Cenário as durações do tempo que a microrrede permanece conectada foram maiores que no Cenário 1. Com isso o SOC das baterias da Figura 5.30(a) permaneceu muitas horas no SOC máximo. Com isso a MG vende mais energia que no Cenário 1, mas também compra mais energia nos instantes que o balanço de potência da Figura 5.30(b) se torna positivo. Além disso, o balanço de potência tem uma oscilação

mais suave que no Cenário 1 entre o 4º e 6º dias (72 h e 144 h), dias de pouca geração de potência renovável.

Figura 5.30 – Cenário 2: (a) Estado da carga, modo de conexão da MG; (b) Balanço de potência e potência das RES em uma semana.



Fonte: próprio autor.

A demanda atendida teve comportamento similar ao Cenário 1 e o HEMPC praticamente não descartou cargas.

5.2.2.3 Análise de sensibilidade do HEMPC em relação aos erros de previsão

A análise de sensibilidade é realizada em relação aos seguintes termos da função objetivo: índice de conforto (CI), custo do banco de baterias (J_{bat}), lucro da venda de energia (J_s), custo da compra de energia (J_{pur}) e custo de desperdício de energia (J_{dump}). Este último termo é definido por

$$J_{dump} = \sum_{k=1}^{N_p} c_s(k) P_g(k), \text{ quando } \delta_{dump}(k) = 1. \quad (5.6)$$

Além disso, é definido o lucro como a diferença entre venda, compra e desperdício de energia

$$profit = J_s - J_{pur} - J_{dump}. \quad (5.7)$$

Para avaliar o impacto de erros de previsão meteorológica e erros de previsão de acordo com a programação das carga no algoritmo HEMPC proposto, foram definidas diferentes estratégias de previsão desses dados:

- F1 O HEMPC foi simulado com a previsão dos dados meteorológicos e a programação das cargas foi adiantada em 2 h.
- F2 O HEMPC foi simulado com a previsão dos dados meteorológicos, mas a programação das cargas é conhecida.
- F3 Todos os dados meteorológicos e a programação das cargas são conhecidos, isto é, não há erros de previsão (previsão perfeita).

O algoritmo HEMPC com a estratégia F3 é determinística e pode ser considerado como a referência. A Tabela 21 apresenta os resultados dos termos da função objetivo para os diferentes cenários de previsão e mostra que a MG precisou comprar energia em todos os cenários, considerando o HEMPC com todas as estratégias de previsão avaliadas. No entanto, em Natal, houve prejuízo financeiro para não violar o SOC crítico e prejudicar a vida útil do banco de baterias, uma vez que no período testado não havia geração eólica suficiente. Além disso, em todos os cenários e estratégias de previsão do HEMPC, tanto em Natal quanto em Santa Vitória, são observados um alto nível de conforto (menos de 1% da demanda não foi atendida) e não houve desperdício de energia devido ao excesso geração renovável. Para a estação meteorológica de Natal, observa-se para cada cenário (minimizando o custo de O&M das baterias ou vendendo energia) que os termos (J_{bat}), (J_s), (J_{pur}) não variam muito quando as estratégias de previsão são modificadas. Isso mostra que o algoritmo HEMPC é pouco sensível a erros de previsão devido à baixa geração de energia eólica em Natal.

No entanto, devido à estação de Santa Vitoria do Palmar ter uma boa produção de energia solar, com excelente produção de energia eólica, observa-se na Tabela 21 que, nesse local, o algoritmo de otimização proposto vende 10 vezes mais energia do que em Natal-RN, e o custo de operação do banco de baterias é 39,6% menor. Diferente de Natal, onde a MG se conecta à rede principal para evitar ultrapassar o SOC crítico, a conexão da rede em Santa Vitória permite a venda do excesso de energia gerada, uma vez que as baterias permanecem carregadas por um longo período, como mostra a Figura 5.30. Em Santa Vitória, os termos da função objetivo apresentam maiores variações quando as três estratégias de previsão do HEMPC são comparadas. Pode ser observado também que a previsão perfeita (F3) obteve um lucro relativo 19,5 % maior, em média, do que a estratégia de previsão F2 com o banco de baterias custando 27,4% mais.

Tabela 21 – Sensibilidade dos termos da função objetivo com relação aos erros de previsão para os Cenário 1 e 2 em uma semana.

Local	Cenários	Previsão	C_{bat} (U\$)	J_s (U\$)	J_{pur} (U\$)	J_{dump} (U\$)	$profit$ (U\$)	CI (%)
Natal Brasil	1	F1	6,91	0,02	0,64	0,00	-0,62	100,00
		F2	6,89	0,02	0,64	0,00	-0,62	100,00
		F3	6,76	0,02	0,66	0,00	-0,64	100,00
	2	F1	7,19	0,04	0,52	0,00	-0,48	99,56
		F2	7,18	0,04	0,52	0,00	-0,48	99,56
		F3	6,99	0,05	0,61	0,00	-0,57	99,93
Santa Vitória Brasil	1	F1	5,44	0,45	0,15	0,00	0,30	99,37
		F2	5,24	0,47	0,17	0,00	0,31	99,56
		F3	6,08	0,44	0,10	0,00	0,34	99,56
	2	F1	4,10	0,67	0,25	0,00	0,42	99,56
		F2	3,77	0,69	0,31	0,00	0,38	99,56
		F3	5,39	0,60	0,12	0,00	0,48	99,56


Portanto, conclui-se que a sensibilidade do algoritmo proposto em relação ao erro de previsão é maior em cenários de maior produção de energia renovável. No entanto, esse aumento de sensibilidade não é muito significativo quando se verifica que os erros de previsão na potência renovável considerado na estratégia F1 são altos (consulte Tabelas 19 e 20).

5.2.2.4 Comparação do algoritmo proposto com outras estratégias de gerenciamento

As Figura 5.31(a) e 5.32(a) mostram os níveis do SOC de Natal e Santa Vitória, respectivamente, para o Cenário 1. Note que, devido a baixa geração em Natal, o SOC oscila em torno do nível crítico ($S_{crt} = 0,5$) para as estratégias MILPm e RBS e acima do nível crítico para o HEMPC. Como a geração em Santa Vitória é elevada, HEMPC e RBS operam acima do SOC crítico e o MILPm viola o SOC crítico somente no início da simulação. As Figura 5.31(b) e 5.32(b) mostram os balanços de energia em Natal e Santa Vitória respectivamente. Note que o balanço de potência é predominantemente positivo em Natal e predominantemente negativo em Santa Vitória, ou seja, vende-se mais energia em Santa Vitória e compra-se mais energia em Natal. Isso pode ser observado na Tabela 22, onde se mostra que todas as estratégias tiveram prejuízo em Natal e somente o HEMPC realiza lucro em Santa Vitória. Isto se deve ao fato de que as estratégias MILPm e RBS em Santa Vitória não fizeram um bom gerenciamento da energia, pois o excesso de energia renovável foi desperdiçada, provocando prejuízo. Observe também na Tabela 22 que o CI do RBS ficou abaixo de 94,69% em Santa Vitória, enquanto que o MILPm e HEMPC tiveram um atendimento à demanda superior a 99% em todos os cenários (o MILPm teve um índice de conforto médio de 0,3% maior que o HEMPC e 13% maior que o RBS). Apesar do RBS possuir um menor índice de atendimento à demanda, seu


custo de bateria em Natal foi o menor, ou seja, esta estratégia preferiu descartar carga para conservar o banco de baterias quando ocorre baixa geração de energia. Porém, em Santa Vitória o custo médio da bateria do HEMPC foi menor que o das outras estratégias (para o RBS, o custo médio da bateria foi 10,3% maior e o MILPm foi 7,5% maior do que o HEMPC). Portanto, o gerenciamento da MG para cenários com maior geração de potência, o HEMPC é o mais eficiente.

Figura 5.31 – Comparação entre estratégias de gerenciamento da MG em Natal-RN (a) Nível do SOC; (b) Balanço de potência e potência das RES.



Fonte: próprio autor.

Figura 5.32 – Comparação entre estratégias de gerenciamento da MG em Santa Vitória-RS (a) Nível do SOC; (b) Balanço de potência e potência das RES.



Fonte: próprio autor.

A Tabela 23 compara os índices de segurança operacional da MG definidos pelo SOC mínimo (SOC_{min}) obtido durante o período de simulação, o período de tempo em que o SOC ficou abaixo do SOC crítico (T_{cr}), e a relação percentual entre T_{cr} e o tempo total de simulação (PT_{cr}). Nota-se que o nível do SOC do MILPm (Tabela 23) atingiu valores menores que o SOC crítico durante um longo período de tempo, principalmente no cenário de baixa geração de energia. Assim, a estratégia MILPm possui maior risco operacional já que a operação do banco de baterias em níveis muito baixos durante um longo período de tempo diminui a confiabilidade da operação da MG. Por outro lado, no HEMPC observa-se que o nível mínimo do SOC ficou próximo de 0,5, o T_{cr} médio é de 90 minutos em Natal e de 10 minutos em Santa Vitória (PT_{cr} iguais a 1,4% e 0,1%, respectivamente). Portanto, o HEMPC é mais seguro em qualquer cenário pois o MILPm teve tempo operacional abaixo do SOC crítico 19,7 vezes maior que o HEMPC e o RBS 4,3 vezes maior que o HEMPC.

Tabela 22 – Comparação do desempenho do HEMPC com as estratégias MILPm e RBS.

Local	Cenários	Estratégias	C_{bat} (US\$)	J_s (US\$)	J_{pur} (US\$)	J_{dump} (US\$)	Lucro (US\$)	CI (%)
Natal Brasil	1	RBS	6,82	0,25	4,70	0,00	-4,45	92,52
		MILPm	8,50	0,01	5,63	0,00	-5,62	100,00
		HEMPC	7,37	0,17	5,63	0,00	-5,46	99,57
	2	RBS	5,80	0,18	3,61	0,01	-3,44	80,26
		MILPm	7,29	0,40	7,51	0,68	-7,79	100,00
		HEMPC	7,71	0,34	4,35	0,00	-4,01	99,61
Santa Vitória Brasil	1	RBS	6,53	1,58	0,33	1,92	-0,67	94,69
		MILPm	7,35	0,42	2,42	2,26	-4,26	99,92
		HEMPC	6,46	4,70	0,62	0,01	4,07	99,91
	2	RBS	6,08	1,85	0,18	2,14	-0,47	89,15
		MILPm	4,93	1,25	4,97	3,48	-7,20	100,00
		HEMPC	4,96	6,74	2,01	0,00	4,73	99,93

Tabela 23 – Comparação dos índices de segurança operacional da microrrede entre as estratégias HEMPC, MILPm e RBS.

Local	Cenários	Estratégia	SOC_{min}	T_{cr} PT_{cr} (min)	Crítico (%)
Natal Brasil	1	RBS	0,38	710	7,04
		MILPm	0,32	4380	43,45
		HEMPC	0,49	110	1,09
	2	RBS	0,49	210	2,08
		MILPm	0,43	210	2,08
		HEMPC	0,49	70	0,69
Santa Vitória Brasil	1	RBS	0,49	20	0,20
		MILPm	0,30	530	5,26
		HEMPC	0,49	20	0,20
	2	RBS	0,54	0	-
		MILP	0,46	100	0,99
		HEMPC	0,53	0	-

5.2.3 Custo computacional

A solução HEMPC, feita através de uma otimização exata, requer um tempo computacional proporcional ao horizonte de previsão. Observe na Tabela 24 que o tempo computacional para resolver o problema de otimização para horizontes menores ou iguais a 8 h é muito menor que a taxa de amostragem (10 min ou 600 s). Não é recomendado a previsão de horizontes maiores que 8 horas, porque o tempo computacional para resolver o problema MILP aumenta consideravelmente. Este aumento pode levar à falta de memória pelo grande número de variáveis de decisão e de restrições, não restando tempo suficiente para o algoritmo executar previsões durante o período de amostragem de 10 minutos. Outra

vantagem do uso de horizontes de previsão inferiores ou iguais a 8 horas é a possibilidade de usar modelos de previsão mais precisos (FOLEY et al., 2012; ANTONANZAS et al., 2016).

Tabela 24 – Custo computacional entre iterações para diversos horizontes de previsão.

N (h)	N. de variáveis de decisão	Número de restrições	Tempo médio (s)	Pior tempo (s)	Memória (MB)
1	42	552	3,4	3,6	507
3	126	1656	3,5	3,7	521
6	252	3312	11,1	11,4	565
8	336	4968	26,4	27,0	741

6 Conclusões

Neste trabalho, apresentou-se uma nova formulação do controle preditivo econômico híbrido para o gerenciamento de uma microrrede isolada, capaz de se conectar/desconectar com a rede principal, com autonomia na tomada de decisão em todos os cenários simulados. Novos modelos híbridos de geração de energia eólica e solar foram propostos para calcular a potência renovável usando dados meteorológicos, como irradiância, temperatura e velocidade do vento de qualquer local do mundo. O novo modelo de banco de baterias proposto considera que a rede principal vê o banco de baterias como uma carga elétrica quando a microrrede está conectada, permitindo o seu carregamento.

Uma plataforma de simulação de uma microrrede em malha aberta foi desenvolvida para integrar cada equipamento como um sistema dinâmico lógico misto que contempla as variáveis contínuas, variáveis binárias, variáveis inteiras e as restrições operacionais. Foram propostos 3 cenários de simulação em malha aberta utilizando dados históricos reais de irradiância, temperatura, velocidade dos ventos de bases de dados extraídos de Vitória-Brasil e do NOAA. Os resultados de simulação mostraram, de forma bem sucedida, a operação da microrrede em malha aberta. A microrrede operou sem gerenciamento e algumas situações de emergência ocorreram durante a simulação. No Cenário 1 as cargas foram desabilitadas por mais de dez horas para evitar que o nível do SOC ficasse crítico e comprometesse a operação da microrrede. Nos cenários que a microrrede estava conectada com a rede principal, houve períodos de compra e venda de energia. Neste caso, não houve qualquer gerenciamento para otimizar o melhor período de venda e minimizar a compra de energia. Uma microrrede sem gerenciamento opera somente de acordo com o funcionamento de cada equipamento e a energia comprada e vendida depende do balanço de potência entre a demanda e a potência RES que, por sua vez, depende dos dados meteorológicos. A falta de gerenciamento pode acarretar em baixa eficiência na gestão de custos operacionais, na segurança operacional da microrrede e no desconforto para o usuário em situações de emergência que poderiam ser evitadas.

Para o gerenciamento da microrrede, a função objetivo proposta contempla uma nova formulação de custos operacionais relacionados ao banco de baterias, desperdício do excesso de energia renovável e conexão à rede principal para fornecer serviços ancilares, como a venda de geração excedente. Além disso, o modelo considera um limite máximo de ocorrências de conexões à rede e, depois que a MG realiza uma conexão, ela deve permanecer conectada à rede principal por um intervalo de tempo mínimo. Estas restrições oferecem flexibilidade para adaptar o algoritmo de controle a várias políticas de conexão de microrrede estabelecidas pela concessionária de energia elétrica.

O algoritmo proposto considerando incertezas gaussianas foi testado com erros relativos médios de 15%, 25% e 35% nas variáveis meteorológicas e de 10% na demanda prevista. Observa-se que o controle preditivo econômico híbrido é pouco sensível ao aumento da variância, inclusive com tendência. Além disso, o algoritmo proposto vende 10 vezes mais energia e o custo de operação do banco de baterias é 39,6% menor nos cenários de boa geração em relação aos cenários de baixa geração renovável. Nos cenários com baixa geração renovável a sensibilidade do algoritmo com incertezas gaussianas é menor em comparação com cenários de boa geração renovável.

O algoritmo proposto também foi testado considerando a previsão de dados meteorológicos em duas localidades utilizando o modelo WRF que gera incertezas não gaussianas. Observa-se que o erro de previsão da potência renovável é maior que o erro de previsão dos dados meteorológicos devido à baixa correlação entre essas grandezas. O erro da potência eólica é 126% maior que o erro da velocidade em Santa Vitória e 144% maior em Natal. Já o erro da potência fotovoltaica é 5,8% maior que o erro da irradiância em Santa Vitória e 7,1% maior em Natal. Além disso, o modelo WRF é capaz de fazer previsões meteorológicas em qualquer lugar do planeta, permitindo fazer estudos de viabilidade de implantação de qualquer sistema sem a necessidade de instalação física de estações meteorológicas de superfície.

O algoritmo proposto permite simular a operação da microrrede sob condições meteorológicas diferentes com três tipos de previsões e os estudos mostram que o controle preditivo econômico híbrido é pouco sensível em relação aos erros de previsão de dados meteorológicos. Nos cenários testados não houve desperdício do excesso de geração renovável e o índice de conforto ao usuário deixou de atender, em média, menos de 1% da demanda.

O algoritmo proposto é comparado com uma estratégia baseada em regras e a estratégia MILP multi-período em malha aberta. Em todos os comparativos o controle preditivo econômico híbrido não desperdiçou o excesso de energia. Na condição meteorológica que possui boa produção de energia renovável o controle preditivo econômico híbrido foi a única que obteve lucro financeiro positivo, em média 113% maior que a estratégia baseada em regras e 230% maior que o MILP multi-período, além de ter um índice de conforto 8% maior que a estratégia baseada em regras e no mesmo patamar que do MILP multi-período. Na condição meteorológica testada com menos produção de energia renovável a estratégia baseada em regras obteve desempenho melhor que o controle preditivo econômico híbrido nas despesas financeiras (custo médio de bateria 19,5% menor e lucro relativo 16,6% maior) e desempenho 13,2% pior no índice de conforto. Este resultado indica que a estratégia baseada em regras pode ser uma alternativa de implementação pela sua simplicidade. Já o MILP multi-período se destacou apenas no índice de conforto, onde obteve um desempenho médio 0,3% melhor que o controle preditivo econômico híbrido e 13% melhor que a estratégia baseada em regras.

O controle preditivo econômico híbrido é mais seguro em qualquer cenário pois o MILP multi-período e a estratégia baseada em regras tiveram tempos abaixo do estado da carga crítico 19,7 vezes maior e 4,3 vezes maior que o tempo do controle preditivo econômico híbrido respectivamente. Do ponto de vista de segurança operacional, atendimento à demanda e lucro com a venda de energia o controle preditivo econômico híbrido é a melhor estratégia.

Embora a solução de problemas de otimização usando modelos híbridos tenha um alto custo computacional, os resultados do algoritmo proposto permaneceram estáveis dentro do horizonte de planejamento com horizontes de previsão de 1 hora. Além disso, os resultados mostram que a otimização em tempo real é factível com períodos de amostragem de até 10 minutos. Por fim ressalta-se que o modelo WRF tem alto custo computacional e geralmente necessita de um servidor de alto desempenho. Assim, uma alternativa seria adquirir os serviços de previsão meteorológica de um agente externo público ou privado.

6.1 Trabalhos Futuros

A seguir uma relação de trabalhos futuros que visam contribuir com o andamento da pesquisa sobre o tema desta Tese:

1. Implementação da estrutura proposta em uma planta real, considerando as malhas de controle dos conversores.
2. Resolução da função objetivo utilizando algoritmos evolutivos e comparar seu desempenho com o algoritmo proposto que utiliza o método da soma ponderada.
3. Aquisição de dados reais de demanda e implementação do modelo de previsão e cálculo das incertezas para implementação no algoritmo proposto.
4. Inclusão de novos equipamentos na microrrede como célula a combustível e veículo elétrico.
5. Desenvolvimento de um formalismo matemático para provar a estabilidade em malha fechada bem como a factibilidade do algoritmo proposto.

Referências

ABEDINI, M.; MORADI, M. H.; HOSSEINIAN, S. M. Optimal management of microgrids including renewable energy sources using GPSO-GM algorithm. *Renewable Energy*, v. 90, p. 430 – 439, 2016. Citado na página 32.

AGÜERA-PÉREZ, A. et al. Weather forecasts for microgrid energy management: Review, discussion and recommendations. *Applied Energy*, v. 228, p. 265–278, 2018. Citado 7 vezes nas páginas 30, 31, 35, 38, 55, 77 e 114.

ALMEIDA, G. M.; SALLES, J. L. F. *CONTROLE PREDITIVO: Sintonia e aplicações na indústria*. 1. ed. Brasil: Editora Appris, 2016. Citado 2 vezes nas páginas 29 e 46.

ALRAMLAWI, M.; GABASH, A.; LI, P. Optimal operation strategy of a hybrid PV-battery system under grid scheduled blackouts. In: *IEEE International Conference on Environment and Electrical Engineering and IEEE Industrial and Commercial Power Systems Europe (EEEIC / I CPS Europe)*. Milan, Italy: [s.n.], 2017. p. 1–5. Citado 2 vezes nas páginas 34 e 114.

ANEEL. *Resolução Normativa N. 482*. 2012. [acessado dia 26 de abril de 2019]. Disponível em: <<http://www2.aneel.gov.br/cedoc/ren2012482.pdf>>. Citado 2 vezes nas páginas 26 e 103.

ANTONANZAS, J. et al. Review of photovoltaic power forecasting. *Solar Energy*, v. 136, p. 78 – 111, 2016. Citado na página 127.

ANTSAKLIS, P. J. Special issue on hybrid systems: theory and applications a brief introduction to the theory and applications of hybrid systems. *Proceedings of the IEEE*, v. 88, n. 7, p. 879–887, 2000. Citado 2 vezes nas páginas 32 e 43.

AXITEC. *Crystalline Photovoltaic Modules Installation and Operation Manual*. [S.l.], 2009. Disponível em: <www.axitecsolar.com/data/document_files/Manual_PT.pdf>. Citado na página 87.

BAE, I. S.; KIM, J. O. Reliability evaluation of customers in a microgrid. *IEEE Transactions on Power Systems*, v. 23, p. 1416 – 1422, 2008. Citado na página 30.

BELLIDO, M. H. et al. Barriers, challenges and opportunities for microgrid implementation: The case of Federal University of Rio de Janeiro. *Journal of Cleaner Production*, v. 188, p. 203–216, 2018. Citado 2 vezes nas páginas 26 e 31.

BEMPORAD, A.; MORARI, M. Control of systems integrating logic, dynamics, and constraints. *Automatica*, v. 35, p. 407–427, 1999. Citado 6 vezes nas páginas 40, 44, 46, 48, 78 e 81.

BEMPORAD, A.; TORRISI, F. D.; MORARI, M. Discrete-time hybrid modeling and verification of the batch evaporator process benchmark. *European Journal of Control*, v. 0,, p. 1–18, 2001. Citado na página 40.

- BORRELLI, F.; BEMPORAD, A.; MORARI, M. *Predictive Control for Linear and Hybrid Systems*. 1st. ed. Cambridge, England: Cambridge University Press, 2017. Citado 3 vezes nas páginas 44, 45 e 48.
- BRACCO, S. et al. A mathematical model for the optimal operation of the University of Genoa Smart Polygeneration Microgrid: Evaluation of technical, economic and environmental performance indicators. *Energy*, v. 64, p. 912–922, 2014. Citado na página 31.
- BRUNI, G. et al. Energy management in a domestic microgrid by means of model predictive controllers. *Energy*, v. 108, p. 119–131, 2016. Citado 4 vezes nas páginas 35, 37, 38 e 85.
- CAETANO, A. de O. *Controle Preditivo de Sistemas Híbridos*. Dissertação (Mestrado) — Universidade Federal de Uberlândia, Uberlândia-MG, 2011. Programa de Pós-graduação em Engenharia Química. Citado 2 vezes nas páginas 47 e 48.
- CAPLAN, P. et al. Changes to the 1995 NCEP operational medium-range forecast model analysis-forecast system. *Weather and Forecasting*, v. 12, p. 581–594, 1997. Citado na página 113.
- CARLONI, L. et al. *Modeling techniques, programming languages, and design toolsets for hybrid systems*. [S.l.], 2004. Citado na página 44.
- CHO, B. H. P. H. Design and analysis of a microprocessor-controlled peak-power-tracking system. *IEEE Transactions on Aerospace and Electronic Systems*, v. 32, p. 182–190, 1996. Citado na página 169.
- CHRISTO, T. M. de et al. Demand-side energy management by cooperative combination of plans: A multi-objective method applicable to isolated communities. *Applied Energy*, v. 240, p. 453–472, 2019. Citado na página 26.
- CLARKE, W. C.; MANZIE, C.; BREAR, M. J. An economic MPC approach to microgrid control. In: . Newcastle, NSW, Australia: IEEE, 2017. p. 276–281. Citado 2 vezes nas páginas 35 e 37.
- de Oliveira Junior, V. B.; PENA, J. G.; SALLES, J. L. An improved plant-wide multiperiod optimization model of a byproduct gas supply system in the iron and steel-making process. *Applied Energy*, v. 164, p. 462–474, 2016. Citado 2 vezes nas páginas 85 e 112.
- DOMENECH, B. et al. Local and regional microgrid models to optimise the design of isolated electrification projects. *Renewable Energy*, v. 119, p. 795–808, 2018. Citado na página 33.
- DURANA, J. Gonzalez de; BARAMBONES, O. Technology-free microgrid modeling with application to demand side management. *Applied Energy*, v. 219, p. 165–178, 2018. Citado na página 33.
- DUTTA, P. et al. A multiobjective optimization model for sustainable reverse logistics in indian e-commerce market. *Journal of Cleaner Production*, v. 249, p. 119348, 2020. Citado na página 50.

- EIA. *Electricity in the United States*. 2019. [acessado dia 18 de maio de 2020]. Disponível em: <www.eia.gov/outlooks/aeo/pdf/AEO2020%20Electricity.pdf>. Citado na página 25.
- EL-HENDAWI, M. et al. Control and EMS of a Grid-Connected Microgrid with Economical Analysis. *Energies*, v. 11, p. 20, 2018. Citado na página 39.
- ELSIED, M. et al. An advanced real time energy management system for microgrids. *Energy*, v. 114, p. 742–752, 2016. Citado na página 34.
- EMMERICH, M.; DEUTZ, A. A tutorial on multiobjective optimization: fundamentals and evolutionary methods. *Natural Computing*, v. 17, p. 585—609, 2018. Citado 4 vezes nas páginas 50, 52, 53 e 55.
- ENERGETIC RESEARCH COMPANY. *Statistical annual of electricity*. 2018. [acessado dia 10 de maio de 2020]. Disponível em: <epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/anuario-estatistico-de-energia-eletrica>. Citado na página 25.
- ENERSUD. *GERAR 246 instructions manual*. 2017. Disponível em: <<http://www.enersud.com.br/produtos/turbina-eolica-gerar-246/>>. Citado 3 vezes nas páginas 62, 87 e 89.
- ESEYE, A. T.; ZHANG, J.; ZHENG, D. Short-term photovoltaic solar power forecasting using a hybrid Wavelet-PSO-SVM model based on SCADA and Meteorological information. *Renewable Energy*, v. 118, p. 357–367, 2018. Citado na página 35.
- EUROSTAT. *Production of primary energy*. 2019. [acessado dia 18 de maio de 2020]. Disponível em: <ec.europa.eu/eurostat/statistics-explained/index.php/Energy>. Citado na página 25.
- FAN, S.; AI, Q.; PIAO, L. Fuzzy day-ahead scheduling of virtual power plant with optimal confidence level. *IET Generation, Transmission & Distribution*, v. 10, p. 205–212(7), 2016. Citado na página 30.
- FOLEY, A. M. et al. Current methods and advances in forecasting of wind power generation. *Renewable Energy*, v. 37, p. 1 – 8, 2012. Citado na página 127.
- FONTENOT, H.; DONG, B. Modeling and control of building-integrated microgrids for optimal energy management – a review. *Applied Energy*, v. 254, p. 113689, 2019. Citado na página 31.
- FRONIUS. *Fronius Galvo 208-240 operating instructions*. [S.l.], 2016. Disponível em: <www.fronius.com/~/downloads/Solar%20Energy/Operating%20Instructions/42%20C0410%20C1934.pdf>. Citado na página 87.
- GAO, M. et al. Day-ahead power forecasting in a large-scale photovoltaic plant based on weather classification using LST. *Energy*, v. 187, p. 115838, 2019. Citado 2 vezes nas páginas 35 e 101.
- GARCIA, M. J. P. *Uma Contribuição ao Controle de Sistemas Comutados*. Tese (Doutorado) — Universidade Federal de Santa Catarina, Florianópolis-SC, 2009. Programa de Pós-graduação em Engenharia de Automação e Sistemas (PG-EAS). Citado na página 47.

- GARCIA-TORRES, F.; BORDONS, C. Optimal economical schedule of hydrogen-based microgrids with hybrid storage using model predictive control. *IEEE Transactions on Industrial Electronics*, v. 62, p. 5195–5207, 2015. Citado 5 vezes nas páginas 30, 31, 37, 38 e 82.
- GAZIJAHANI, F. S.; SALEHI, J. Integrated DR and reconfiguration scheduling for optimal operation of microgrids using Hong's point estimate method. *International Journal of Electrical Power and Energy Systems*, v. 99, p. 481–492, 2018. Citado na página 34.
- GHANBARIAN, M. M. et al. Model predictive control of distributed generation micro-grids in island and grid connected operation under balanced and unbalanced conditions. *Journal of Renewable and Sustainable Energy*, v. 9, p. 0–17, 2017. Citado na página 37.
- GINLONG. *Wind Grid Tie Inverter GCI-2G-W Single Phase Inverter, installation and operation manual*. [S.l.], 2014. Disponível em: <http://fortiswindenergy.com/wp-content/uploads/2016/05/GCI-1-5K-2G-W-US_V2.pdf>. Citado na página 87.
- GRILLO, S.; PIEVATOLO, A.; TIRONI, E. Optimal Storage Scheduling Using Markov Decision Processes. *IEEE Transactions on Sustainable Energy*, v. 7, p. 755 – 764, 2016. Citado 2 vezes nas páginas 29 e 35.
- GU, W. et al. An Online Optimal Dispatch Schedule for CCHP Microgrids Based on Model Predictive Control. *IEEE Transactions on Smart Grid*, v. 8, p. 2332–2342, 2017. Citado 2 vezes nas páginas 35 e 37.
- HANNA, R. et al. Evaluating business models for microgrids: Interactions of technology and policy. *Energy Policy*, v. 103, p. 47–61, 2017. Citado na página 33.
- HAWKES, A.; LEACH, M. Modelling high level system design and unit commitment for a microgrid. *Applied Energy*, v. 86, p. 1253–1265, 2009. Citado na página 30.
- HEEMELS, W.; SCHUTTER, B. D.; BEMPORAD, A. Equivalence of hybrid dynamical models. *Automatica*, v. 37, p. 1085 – 1091, 2001. Citado 2 vezes nas páginas 43 e 44.
- HEIRUNG, T. A. N. et al. Stochastic model predictive control — how does it work? *Computers and Chemical Engineering*, v. 114, p. 158–170, 2018. Citado na página 30.
- HERATH, P. U. et al. Day-ahead power forecasting in a large-scale photovoltaic plant based on weather classification using LSTM. *IEEE Transactions on Industry Applications*, v. 55, p. 732–740, 2019. Citado na página 34.
- HONARMAND, M.; ZAKARIAZADEH, A.; JADID, S. Integrated scheduling of renewable generation and electric vehicles parking lot in a smart microgrid. *Energy Conversion and Management*, v. 86, p. 745–755, 2014. Citado na página 31.
- HOSSAIN, M. A. et al. Modified PSO algorithm for real-time energy management in grid-connected microgrids. *Renewable Energy*, v. 136, p. 746–757, 2019. Citado na página 34.
- IEEE Standard for Interconnection and Interoperability of Distributed Energy Resources with Associated Electric Power Systems Interfaces. *IEEE Std 1547-2018 (Revision of IEEE Std 1547-2003)*, v. 1, p. 1–138, 2018. Citado 2 vezes nas páginas 105 e 115.

IGUALADA, L. et al. Optimal energy management for a residential microgrid including a vehicle-to-grid system. *IEEE Transactions on Smart Grid*, v. 5, p. 2163–2172, 2014. Citado na página 32.

INMET. *National Institute of Meteorology*. 2020. [acessado dia 10 de maio de 2020]. Disponível em: <www.inmet.gov.br/portal/index.php?r=estacoes/estacoesAutomaticas>. Citado 2 vezes nas páginas 113 e 184.

ISMAIL, M. S. et al. *Effective utilization of excess energy in standalone hybrid renewable energy systems for improving comfort ability and reducing cost of energy: A review and analysis*. 2015. Citado na página 34.

JABBARI-SABET, R.; MOGHADDAS-TAFRESHI, S.-M.; MIRHOSEINI, S.-S. Microgrid operation and management using probabilistic reconfiguration and unit commitment. *International Journal of Electrical Power & Energy Systems*, v. 75, p. 328 – 336, 2016. Citado 2 vezes nas páginas 28 e 32.

JOHANSSON, K. H.; LYGEROS, J.; SASTRY, S. &. Modeling of hybrid systems. *Encyclopedia of Life Support Systems (EOLSS)*, p. 1–22, 2004. Citado na página 43.

KANG, B. O.; PARK, J. H. Kalman filter MPPT method for a solar inverter. In: . Urbana, IL, USA: IEEE, 2011. p. 1–5. Citado 2 vezes nas páginas 41 e 60.

KHAKIMOVA, A. et al. Hybrid model predictive control for optimal energy management of a smart house. In: . Rome, Italy: IEEE, 2015. p. 513–518. Citado 4 vezes nas páginas 35, 37, 38 e 48.

KRIETT, P. O.; SALANI, M. Optimal control of a residential microgrid. *Energy*, v. 42, p. 321–330, 2012. Citado na página 32.

KUMAR, R. H.; USHAKUMARI, S. A Novel Control Strategy for Autonomous Operation of Isolated Microgrid with Prioritized Loads. *Journal of The Institution of Engineers (India): Series B*, v. 99, p. 323–330, 2018. Citado na página 34.

KUROSAWA YUSUKE UCHIYAMA, T. K. K. Development of a numerical marine weather routing system for coastal and marginal seas using regional oceanic and atmospheric simulations. *Ocean Engineering*, v. 195, p. 106706, 2020. Citado na página 184.

LI, B.; ROCHE, R.; MIRAOU, A. Microgrid sizing with combined evolutionary algorithm and MILP unit commitment. *Applied Energy*, v. 188, p. 547 – 562, 2017. Citado na página 32.

LI, Z.; XU, Y. Optimal coordinated energy dispatch of a multi-energy microgrid in grid-connected and islanded modes. *Applied Energy*, v. 158, p. 6601–6606, 2018. Citado na página 34.

LIANG, H.; ZHUANG, W. Stochastic modeling and optimization in a microgrid: A survey. *Energies*, v. 7, p. 2027–2050, 2014. Citado 3 vezes nas páginas 25, 26 e 28.

LIANG, Y. et al. Stochastic control for smart grid users with flexible demand. *IEEE Transactions on Smart Grid*, v. 4, p. 2296–2308, 2013. Citado 2 vezes nas páginas 30 e 37.

- LIU, G. et al. Microgrid optimal scheduling with chance-constrained islanding capability. *Electric Power Systems Research*, v. 145, p. 197–206, 2017. Citado na página 34.
- Lo Prete, C. et al. Sustainability and reliability assessment of microgrids in a regional electricity market. *Energy*, v. 41, p. 192 – 202, 2012. Citado na página 30.
- Logenthiran, T.; Srinivasan, D. Short term generation scheduling of a microgrid. In: . Singapore, Singapore: IEEE, 2009. p. 1–6. Citado na página 30.
- MA, J.; MA, X. State-of-the-art forecasting algorithms for microgrids. In: . Huddersfield, UK: IEEE, 2017. p. 1–6. Citado na página 30.
- MACIEL, R. S. *Otimização multiobjetivo na análise da integração de geração distribuída às redes de distribuição*. Tese (Doutorado) — Universidade Estadual Paulista, Ilha Solteira-SP, 2012. Citado 3 vezes nas páginas 50, 51 e 55.
- MAGRO, M. C. et al. Real time simulator for microgrids. *Electric Power Systems Research*, v. 160, p. 381–396, 2018. Citado na página 33.
- MAKHADMEH, S. N. et al. Optimization methods for power scheduling problems in smart home: Survey. *Renewable and Sustainable Energy Reviews*, v. 115, p. 109362, 2019. Citado na página 34.
- MARINELLI, M. et al. Testing of a predictive control strategy for balancing renewable sources in a microgrid. *IEEE Transactions on Sustainable Energy*, v. 5, p. 1426–1433, 2014. Citado 2 vezes nas páginas 33 e 41.
- MARQUANT, J. F.; EVINS, R.; CARMELIET, J. Reducing computation time with a rolling horizon approach applied to a MILP formulation of multiple urban energy hub system. *Procedia Computer Science*, v. 51, p. 11, 2015. Citado na página 34.
- MASTERS, G. M. *Renewable and efficient electric power systems*. 2nd. ed. [S.l.]: John Wiley and Sons, 2013. ISBN 9781118140621. Citado na página 177.
- MAZIDI, M. et al. Integrated scheduling of renewable generation and demand response programs in a microgrid. *Energy Conversion and Management*, v. 86, p. 1118–1127, 2014. Citado na página 81.
- MELO, N. R. de. *Dimensionamento e simulação de uma microrrede em um condomínio residencial utilizando geração eólica e solar*. Tese (Doutorado) — Instituto Federal de Minas Gerais, Formiga-MG, 2016. Citado na página 26.
- MOGHIMI, H. et al. Stochastic techno-economic operation of power systems in the presence of distributed energy resources. *International Journal of Electrical Power & Energy Systems*, v. 45, p. 477–488, 2013. Citado na página 31.
- MOHAMED, A.; MOHAMMED, O. Real-time energy management scheme for hybrid renewable energy systems in smart grid applications. *Electric Power Systems Research*, v. 96, p. 133–143, 2013. Citado na página 31.
- MOHAMED, F. A.; KOIVO, H. N. System modelling and online optimal management of microgrid using mesh adaptive direct search. *International Journal of Electrical Power & Energy Systems*, v. 32, p. 398 – 407, 2010. Citado na página 30.

- MOURA. *Stationary Battery Technical Manual Clean Nano*. [S.l.], 2016. Disponível em: <moura-portal.s3.amazonaws.com/uploads/2017/07/MANUAL_CLEAN_NANO_V13_06_DEZ_16.pdf>. Citado 2 vezes nas páginas 87 e 114.
- MOUTIS, P.; HATZIARGYRIOU, N. D. Decision trees-aided active power reduction of a virtual power plant for power system over-frequency mitigation. *IEEE Transactions on Industrial Informatics*, v. 11, p. 251–261, 2015. Citado na página 30.
- NOAA. *National Oceanic and Atmospheric Administration*. 2019. [acessado dia 30 setembro de 2019]. Disponível em: <https://www.ncdc.noaa.gov>. Citado na página 105.
- NOSRATABADI, S. M.; HOOSHMAND, R. A.; GHOLIPOUR, E. A comprehensive review on microgrid and virtual power plant concepts employed for distributed energy resources scheduling in power systems. *Renewable and Sustainable Energy Reviews*, v. 67, p. 341–363, 2017. Citado 4 vezes nas páginas 25, 26, 30 e 31.
- OLAMA, A.; MENDES, P. R.; CAMACHO, E. F. Lyapunov-based hybrid model predictive control for energy management of microgrids. *IET Generation, Transmission & Distribution*, v. 12,, p. 5770–5780, 2018. Citado 3 vezes nas páginas 35, 37 e 41.
- OLIVARES, D. E. et al. Trends in microgrid control. *IEEE Transactions on Smart Grid*, v. 5, p. 1905–1919, 2014. Citado 2 vezes nas páginas 27 e 28.
- OLIVARES J. D. LARA, C. A. C. D. E.; KAZERANI, M. Stochastic-predictive energy management system for isolated microgrids. *IEEE Transactions on Smart Grid*, v. 6, p. 2681–2693, 2015. Citado 4 vezes nas páginas 37, 38, 39 e 57.
- OPPENHEIM, A. V.; SCHAFER, R. W.; BUCK, J. R. *Discrete-time Signal Processing*. 2nd. ed. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 1999. Citado na página 89.
- PALMA-BEHNKE, R. et al. A microgrid energy management system based on the rolling horizon strategy. *IEEE Transactions on Smart Grid*, v. 4, p. 996 – 1006, 2013. Citado na página 39.
- PARISIO, A.; GLIELMO, L. Stochastic model predictive control for economic/environmental operation management of microgrids. In: . Zurich, Switzerland: IEEE, 2013. p. 2014–2019. Citado na página 37.
- PARISIO, A.; RIKOS, E.; GLIELMO, L. A model predictive control approach to microgrid operation optimization. *IEEE Transactions on Control Systems Technology*, v. 22, p. 1813–1827, 2014. Citado 6 vezes nas páginas 31, 35, 37, 41, 69 e 82.
- PARISIO, A.; RIKOS, E.; GLIELMO, L. Stochastic model predictive control for economic/environmental operation management of microgrids: An experimental case study. *Journal of Process Control*, v. 43, p. 24–37, 2016. Citado 3 vezes nas páginas 35, 37 e 41.
- PARISIO, A. et al. An MPC-based Energy Management System for multiple residential microgrids. In: . Gothenburg, Sweden: IEEE, 2015. p. 7–14. Citado na página 35.
- PATINO, J.; MARQUEZ, A.; ESPINOSA, J. An economic MPC approach for a micro grid energy management system. In: . Medellin, Colombia: IEEE, 2014. p. 1–6. Citado na página 37.

- PAULA, D. de et al. Hybrid modeling of energy storage system and electrical loads in a pilot-microgrid. In: *13th IEEE/IAS International Conference on Industry Applications*. Sao Paulo, Brazil: [s.n.], 2018. p. 6. Citado na página 173.
- PEREIRA, M.; Muñoz de la Peña, D.; LIMON, D. Robust economic model predictive control of a community micro-grid. *Renewable Energy*, v. 100, p. 3–17, 2017. Citado 2 vezes nas páginas 35 e 37.
- PRASAI, A. et al. Minimizing emissions in microgrids while meeting reliability and power quality objectives. In: . Sapporo, Japan: IEEE, 2010. p. 1–6. Citado na página 31.
- RES WORLD. *End of the year wrap-up: five figures show China's renewable energy growth in 2019*. 2019. [acessado dia 18 de maio de 2020]. Disponível em: <www.renewableenergyworld.com/2019/12/01/end-of-the-year-wrap-up-five-figures-show-chinas-renewable-energy-growth-in-2019>. Citado na página 25.
- RESENDE, M.; CARDOSO, V. Mapping service quality in electricity distribution: An exploratory study of Brazil. *Utilities Policy*, v. 56,, p. 41–52, 2019. Citado 2 vezes nas páginas 31 e 34.
- ROMERO-QUETE, D.; GARCIA, J. R. An affine arithmetic-model predictive control approach for optimal economic dispatch of combined heat and power microgrids. *Applied Energy*, v. 242, p. 1436–1447, 2019. Citado 3 vezes nas páginas 34, 35 e 37.
- RUEDA-MEDINA, A. C.; PADILHA-FELTRIN, A. Pricing of reactive power support provided by distributed generators in transmission systems. In: . Trondheim, Norway: IEEE, 2011. p. 1–5. Citado na página 50.
- SARTORI, R. *Controle Preditivo Econômico : Aplicação a uma Unidade de Processamento de Gás Natural*. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, Florianópolis-SC, 2017. Programa de Pós-graduação em Engenharia de Automacao e Sistemas (PG-EAS). Citado 2 vezes nas páginas 47 e 49.
- SCOLA, L. A. *Otimização multiobjetivo evolutiva da operação de sistemas de reservatórios multiusos*. Tese (Doutorado) — Universidade Federal de Minas Gerais, Belo Horizonte-MG, 2014. Citado 3 vezes nas páginas 50, 54 e 57.
- SHARMA, A.; PANIGRAHI, B. K. Phase fault protection scheme for reliable operation of microgrids. *IEEE Transactions on Industry Applications*, v. 54, p. 2646–2655, 2018. Citado na página 34.
- SHI, Y. T. et al. Hybrid model predictive control and fault detection of wind energy conversion system based on mixed logical dynamic. In: . Changsha, China: IEEE, 2014. p. 782–788. Citado na página 41.
- SHUAI, H. et al. Stochastic optimization of economic dispatch for microgrid based on approximate dynamic programming. *IEEE Transactions on Smart Grid*, v. 3053, p. 1–13, 2018. Citado 2 vezes nas páginas 30 e 37.
- SILVA, D. P. e et al. Management of an island and grid-connected microgrid using hybrid economic model predictive control with weather data. *Applied Energy*, v. 278, p. 115581, 2020. Citado 5 vezes nas páginas 57, 181, 182, 185 e 186.

- SILVA, D. P. e et al. *Measured weather and power dataset for management of an island and grid-connected microgrid*. [S.l.], 2020. Citado na página 181.
- SILVENTE GEORGIOS M. KOPANOS, V. D. J.; PAPAGEORGIU, L. G. A rolling horizon approach for optimal management of microgrids under stochastic uncertainty. *Chemical Engineering Research*, v. 131, p. 293–317, 2018. Citado 4 vezes nas páginas 34, 35, 37 e 38.
- SILVENTE, J. et al. A rolling horizon optimization framework for the simultaneous energy supply and demand planning in microgrids. *Applied Energy*, v. 155, p. 485–501, 2015. Citado 3 vezes nas páginas 30, 34 e 37.
- SKAMAROCK, W. et al. *A Description of the Advanced Research WRF Model Version 4*. [S.l.], 2019. Citado 3 vezes nas páginas 36, 56 e 113.
- SUCIC, S. et al. Economic dispatch of virtual power plants in an event-driven service-oriented framework using standards-based communications. *Electric Power Systems Research*, v. 81, p. 2108 – 2119, 2011. Citado na página 30.
- SUNNY LIM, K.-S. et al. Impact of boundary layer simulation on predicting radioactive pollutant dispersion: A case study for HANARO research reactor using the WRF-MMIF-CALPUFF modeling system. *Nuclear Engineering and Technology*, p. in press, 2020. Citado na página 56.
- TORRISI, F. D.; BEMPORAD, A. Control of systems integrating logic, dynamics, and constraints. *IEEE Transactions on Control Systems Technology*, v. 12, p. 235–249, 2004. Citado 3 vezes nas páginas 44, 46 e 174.
- TORRISI, F. D. et al. *HYSDEL 2.0.5- User manual*. [S.l.], 2019. Citado na página 46.
- VARLAS, G. et al. Investigating the impact of atmosphere–wave–ocean interactions on a mediterranean tropical-like cyclone. *Ocean Modelling*, v. 153, p. 101675, 2020. Citado na página 56.
- VILLA, J. et al. Model predictive control of MLD models with integrators. In: . Toronto, Ont., Canada: IEEE, 2005. p. 641–644. Citado na página 47.
- WANG, C. et al. Energy management system for stand-alone diesel-wind-biomass microgrid with energy storage system. *Energy*, v. 97, p. 90 – 104, 2016. Citado na página 32.
- WASILEWSKI, J. Optimisation of multicarrier microgrid layout using selected metaheuristics. *International Journal of Electrical Power and Energy Systems*, v. 99, p. 246–260, 2018. Citado na página 34.
- XIAO, C.; LOFGREN, B. M.; WANG, J. WRF-based assessment of the great lakes’ impact on cold season synoptic cyclones. *Atmospheric Research*, v. 214, p. 189–203, 2018. Citado na página 56.
- XUE, X. et al. An interactive building power demand management strategy for facilitating smart grid optimization. *Applied Energy*, v. 116, p. 297–310, 2014. Citado na página 31.

- YAN, X.; ABBES, D.; FRANCOIS, B. Uncertainty analysis for day ahead power reserve quantification in an urban microgrid including PV generators. *Renewable Energy*, v. 106, p. 288–297, 2017. Citado na página 41.
- ZAKARIAZADEH, A.; JADID, S.; SIANO, P. Smart microgrid energy and reserve scheduling with demand response using stochastic optimization. *International Journal of Electrical Power & Energy Systems*, v. 63, p. 523–533, 2014. Citado na página 32.
- ZÉPHYR, L.; ANDERSON, C. L. Stochastic dynamic programming approach to managing power system uncertainty with distributed storage. *Computational Management Science*, v. 15, p. 87–110, 2018. Citado 3 vezes nas páginas 29, 30 e 35.
- ZHANG, X. et al. A multi-microgrids system model considering stochastic correlations among microgrids. *Energy Procedia*, v. 145, p. 3–8, 2018. Citado na página 33.
- ZHENG, J. et al. Time series prediction for output of multi-region solar power plants. *Applied Energy*, v. 257, p. 114001, 2020. Citado na página 101.
- ZHENG, Y.; LI, S.; TAN, R. Distributed model predictive control for on-connected microgrid power management. *IEEE Transactions on Control Systems Technology*, v. 26, p. 1–12, 2017. Citado 2 vezes nas páginas 35 e 37.
- ZHU, L.; HILL, D. J. Modeling and Stability of Microgrids with Smart Loads. *IFAC-PapersOnLine*, v. 50, p. 10021–10026, 2017. Citado na página 33.
- ZITZLER, E. *Evolutionary Algorithms for Multiobjective Optimization: Methods and Applications*. Tese (Doutorado) — Swiss Federal Institute of Technology Zurich, Zurich, Switzerland, 1999. Citado 3 vezes nas páginas 50, 53 e 54.

APÊNDICE A – Modelagem MLD

No Capítulo 2 é detalhado a modelagem DHA da MG. Neste apêndice é feito a conversão do modelo DHA para o modelo MLD da expressão (2.1) utilizando a metodologia da Figura 3.1. A estrutura MLD é capaz de converter não linearidades da forma $z(k) = \delta(k)q(k)$ onde $z(k)$ é uma variável auxiliar, $\delta(k)$ é uma variável binária e $q(k)$ é uma variável real. Essa conversão é feita através das proposições lógicas da Tabela 4, o que significa transformar termos não lineares do tipo $\delta(k)q(k)$ em termos lineares do tipo $z(k)$ com adição de restrições na forma de equações de desigualdades.

A.1 Geração Fotovoltaica

O modelo MLD dos painéis fotovoltaicos é mostrado na em (A.1)

$$\begin{aligned}
 \mathbf{x}_{pv}(k+1) &= \mathbf{B}_{3pv} \mathbf{z}_{pv}(k) \\
 P_{pv}(k) &= \mathbf{C}_{pv} \mathbf{x}_{pv}(k) \\
 \mathbf{E}_{pv2} \delta(k) + \mathbf{E}_{pv3} z(k) &\leq \mathbf{E}_{pv1} \mathbf{u}(k) + \mathbf{E}_{pv4} \mathbf{x}(k) + \mathbf{E}_{pv5}.
 \end{aligned} \tag{A.1}$$

A variável auxiliar $z_{pv}(k)$, representada pela Tabela 25, muda de valor em função da saturação dos painéis PV. Quando $\delta_{pv1}(k) = 0$ significa que $P_{pv}(k)$ gera potência de acordo com o polinômio em (3.2). Caso contrário, a potência $P_{pv}(k)$ satura em um valor igual a P_{pvmax} .

Tabela 25 – Variável auxiliar $z_{pv}(k)$ que representa uma combinação linear do SAS em (3.4).

Símbolo	Definição
$z_{pv}(k)$	$ \begin{cases} P_{pvmax} & \text{se } \delta_{pv1}(k) = 1 \\ P_{pv}(k) & \text{caso contrário.} \end{cases} $

A.2 Geração Eólica

De forma análoga ao modelo PV, o DHA da turbina eólica foi convertido para a classe MLD através de (A.2). O modelo MLD converte as dinâmicas do SAS em (3.10) associadas aos estados da FSM da expressão (3.7) em uma combinação linear das variáveis auxiliares representadas por $\mathbf{z}_w(k)$

$$\begin{aligned}
\mathbf{x}_w(k+1) &= \mathbf{A}_w \boldsymbol{\delta}_w(k) + \mathbf{B}_{w3} \mathbf{z}_w(k) \\
\mathbf{P}_w(k) &= \mathbf{C}_w \mathbf{x}_w(k) \\
\mathbf{E}_{w2} \boldsymbol{\delta}_w(k) + \mathbf{E}_{w3} \mathbf{z}_w(k) &\leq \mathbf{E}_{w1} \mathbf{u}(k) + \mathbf{E}_{w4} \mathbf{x}_w(k) + \mathbf{E}_{w5}.
\end{aligned} \tag{A.2}$$

A Tabela 26 mostra a definição de cada variável $z_{wi} \in \mathbf{z}_w$, $i = 1, 2, \dots, n_w$ no qual

- $\mathbf{E}_{w1}, \mathbf{E}_{w2}, \mathbf{E}_{w3}, \mathbf{E}_{w4}$ e \mathbf{E}_{w5} são matrizes das desigualdades inteiras mistas;
- $\boldsymbol{\delta}_w(k)$ é o vetor de estados discretos;
- $\mathbf{u}_w(k) = [P_w(k) \ v(k)]^T$ é a potência em W e a velocidade do vento em m/s;
- $\mathbf{P}_w(k)$ é o vetor de saída que corresponde à potência gerada em W; e
- $\mathbf{z}_w(k)$ é o vetor das variáveis auxiliares definidas na Tabela 26.

Tabela 26 – Variáveis auxiliares $z_w(k)$ da turbina eólica que representam uma combinação linear do SAS em (3.10).

Símbolo	Definição
$z_{w1}(k)$	$\begin{cases} 0 & \text{se } x_{wb}(k) = x_{wb1}(k) \end{cases}$
$z_{w2}(k)$	$\begin{cases} P_w(k) & \text{se } x_{wb}(k) = x_{wb2}(k) \\ 0 & \text{Caso contrário} \end{cases}$
$z_{w3}(k)$	$\begin{cases} P_n & \text{se } x_{wb}(k) = x_{wb3}(k) \\ 0 & \text{Caso contrário} \end{cases}$
$z_{w4}(k)$	$\begin{cases} P_{cutoff} & \text{se } x_{wb}(k) = x_{wb4}(k) \\ 0 & \text{Caso contrário} \end{cases}$

A.3 Banco de Baterias

O modelo MLD do banco de baterias é obtido pela conversão do DHA em (3.13), (3.11) e (3.12) para (A.3)

$$\begin{aligned}
\mathbf{x}_s(k+1) &= \mathbf{B}_{s2} \boldsymbol{\delta}_s(k) + \mathbf{B}_{s3} \mathbf{z}_s(k) \\
\mathbf{y}_s(k) &= \mathbf{C}_s \mathbf{x}_s(k) \\
\mathbf{E}_{s2} \boldsymbol{\delta}_s(k) + \mathbf{E}_{s3} \mathbf{z}_s(k) &\leq \mathbf{E}_{s1} \mathbf{u}_s(k) + \mathbf{E}_{s4} \mathbf{x}_s(k) + \mathbf{E}_{s5}
\end{aligned} \tag{A.3}$$

em que:

- $\mathbf{E}_{s1}, \mathbf{E}_{s2}, \mathbf{E}_{s3}, \mathbf{E}_{s4}$ e \mathbf{E}_{s5} são matrizes das desigualdades inteiras mistas;

- $\mathbf{x}_s(k)$ é o vetor híbrido de estados contínuos de tempo discreto e estados discretos x_{sbi} , $i = 1, \dots, n_{ess}$;
- $\mathbf{u}_s(k) = [i_s(k) \ u_g(k)]^T$ são as entradas de corrente e status de conexão da MG respectivamente;
- $\mathbf{y}_s(k)$ é o vetor de saída que corresponde ao $\mathbf{S}(k)$; e
- $\mathbf{z}_s(k)$ é o vetor das variáveis auxiliares definidas na Tabela 27.

Tabela 27 – Variáveis auxiliares $z_s(k)$ do SOC que representam uma combinação linear do SAS em (3.13).

Símbolo	Definição
$z_{s1}(k)$	$\begin{cases} S_{min} & \text{se } x_{b1} \\ 0 & \text{Caso contrário} \end{cases}$
$z_{s2}(k)$	$\begin{cases} S(k) + \frac{\eta T_s}{C_{max}} \cdot i_1(k) & \text{se } x_{b2} \\ 0 & \text{Caso contrário} \end{cases}$
$z_{s3}(k)$	$\begin{cases} S(k) + \frac{\eta T_s}{C_{max}} \cdot i_2(k) & \text{se } x_{b3} \\ 0 & \text{Caso contrário} \end{cases}$
$z_{s4}(k)$	$\begin{cases} S_{max} & \text{se } x_{b4} \\ 0 & \text{Caso contrário} \end{cases}$
$z_{s5}(k)$	$\begin{cases} S_{up} & \text{se } x_{b5} \\ 0 & \text{Caso contrário} \end{cases}$
$z_{s6}(k)$	$\begin{cases} S_{low} & \text{se } x_{b6} \\ 0 & \text{Caso contrário} \end{cases}$
$z_{s7}(k)$	$\begin{cases} Temp(k) + a_n T_s & \text{se } x_{b6} \vee x_{b7} \\ 0 & \text{Caso contrário} \end{cases}$

A.4 Controlador de Carga

A metodologia usada é a mesma da Seção A.1 para encontrar a expressão (A.4)

$$\begin{aligned}
 \mathbf{x}_c(k+1) &= \mathbf{B}_{c2} \boldsymbol{\delta}_c(k) \\
 \mathbf{y}_c(k) &= [1 \ 0] \begin{bmatrix} x_{cb1}(k) \\ x_{cb2}(k) \end{bmatrix} \\
 \mathbf{E}_{c2} \boldsymbol{\delta}_c(k) &\leq \mathbf{E}_{c1} \mathbf{u}_c(k) + \mathbf{E}_{c4} \mathbf{x}_c(k) + \mathbf{E}_{c5}
 \end{aligned} \tag{A.4}$$

em que

- \mathbf{E}_{c1} , \mathbf{E}_{c2} , \mathbf{E}_{c4} e \mathbf{E}_{c5} são matrizes das desigualdades inteiras mistas;

- $\mathbf{x}_{cb}(k)$ são os estados discretos;
- $\mathbf{u}_c(k)$ é a entrada $S(k)$ (SOC);
- $\delta_c(k)$ são as transições da FSM; e
- $\mathbf{y}_c(k)$ é a saída que corresponde ao estado habilitado.

A.5 Tarifas de Energia

O modelo resultante da conversão do DHA das expressões (3.24) e (3.26) para a classe MLD é representado por (A.5)

$$\begin{aligned} \mathbf{x}_p(k+1) &= z_{p2}(k) \\ \begin{bmatrix} C_g(k) \\ \delta_g(k) \end{bmatrix} &= \begin{bmatrix} 1 \\ 0 \end{bmatrix} \mathbf{x}_p(k) + \begin{bmatrix} 0 \\ 1 \end{bmatrix} \delta_p(k) \\ \mathbf{E}_{p2} \delta_p(k) + \mathbf{E}_{p3} z_p(k) &\leq \mathbf{E}_{p1} \mathbf{u}_p(k) + \mathbf{E}_{p4} \mathbf{x}_p(k) + \mathbf{E}_{p5} \end{aligned} \quad (\text{A.5})$$

em que

- $\mathbf{E}_{p1}, \mathbf{E}_{p2}, \mathbf{E}_{p3}, \mathbf{E}_{p4}$ e \mathbf{E}_{p5} são matrizes das desigualdades inteiras mistas;
- $\mathbf{x}_p(k)$ é o vetor de estados;
- $\delta_p(k)$ é o vetor de variáveis discretas;
- $z_{p1}(k)$ e $z_{p2}(k)$ são as variáveis auxiliares definidas na Tabela 28.

Tabela 28 – Variáveis auxiliares $z_{p1}(k)$ e $z_{p2}(k)$.

Símbolo	Definição
$z_{p1}(k)$	$\begin{cases} P_g(k)c_s(k) & \text{se } \delta_p(k) = 1 \\ P_g(k)c_p(k) & \text{Caso contrário} \end{cases}$
$z_{p2}(k)$	$\begin{cases} z_{p1}(k) & \text{se } u_g(k) = 1 \\ 0 & \text{Caso contrário} \end{cases}$

A.6 Cargas Elétricas

O modelo MLD representado por (A.6) é obtido pela conversão do DHA das expressões (3.17), (3.19) e (3.18) e a inclusão das cargas críticas, isto é,

$$\mathbf{x}_L(k+1) = \sum_{h=1}^{n_c} z_{Lh}(k) + \sum_{i=1}^{n_l} D_i$$

$$\begin{bmatrix} P_L(k) \\ \delta_{load}(k) \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \end{bmatrix} \mathbf{x}_L(k) + \mathbf{D}_2 \boldsymbol{\delta}_L(k) \quad (\text{A.6})$$

$$\mathbf{E}_{L2} \boldsymbol{\delta}_L(k) + \mathbf{E}_{L3} \mathbf{z}_L(k) \leq \mathbf{E}_{L1} \mathbf{u}_L(k) + \mathbf{E}_{L4} \mathbf{x}_L(k) + \mathbf{E}_{L5}$$

em que

- \mathbf{E}_{L1} , \mathbf{E}_{L2} , \mathbf{E}_{L3} , \mathbf{E}_{L4} e \mathbf{E}_{L5} são matrizes das desigualdades inteiras mistas;
- $\mathbf{z}_{Lh}(k)$, $h = 1, 2, \dots, n_c$ são as variáveis auxiliares definidas na Tabela 29;
- $P_L(k)$ é a saída real que corresponde à demanda total em W;
- $\delta_{load}(k)$ é a saída binária que indica se as cargas estão ligadas ou desligadas.

Tabela 29 – Variáveis auxiliares $z_L(k)$ para n_c cargas controláveis.

Símbolo	Definição
$z_{L1}(k)$	$\begin{cases} D_1 & \text{se } c_1(k) = 1 \\ 0 & \text{Caso contrário} \end{cases}$
$z_{L2}(k)$	$\begin{cases} D_2 & \text{se } c_2(k) = 1 \\ 0 & \text{Caso contrário} \end{cases}$
\vdots	
$z_{Ln_c}(k)$	$\begin{cases} D_{nc} & \text{se } c_{nc}(k) = 1 \\ 0 & \text{Caso contrário} \end{cases}$

O número de variáveis auxiliares depende do número de cargas n_c .

APÊNDICE B – Matrizes Numéricas MLD

Legenda:

- $\mathbf{O}_{m \times n}$ - Matriz de zeros $m \times n$;
- \mathbf{I}_n - Matriz identidade $n \times n$; e
- $\mathbf{1}_{m \times n}$ - Matriz de números 1 $m \times n$.

B.1 Painéis Fotovoltaicos

$$\mathbf{A}_{pv} = \begin{bmatrix} 2.000 & -1.106 & 0.000 & 0.424 \\ 1.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.500 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.500 & 0.000 \end{bmatrix} \quad \mathbf{B}_{pv1} = \begin{bmatrix} 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \end{bmatrix}$$

$$\mathbf{B}_{pv2} = \begin{bmatrix} 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \end{bmatrix} \quad \mathbf{B}_{pv3} = \begin{bmatrix} 1.000 & 1.000 & 1.000 \\ 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \end{bmatrix}$$

$$\mathbf{C}_{pv} = [0.000 \quad 0.106 \quad 0.000 \quad -0.424] \quad \mathbf{D}_{pv1} = [0.000]$$

$$\mathbf{D}_{pv2} = [0.000 \quad 0.000 \quad 0.000] \quad \mathbf{D}_{pv3} = [0.000 \quad 0.000 \quad 0.000]$$

$$\mathbf{E}_{pv1} = \begin{bmatrix} -1.000 \\ 1.000 \\ -1.000 \\ 1.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ -1.000 \\ 1.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \end{bmatrix} \quad \mathbf{E}_{pv2} = \begin{bmatrix} 0.000 & 0.000 & 0.000 \\ 1500.000 & 0.000 & 0.000 \\ 0.000 & -1500.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \\ -1.000 & 1.000 & -1.000 \\ 1.000 & 0.000 & 1.000 \\ 0.000 & -1.000 & 1.000 \\ 0.000 & 0.000 & 1500.000 \\ 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & -1500.000 \\ 1500.000 & 0.000 & 0.000 \\ -1500.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \end{bmatrix}$$

$$\mathbf{E}_{pv3} = \begin{bmatrix} 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & -1.000 \\ 0.000 & 0.000 & 1.000 \\ 0.000 & 0.000 & -1.000 \\ 0.000 & 0.000 & 1.000 \\ -1.000 & 0.000 & 0.000 \\ 1.000 & 0.000 & 0.000 \\ 0.000 & -1.000 & 0.000 \\ 0.000 & 1.000 & 0.000 \end{bmatrix} \quad \mathbf{E}_{pv4} = \mathbf{O}_{15 \times 4} \quad \mathbf{E}_{pv5} = \begin{bmatrix} 1500.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 1.000 \\ 0.000 \\ 1500.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \end{bmatrix}$$

B.2 Turbina Eólica

$$\mathbf{A}_w = \begin{bmatrix} 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \end{bmatrix} \quad \mathbf{B}_{w1} = \begin{bmatrix} 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \end{bmatrix}$$

$$\mathbf{B}_{w2} = \begin{bmatrix} 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 1.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 1.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 1.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 1.000 \end{bmatrix}$$

$$\mathbf{B}_{w3} = \begin{bmatrix} 1.000 & 1.000 & 1.000 & 1.000 \\ 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 \end{bmatrix} \quad \mathbf{C}_w = \begin{bmatrix} \\ \\ \\ \end{bmatrix}$$

$$\mathbf{D}_{w1} = \begin{bmatrix} \\ \\ \\ \end{bmatrix} \quad \mathbf{D}_{w2} = \begin{bmatrix} \\ \\ \\ \end{bmatrix} \quad \mathbf{D}_{w3} = \begin{bmatrix} \\ \\ \\ \end{bmatrix}$$

$$\mathbf{E}_{w1} = \begin{bmatrix} 0.000 & -1.000 \\ 0.000 & 1.000 \\ 0.000 & -1.000 \\ 0.000 & 1.000 \\ 0.000 & -1.000 \\ 0.000 & 1.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ -1.000 & 0.000 \\ 1.000 & 0.000 \\ \hline \mathbf{O}_{44 \times 1} & \mathbf{O}_{44 \times 1} \end{bmatrix}$$

B.3 Banco de Baterias

$$A_s = \mathbf{O}_{9 \times 9} \quad B_{s1} = \begin{bmatrix} -1.000 & 1.000 & 1.000 & 1.000 & 1.000 & 1.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \end{bmatrix}$$

$$B_{s2} = \left[\begin{array}{c|c|c} \mathbf{O}_{3 \times 5} & \mathbf{O}_{3 \times 6} & \mathbf{O}_{3 \times 1} \\ \hline \mathbf{O}_{6 \times 5} & \mathbf{I}_6 & \mathbf{O}_{6 \times 1} \end{array} \right]$$

$$B_{s3} = \begin{bmatrix} 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 1.000 \\ 1.000 & 1.000 & 1.000 & 1.000 & 1.000 & 1.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 1.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \end{bmatrix}$$

$$C_s = [0.000 \quad 1.000 \quad 0.000 \quad 0.000 \quad 0.000 \quad 0.000 \quad 0.000 \quad 0.000 \quad 0.000]$$

$$D_{s1} = \mathbf{O}_{1 \times 7} \quad D_{s2} = \mathbf{O}_{1 \times 12} \quad D_{s3} = \mathbf{O}_{1 \times 8}$$

$$\mathbf{E}_{s5} = \begin{bmatrix}
 -0.000 \\
 1.350 \\
 1.000 \\
 0.100 \\
 -0.000 \\
 3.300 \\
 -1.000 \\
 5.000 \\
 0.000 \\
 0.000 \\
 1.000 \\
 1.370 \\
 0.115 \\
 -0.000 \\
 0.000 \\
 1.350 \\
 0.100 \\
 -0.000 \\
 0.000 \\
 5.000 \\
 \hline
 \mathbf{O}_{3 \times 1} \\
 \mathbf{I}_{3 \times 1} \\
 \hline
 0.000 \\
 0.000 \\
 1.000 \\
 1.000 \\
 \hline
 \mathbf{O}_{7 \times 1} \\
 \hline
 1.000 \\
 1.000 \\
 2.000 \\
 1.000 \\
 2.000 \\
 \hline
 \mathbf{I}_{5 \times 1} \\
 \hline
 0.000 \\
 1.000 \\
 1.000 \\
 2.000 \\
 1.000 \\
 2.000 \\
 0.000 \\
 1.000 \\
 0.000 \\
 1.000 \\
 1.000 \\
 0.000 \\
 0.000 \\
 \hline
 \mathbf{I}_{6 \times 1} \\
 \mathbf{O}_{4 \times 1} \\
 \hline
 2.000 \\
 1.000 \\
 \hline
 \mathbf{O}_{19 \times 1}
 \end{bmatrix}$$

B.5 Tarifas de Energia

$$\mathbf{A}_p = \begin{bmatrix} 0.000 & 0.000 \\ 0.000 & 0.000 \end{bmatrix}$$

$$\mathbf{B}_{p1} = \begin{bmatrix} -1.000 & 1.000 & 1.000 & 1.000 & 1.000 & 1.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \end{bmatrix}$$

$$\mathbf{B}_{p2} = \begin{bmatrix} 0.000 \\ 0.000 \end{bmatrix} \quad \mathbf{B}_{p3} = \begin{bmatrix} 0.000 & 0.000 & 1.000 \\ 0.000 & 1.000 & 0.000 \end{bmatrix}$$

$$\mathbf{C}_p = \begin{bmatrix} 0.000 & 0.000 \end{bmatrix} \quad \mathbf{D}_{p1} = \mathbf{O}_{1 \times 8}$$

$$\mathbf{D}_{p2} = \begin{bmatrix} 1.000 \end{bmatrix} \quad \mathbf{D}_{p3} = \begin{bmatrix} 0.000 & 0.000 & 0.000 \end{bmatrix}$$

$$\mathbf{E}_{p1} = \begin{bmatrix} 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.021 & -0.021 & -0.021 & -0.021 & -0.021 & -0.021 & 0.000 & 0.000 \\ -0.021 & 0.021 & 0.021 & 0.021 & 0.021 & 0.021 & 0.000 & 0.000 \\ 0.012 & -0.012 & -0.012 & -0.012 & -0.012 & -0.012 & 0.000 & 0.000 \\ -0.012 & 0.012 & 0.012 & 0.012 & 0.012 & 0.012 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & -0.039 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & -0.052 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.052 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.039 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & -0.770 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.000 & 0.770 \end{bmatrix}$$

$$\mathbf{E}_{p2} = \begin{bmatrix} -3.300 \\ 3.300 \\ 0.069 \\ 0.074 \\ -0.074 \\ -0.069 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \end{bmatrix} \quad \mathbf{E}_{p3} = \begin{bmatrix} 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 \\ -1.000 & 0.000 & 0.021 \\ 1.000 & 0.000 & -0.021 \\ -1.000 & 0.000 & 0.012 \\ 1.000 & 0.000 & -0.012 \\ 1.000 & -1.000 & 0.000 \\ -1.000 & 1.000 & 0.000 \\ 0.000 & -1.000 & 0.000 \\ 0.000 & 1.000 & 0.000 \\ 0.000 & 0.000 & -1.000 \\ 0.000 & 0.000 & 1.000 \end{bmatrix}$$

$$\mathbf{E}_{p4} = \begin{bmatrix} -1.000 & 0.000 \\ 1.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \\ 0.000 & 0.000 \end{bmatrix} \quad \mathbf{E}_{p5} = \begin{bmatrix} 0.000 \\ 3.300 \\ 0.069 \\ 0.074 \\ 0.000 \\ 0.000 \\ 0.039 \\ 0.052 \\ 0.000 \\ 0.000 \\ 0.000 \\ 0.000 \end{bmatrix}$$

B.6 Cargas Eléctricas

$$\mathbf{A}_L = \mathbf{O}_{5 \times 5} \quad \mathbf{B}_{L1} = \mathbf{O}_{5 \times 4}$$

$$\mathbf{B}_{L2} = \begin{bmatrix} \\ \\ \\ \\ \end{bmatrix} \quad \mathbf{B}_{L3} = \begin{bmatrix} 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 1.000 & 1.000 & 1.000 & 1.000 & 1.000 \end{bmatrix}$$

$$\mathbf{C}_L = \begin{bmatrix} \\ \end{bmatrix} \quad \mathbf{D}_{L1} = \begin{bmatrix} \\ \end{bmatrix} \quad \mathbf{D}_{L2} = \begin{bmatrix} \\ \end{bmatrix} \quad \mathbf{D}_{L3} = \begin{bmatrix} \\ \end{bmatrix}$$

$$\mathbf{E}_{L1} = \begin{bmatrix} 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 \\ 0.150 & 0.000 & 0.000 & 0.000 \\ -0.150 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.200 & 0.000 & 0.000 \\ 0.000 & -0.200 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.200 & 0.000 \\ 0.000 & 0.000 & -0.200 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.300 \\ 0.000 & 0.000 & 0.000 & -0.300 \end{bmatrix} \quad \mathbf{E}_{L2} = \begin{bmatrix} \\ \\ \\ \\ \end{bmatrix}$$

$$\mathbf{E}_{L3} = \begin{bmatrix} -1.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 1.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & -1.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 1.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & -1.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 1.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & -1.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 1.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & -1.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 1.000 \end{bmatrix}$$

$$\mathbf{E}_{L4} = \begin{bmatrix} 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \\ 0.000 & 0.000 & 0.000 & 0.000 & 0.000 \end{bmatrix}$$

$$\mathbf{E}_{L5} = \begin{bmatrix} -0.250 \\ 0.250 \\ -0.150 \\ 0.150 \\ -0.200 \\ 0.200 \\ -0.200 \\ 0.200 \\ -0.300 \\ 0.300 \end{bmatrix}$$

APÊNDICE C – Modelos Alternativos

Os modelos alternativos descritos neste apêndice permitem ao leitor explorar outras possibilidades de modelagem. A seguir são descritos os modelos alternativos da geração solar (CHO, 1996), o modelo da turbina eólica com controle estol e o modelo do banco de baterias utilizado na planta.

C.1 Geração Fotovoltaica

Este modelo utiliza as equações linearizadas e discretizadas de (3.1) a uma taxa de amostragem de 1 segundo. Os sistemas fotovoltaicos atuais operam utilizando MPPT. A equação em malha aberta para o MPPT é dada por:

$$V(k+1) = V(k) + \mathcal{M} \cdot \frac{\Delta P}{\Delta V} \quad (\text{C.1})$$

em que

- V a tensão no instante k ;
- P a potência no instante k ;
- $\Delta P/\Delta V$ a taxa de variação da potência gerada em relação à variação da tensão. Quando essa taxa for igual a zero, o sistema estará no ponto (V_p, I_p) de máxima potência; e
- \mathcal{M} ganho incremental.

A expressão (C.1) foi linearizada por CHO (1996) em torno do ponto de máxima potência, gerando uma função de transferência de tempo discreto, G_{ppt} , com segurador de ordem zero. A curva característica de potência *versus* tensão em malha aberta é representada pela expressão

$$G_{ppt}(z) = -\mathcal{M} \cdot \frac{V_p}{I_p} \cdot T_s \cdot \frac{1}{s} \cdot \frac{z+1}{z^2}. \quad (\text{C.2})$$

Para controlar o MPPT, o sistema pode ser projetado de maneira que o modelo em malha fechada seja representado por (C.3)

$$\begin{aligned} \mathbf{x}_{pv}(k+1) &= \mathbf{A}_{pv}\mathbf{x}_{pv}(k) + \mathbf{B}_{pv}\mathbf{u}_{pv}(k) \\ \mathbf{y}_{pv}(k) &= \mathbf{C}_{pv}\mathbf{x}_{pv}(k) + \mathbf{D}_{pv}\mathbf{u}_{pv}(k) \end{aligned} \quad (\text{C.3})$$

na qual a variável $u_{pv}(k) = P_{MPPT}(k)$ é definida pelo ponto de máxima potência (V_p, I_p) , $x_{pv}(k)$ são as variáveis de estados e $y_{pv}(k)$ é a potência gerada que vai seguir o $P_{MPPT}(k)$.

A equação (C.3) depende dos parâmetros de (3.1). O problema deste modelo é que cada painel PV tem um limite máximo de potência nominal. Para representar este limite é necessário incluir a variável binária $\delta_{pv1}(k)$, mostrada em (3.5). Se a potência PV for maior que a potência nominal, P_{pvmax} , então $\delta_{pv1}(k) = 1$ e a dinâmica (C.3) chaveia para a saturação. Essa é uma característica híbrida que pode ser modelada pelo formalismo do DHA, onde as variáveis binárias são representadas pelo gerador de eventos (EG) de (C.4) e o sistema comutado por partes (SAS) é representado por duas dinâmicas de tempo discreto (C.5)

$$EG : \left\{ [\delta_{pv1}(k) = 1] \leftrightarrow [P_{MPPT} \geq P_{pvmax}] \right. \quad (C.4)$$

$$SAS : \begin{cases} \mathbf{x}_{pv}(k+1) = \mathbf{A}_{pv}\mathbf{x}_{pv}(k) + \mathbf{B}_{pv}P_{MPPT}(k) & \text{se } m_{pv}(k) = 1 \\ \mathbf{x}_{pv}(k+1) = P_{pvmax} & \text{se } m_{pv}(k) = 2. \end{cases} \quad (C.5)$$

$$MS : m_{pv}(k) = \begin{cases} 1 & \text{se } \neg\delta_{pv1}(k) \\ 2 & \text{se } \delta_{pv1}(k). \end{cases} \quad (C.6)$$

O EG em (C.4) define a variável binária $\delta_{pv1}(k)$ em função da potência nominal PV, P_{pvmax} , e o MS de (C.6) seleciona uma dinâmica do SAS (C.5). Isto significa associar os valores de $m_{pv}(k)$ às dinâmicas do MPPT e à saturação da potência gerada respectivamente. Se a potência gerada para um dado valor de irradiância e temperatura ultrapassar a capacidade máxima de geração, então o valor satura em P_{pvmax} , senão o modelo procura o MPPT para a irradiância e temperatura atual ($\lambda(k)$ e $T(k)$). O DHA do painel fotovoltaico alternativo foi convertido para o modelo MLD dado por,

$$\begin{aligned} \mathbf{x}_{pv}(k+1) &= \mathbf{A}_{pv}\mathbf{x}_{pv}(k) + \mathbf{B}_{3pv}\mathbf{z}_{pva}(k) \\ P_{pv}(k) &= \mathbf{C}_{pv}\mathbf{x}_{pv}(k) \\ \mathbf{E}_{pv2}\delta(k) + \mathbf{E}_{pv3}\mathbf{z}(k) &\leq \mathbf{E}_{pv1}\mathbf{u}(k) + \mathbf{E}_{pv4}\mathbf{x}(k) + \mathbf{E}_{pv5}. \end{aligned} \quad (C.7)$$

onde:


- $\mathbf{x}_{pv}(k)$ são as variáveis de estado de tempo discreto do sistema de malha fechada MPPT;
- $\mathbf{z}_{pva}(k)$ é a variável auxiliar definida na Tabela 30.

Tabela 30 – Variável auxiliar $z_{pva}(k)$ que representa uma combinação linear do SAS em (C.5).

Símbolo	Definição
$z_{pva}(k)$	$\begin{cases} P_{pvmax} & \text{if } \delta_{pv1}(k) = 1 \\ P_{MPPT}(k) & \text{caso contrário} \end{cases}$

O modelo MLD recebe o ponto de operação $P_{MPPT}(k)$ a cada instante k . Este valor é calculado através da relação $I(\lambda(k), T(k))$ em (3.1). Considerando que as especificações do painel fotovoltaico não se alteram, $P_{MPPT}(k) = V_p(k)I_p(k) = f(\lambda(k), T(k))$. A Figura C.1 mostra que a variação da temperatura e da irradiância nos instantes $k - 2$, $k - 1$ e k altera a curva de potência e o ponto de operação do modelo descrito por (C.7). Para o instante $k - 2$, o painel PV entrega sua potência nominal com 1.0 kW/m^2 de irradiância e 25°C de temperatura. A geração de energia PV é diretamente proporcional à irradiância e inversamente proporcional à temperatura. Nos instantes $k - 1$ e k há uma diminuição da irradiância que modifica as curvas de potência, diminuindo o valor do MPP.

Figura C.1 – Variação do ponto de máxima potência a partir de mudanças na irradiância e temperatura a cada instante k : P_{MPPT} representa o ponto de operação de (C.3).




A vantagem deste modelo é a representação mais fidedigna da curva real de um painel fotovoltaico.

C.2 Turbina Eólica com Controle Estol

O controle estol contempla a curva de potência da Figura C.2. O modelo DHA terá um estado discreto a menos, referente à potência nominal.

Figura C.2 – Exemplo de curva de potência eólica para turbinas com controle estol.



Fonte: Próprio autor.

Assim, o SAS da turbina eólica com controle estol possui três dinâmicas assim definidas:

$$SAS : \begin{cases} x_w(k+1) = 0 & \text{se } m_w(k) = 1 \\ x_w(k+1) = P_w(k) & \text{se } m_w(k) = 2 \\ x_w(k+1) = P_{cutoff} & \text{se } m_w(k) = 3 \end{cases} \quad (C.8)$$

$$EG : \begin{cases} [d_{w1} = 1] \leftrightarrow [v \leq v_{cutin}] \\ [d_{w2} = 1] \leftrightarrow [v \geq v_{cutoff}] \\ [op = \neg d_{w1} \wedge \neg d_{w2}] \leftrightarrow [v > v_{cutin} \wedge v < v_{cutoff}] \end{cases} \quad (C.9)$$

$$FSM : x_{wb}(k+1) = \begin{cases} x_{wb1} & \text{se } (x_{wb1} \wedge d_{w1}) \vee (x_{wb2} \wedge d_{w1}) \vee (x_{wb3} \wedge d_{w1}) \\ x_{wb2} & \text{se } (x_{wb1} \wedge op) \vee (x_{wb2} \wedge op) \vee (x_{wb3} \wedge op) \\ x_{wb3} & \text{se } (x_{wb1} \wedge d_{w2}) \vee (x_{wb2} \wedge d_{w2}) \vee (x_{wb3} \wedge d_{w2}) \end{cases} \quad (C.10)$$

$$MS : m_w(k) = \begin{cases} 1 & \text{se } x_{wb1} \\ 2 & \text{se } x_{wb2} \\ 3 & \text{se } x_{wb3}. \end{cases} \quad (\text{C.11})$$

em que $m_w(k) \in \{1, 2, 3\}$. Os valores 1, 2, 3 representam a dinâmica selecionada. O critério de seleção das dinâmicas é feito pela máquina de estados (FSM) (C.10). A FSM transita através de eventos discretos entre as operações sem geração, operando na máxima potência e corte. O conjunto de eventos discretos da FSM $Q_w = \{d_{w1}, d_{w2}, op\}$ define o modelo EG. O raciocínio de interpretação das equações é análogo ao da turbina eólica com controle de passo da Seção 3.2. O modelo MLD convertido do modelo DHA das equações (C.8), (C.9), (C.10) e (C.11) é representado por (A.2). A diferença aqui é que as matrizes terão dimensões menores. O modelo MLD da turbina com controle estol possui menos variáveis binárias e auxiliares que a turbina com controle de passo, conforme mostra a Tabela 31.

Tabela 31 – Variáveis auxiliares $z_w(k)$ da turbina eólica com controle estol.

Símbolo	Definição
$z_{w1}(k)$	$\begin{cases} 0 & \text{if } x_{wb} = x_{wb1} \end{cases}$
$z_{w2}(k)$	$\begin{cases} P_w(k) & \text{if } x_{wb} = x_{wb2} \\ 0 & \text{Caso contrário} \end{cases}$
$z_{w3}(k)$	$\begin{cases} P_{cutoff} & \text{if } x_{wb} = x_{wb3} \\ 0 & \text{Caso contrário} \end{cases}$

Assim esse modelo pode ser aplicado em qualquer turbina eólica com controle estol.

C.3 Banco de Baterias

O modelo DHA do banco de baterias (ESS) apresentado no Capítulo 3 representa o modelo utilizado no otimizador. Já o modelo proposto neste apêndice visa corrigir erros de simulação da planta quando o nível do SOC do banco de baterias atinge os níveis de saturação. A grande diferença é que foi necessário incluir estados de reconfiguração (*reset*) permitindo que a planta seja capaz de sair dos modos operação carregado e descarregado. Neste modelo foram propostas algumas melhorias nas restrições de capacidade e no modo de chaveamento entre as dinâmicas em relação ao modelo proposto por Paula et al. (2018).

O SAS do estado da carga do ESS é dado por (C.12),

$$SAS : \begin{cases} S(k+1) = S_{min} & \text{se } m_s(k) = 1 \\ S(k+1) = S(k) + \frac{\eta T_s}{C_{max}} \cdot i_1(k) & \text{se } m_s(k) = 2 \\ S(k+1) = S(k) + \frac{\eta T_s}{C_{max}} \cdot i_2(k) & \text{se } m_s(k) = 3 \\ S(k+1) = S_{max} & \text{se } m_s(k) = 4 \\ S(k+1) = S_{up} & \text{se } m_s(k) = 5 \\ S(k+1) = S_{low} & \text{se } m_s(k) = 6 \end{cases} \quad (C.12)$$

no qual

- $S(k)$ é o estado da carga do ESS;
- C_{max} é capacidade do ESS em Ah;
- S_{min} , S_{max} são os limites máximos e mínimos do SOC;
- S_{up} , e S_{low} são condições de *reset* onde $[S_{low}, S_{up}] \in]S_{min} S_{max}[$, $S_{up} < S_{max}$ e $S_{low} > S_{min}$;
- T_s é a taxa de amostragem; e
- η é a eficiência de carga e descarga.

As dinâmicas $m_s(k) \in \{5, 6\}$ são chamadas de mapas de reconfiguração (*reset*). O compilador HYSDEL representa os mapas de reconfiguração através da inclusão de novas dinâmicas. O leitor interessado pode obter mais detalhes em (TORRISI; BEMPORAD, 2004) e no Apêndice G. Algumas ferramentas de conversão do DHA para a classe MLD não aceitam fazer uma transição rápida da reconfiguração para um estado válido. Para contornar este problema, é necessário incluir um temporizador com um atraso, de forma que a transição da reconfiguração para um estado válido ocorra de forma suave. Assim, a expressão (3.13) pode ser reescrita como

$$SAS : \begin{cases} S(k+1) = S_{min} & \text{se } m_s(k) = 1 \\ S(k+1) = S(k) + \frac{\eta T_s}{C_{max}} \cdot i_1(k) & \text{se } m_s(k) = 2 \\ S(k+1) = S(k) + \frac{\eta T_s}{C_{max}} \cdot i_2(k) & \text{se } m_s(k) = 3 \\ S(k+1) = S_{max} & \text{se } m_s(k) = 4 \\ S(k+1) = S_{up} & \text{se } m_s(k) = 5 \\ temp(k+1) = temp(k) + a_n T_s & \\ S(k+1) = S_{low} & \text{se } m_s(k) = 6, \\ temp(k+1) = temp(k) + a_n T_s & \end{cases} \quad (C.13)$$

sendo $temp(k)$ um temporizador utilizado para a transição dos estados de reconfiguração. As dinâmicas de saturação são representadas por $m_s(k) \in \{1, 4\}$. As dinâmicas dos mapas

de *reset* incluem o termo de atraso $a_n T_s$, sendo a_n uma constante inteira e positiva. A dinâmica $m_s(k) \in \{2\}$ representa a evolução do SOC quando a MG estiver isolada. A dinâmica $m_s(k) \in \{3\}$ representa a evolução do SOC quando a MG estiver conectada com a rede principal. A corrente pode ser representada por um sistema afim por partes (PWA)

$$i_s(k) = \begin{cases} i_1(k) & \text{se } \neg u_g(k) \\ i_2(k) & \text{se } u_g(k) \end{cases} \quad (\text{C.14})$$

em que as variáveis $u_g(k)$, $i_1(k)$ e $i_2(k)$ foram definidas em (3.14), (3.15a) e (3.15b).

O EG do banco de baterias é definido por (C.15). A FSM (C.16) indica que cada dinâmica pertence a um estado discreto. O MS (C.17) representa a associação das dinâmicas de (C.12) com a FSM¹ (C.16)

$$EG : \begin{cases} [\delta_{s1}(k) = 1] \leftrightarrow [S(k) \leq S_{min}] \\ [\delta_{s2}(k) = 1] \leftrightarrow [S(k) \geq S_{max}] \\ [\delta_{s3}(k) = 1] \leftrightarrow [i_s(k) \leq 0] \\ [\delta_{s4}(k) = 1] \leftrightarrow [\neg \delta_{s1}(k) \wedge \neg \delta_{s2}(k)] \\ [\delta_{s5}(k) = 1] \leftrightarrow [u_g(k) \vee \neg \delta_{s3}(k)] \\ [\delta_{s6}(k) = 1] \leftrightarrow [u_g(k) \vee (\neg u_g(k) \wedge \delta_{s3}(k))] \\ [\delta_{s7}(k) = 1] \leftrightarrow [temp(k) \leq a_n T_s] \end{cases} \quad (\text{C.15})$$

$$FSM : x_{sb}(k+1) = \begin{cases} x_{sb1}(k) & \text{se } (x_{sb1} \wedge \delta_{s6}) \vee (x_{sb2} \wedge \delta_{s1}) \vee (x_{sb3} \wedge \delta_{s1}) \\ x_{sb2}(k) & \text{se } [(x_{sb2} \wedge \delta_{s4}) \vee (x_{sb3}) \vee (x_{sb5} \wedge \neg \delta_{s7}) \vee (x_{sb6} \wedge \neg \delta_{s7})] \wedge \neg u_g \\ x_{sb3}(k) & \text{se } [(x_{sb3} \wedge \delta_{s4}) \vee (x_{sb2}) \vee (x_{sb5} \wedge \neg \delta_{s7}) \vee (x_{sb6} \wedge \neg \delta_{s7})] \wedge u_g \\ x_{sb4}(k) & \text{se } (x_{sb4} \wedge \delta_{s5}) \vee (x_{sb2} \wedge \delta_{s2}) \vee (x_{sb3} \wedge \delta_{s2}) \\ x_{sb5}(k) & \text{se } (x_{sb4} \wedge \neg \delta_{s5}) \vee (x_{sb5}(k) \wedge \delta_{s7}) \\ x_{sb6}(k) & \text{se } (x_{sb1} \wedge \neg \delta_{s6}) \vee (x_{sb6} \wedge \delta_{s7}) \end{cases} \quad (\text{C.16})$$

$$MS : m_s(k) = \begin{cases} 1 & \text{se } x_{sb1}(k) \\ 3 & \text{se } x_{sb2}(k) \\ 4 & \text{se } x_{sb3}(k) \\ 5 & \text{se } x_{sb4}(k) \\ 2 & \text{se } x_{sb5}(k) \\ 6 & \text{se } x_{sb6}(k). \end{cases} \quad (\text{C.17})$$

¹ Por questão de espaço, nesta equação o termo (k) foi suprimido nas lógicas.

Os estados discretos são: ESS descarregado ($x_{sb1}(k)$), cíclico isolado ($x_{sb2}(k)$), cíclico conectado ($x_{sb3}(k)$), ESS carregado ($x_{sb4}(k)$), reconfiguração carregado ($x_{sb5}(k)$) e reconfiguração descarregado ($x_{sb6}(k)$). Os estados cíclicos representam a evolução do SOC através das equações para $m_s(k) = 2, 3$. Se a MG está isolada, a equação varia com a somatória das correntes de geração de energia das RES e da demanda das cargas ($i_1(k)$). Se a MG está conectada, o banco de baterias é carregado pelo controlador de carga com corrente $i_2(k)$. O estado ESS carregado ($x_{sb4}(k)$) só é válido se a MG estiver conectada ou a MG isolada e a soma das correntes das RES maior que a soma das correntes das cargas elétricas. Já o estado ESS descarregado ($x_{sb1}(k)$) só é válido se a MG estiver isolada e a soma das correntes das RES for menor que a soma das correntes das cargas elétricas. A maioria das transições em (C.15) depende da variação do SOC. Porém, nas dinâmicas dos estados carregado e descarregado, o SOC é constante. Essa condição não permite que determinados limites operacionais sejam alcançados para habilitar as transições entre estados discretos na FSM. Os estados de reconfiguração forçam $S(k)$ para um valor dentro do intervalo válido dos estados cíclicos que é $]S_{min} S_{max}[$. O temporizador $temp(k)$ conta $a_n T_s$ passos até que $\delta_{s7}(k)$ seja desabilitado. Com $\delta_{s7}(k) = 0$ ocorre a transição da reconfiguração para um dos estados cíclicos que depende do valor de $u_g(k)$. Após a transição o temporizador é zerado e fica pronto para contar uma nova reconfiguração, se houver.

APÊNDICE D – Altura da Turbina Eólica

A altura da turbina eólica é diferente da altura da estação automática dos dados meteorológicos. A velocidade dos ventos real na turbina eólica foi calculada usando um perfil logaritmo dado por,

$$\frac{v}{v_0} = \frac{\ln(H/z_0)}{\ln(H_0/z_0)} \quad (\text{D.1})$$

onde z_0 é o comprimento de rugosidade, H_0 é a altura de referência correspondente à velocidade v_0 na estação automática e H é altura correspondente à velocidade v na turbina eólica respectivamente. Para o estudo de caso, $H = 15\text{m}$, $H_0 = 10\text{m}$ e $z_0 = 1\text{m}$. Os valores das alturas foram obtidos no local de instalação das estações automáticas e turbina eólica e o comprimento de rugosidade foi retirado em uma tabela de rugosidades (MASTERS, 2013) classificado para zona urbana.

APÊNDICE E – Estratégia Baseada em Regras (RBS)

O algoritmo RBS consiste nos seguintes passos:

1. A derivada do estado de carga (SOC) no tempo das baterias é monitorado em n_c faixas de operação, onde n_c é o número de cargas controláveis. As faixas são intervalos entre derivadas negativas do SOC para evitar que o banco de baterias tenha uma descarga profunda;
2. Caso esteja na faixa 1 de valores da taxa de variação do SOC, verifica se as cargas estão ligadas, desliga a carga de menor prioridade e vai ao passo 3. Caso esteja na faixa 2, verifica se as cargas estão ligadas, desliga de 1 a 2 cargas de menor prioridade e vai ao passo 3. Caso esteja na faixa $n_c - 1$, verifica se as cargas estão ligadas, desliga de uma a $n_c - 1$ cargas de menor prioridade e vai ao passo 3. Caso a taxa variação do SOC ultrapasse o menor valor permitido, desliga todas as cargas e vai para o passo 3. Caso contrário, não desliga cargas e vai para o passo 3;
3. O estado de carga das baterias e o balanço de potência são monitorados;
4. Faz a verificação da restrição da quantidade de conexões permitidas da microrrede em um intervalo de tempo. Se a restrição estiver ativa a MG permanece isolada e retorna ao passo 1, caso contrário vá para o passo 5;
5. Verifica se a microrrede conectou com a rede principal. Caso afirmativo a microrrede permanece conectada por, no mínimo, T_{up} períodos de tempo e depois retorna ao passo 1, caso contrário vá ao passo seguinte;
6. Se a microrrede não se conectou, verifica as seguintes condições de conexão: a) O estado de carga do banco de baterias está no nível crítico ou; b) A potência RES gerada é superior a demanda das cargas mais o carregamento do banco de baterias. Se umas das condições for verdadeira a microrrede conecta/mantém conectada na rede principal, caso contrário a MG não conecta/desconecta e volta ao passo 1. Caso a microrrede esteja conectada e pelos critérios anteriores foi desconectada da rede principal, a MG permanece desconectada por, no mínimo, T_{down} períodos de tempo.

APÊNDICE F – Conjunto de Dados Meteorológicos Previstos e Medidos

Este apêndice apresenta os arquivos de dados meteorológicos e de potência das fontes renováveis que são utilizados para resolver o problema de despacho econômico da microrrede no estudo de caso da Seção 5.2.2. Esta metodologia é utilizada também no artigo “*Management of an island and grid-connected microgrid using hybrid economic model predictive control with weather data*” (SILVA et al., 2020a). São apresentados cinco conjunto de dados para cada localidade. 1) Banco de dados meteorológicos medidos baixado do site do instituto nacional de meteorologia; 2) Banco de dados WRF derivado dos dados brutos gerados pelo modelo de previsão *weather research and forecasting*; 3) Banco de dados meteorológicos que junta os dados previstos com os dados medidos em um só arquivo; 4) Arquivos que contém somente os dados de temperatura, irradiância e velocidade dos ventos; 5) Arquivos contendo a potência eólica e solar medida e prevista. Estes dados estão disponíveis na base de dados Silva et al. (2020b).

F.1 Descrição dos Dados

Os dados propostos são necessários para a obtenção da geração de potência eólica e solar de quaisquer sistemas de potência que inclua estas fontes de geração de energia tais como: microrredes, planta de potência virtual, sistemas que combinam calor e potência, fazendas eólicas, fazendas de energia solar, entre outras. No trabalho de Silva et al. (2020a) foi proposto um algoritmo de gerenciamento de uma microrrede composta por painéis fotovoltaicos, turbina eólica, conversores (fotovoltaico e eólico), painel de controle das cargas, cargas resistivas controláveis, sistema de armazenamento de energia do tipo banco de baterias e painel de conexão comum. O algoritmo de otimização proposto contempla um sinal de controle ótimo para o despacho econômico da microrrede através de dados de previsão de potência solar e fotovoltaica 1 hora a frente. Neste algoritmo é necessário atualizar os valores do instante atual da microrrede com a potência medida. Outros estudos foram realizados com os dados meteorológicos medidos e previstos apresentados em Silva et al. (2020a):

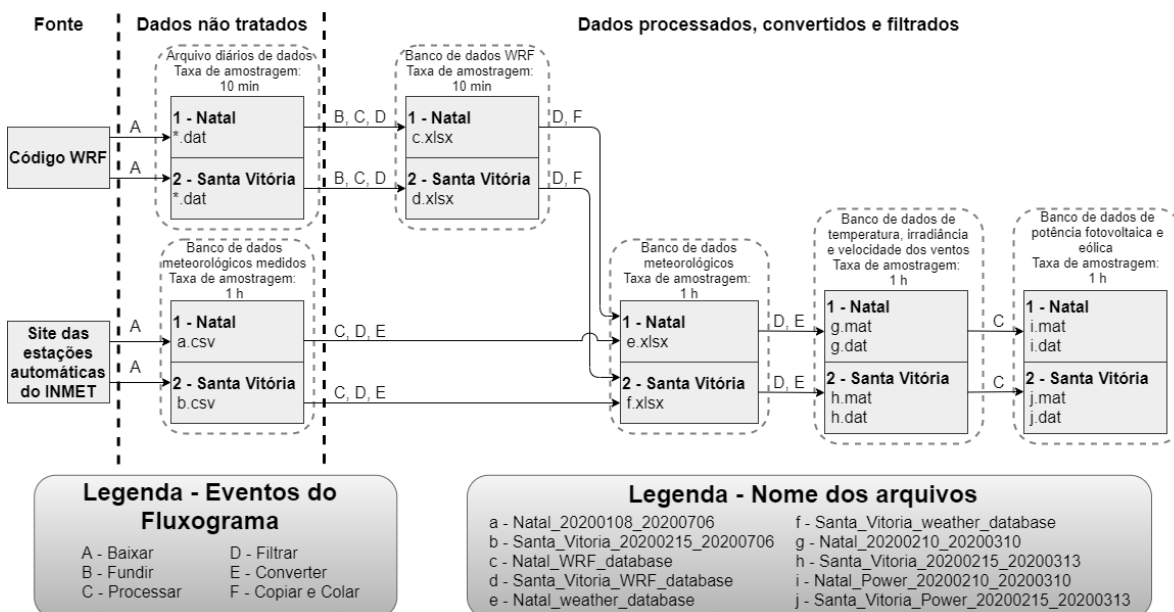
- cálculo dos erros de previsão dos dados meteorológicos de temperatura, irradiância e velocidade dos ventos;
- cálculo dos erros de previsão das potências eólica e fotovoltaica; e

- análise de sensibilidade do algoritmo de otimização comparando os resultados usando dados de previsão de potência e a previsão perfeita, isto é, a previsão é conhecida a priori.

A Fig. F.1 mostra o fluxograma de obtenção dos dados. Os dados brutos obtidos através do INMET e do modelo WRF são convertidos, processados e filtrados em quatro conjuntos de dados:

1. base de dados WRF: são dados que consideram o cálculo de algumas grandezas, a conversão da hora no fuso horário local e a conversão da taxa de amostragem para Natal e Santa Vitória;
2. base de dados meteorológica: se referem a junção dos dados medidos das estações automáticas com os dados previstos do modelo WRF de temperatura, irradiância e velocidade dos ventos;
3. dados de temperatura, irradiância e velocidade dos ventos: São os dados responsáveis por gerar os gráficos e tabelas dos resultados numéricos em (SILVA et al., 2020a) e os dados de potência renovável; e
4. dados de potência eólica e solar: São os dados de potência real e prevista obtida através dos dados de temperatura, irradiância e velocidade dos ventos e dos modelos matemáticos propostos em (SILVA et al., 2020a).

Figura F.1 – Fluxograma de obtenção e processamento do conjunto de dados meteorológicos e de potência renovável.



Fonte: próprio autor.

A seguir uma descrição detalhada de cada conjunto de dados.

F.1.1 Dados brutos

F.1.1.1 Base de dados diária

São arquivos brutos (.dat) diários com as previsões meteorológicas de um dia a frente dos dados descritos na Tabela 1. Os dados foram coletados entre os dias 08/01/2020 à até 06/07/2020 para Natal e de 15/02/2020 até 06/07/2020 para Santa Vitória do Palmar e amostrados a cada 10 minutos.

Tabela 32 – Variáveis da base de dados brutos gerada pelo código do modelo WRF.

Variáveis	Descrição
Time	Tempo e data UTC
X	Índice X na direção oeste-leste
Y	Índice Y na direção sul-norte
Z	Índice Z na direção vertical (altura)
P	Pressão de perturbação
PB	Pressão de estado de base
PH	Geopotencial de perturbação
PHB	Geopotencial de estado de base
U	Velocidade do vento componente X
V	Velocidade do vento componente Y
W	Velocidade do vento componente Z
HGT	Altura do terreno
U10	Velocidade do vento componente X a 10 metros de altura em relação ao terreno
V10	Velocidade do vento componente Y a 10 metros de altura em relação ao terreno
T2 (K)	Temperatura
SWDOWN	Irradiação de ondas curtas

O modelo WRF gerou 320 arquivos diários: 179 arquivos para Natal e 141 arquivos para Santa Vitoria do Palmar. Por questões de simplicidade estes dados não serão disponibilizados. Todas as informações destes arquivos são encontradas nos arquivos base de dados WRF.

F.1.1.2 Base de dados meteorológicos medidos

São arquivos brutos (.csv) gerados pelas estações automáticas do INMET entre os dias 08/01/2020 à até 06/07/2020 para Natal e de 15/02/2020 até 06/07/2020 para Santa Vitória do Palmar. Uma estação meteorológica automática coleta, de minuto em minuto, as informações meteorológicas (temperatura, umidade, pressão atmosférica, precipitação, direção e velocidade dos ventos, radiação solar) representativas da área em que está localizada. A cada hora, estes dados são integralizados e disponibilizados para serem transmitidos, via satélite ou telefonia celular, para a sede do INMET, em Brasília. O conjunto dos dados recebidos é validado, através de um controle de qualidade e armazenado

em um banco de dados. Além disto, os dados são disponibilizados gratuitamente, em tempo real, através da internet (INMET, 2020) para a elaboração de diversos produtos meteorológicos tais como laudos meteorológicos, relatórios meteorológicos, vigilância do tempo, previsão do tempo e previsão meteorológica. Estes dados podem ser usados para uma vasta gama de aplicações em pesquisa em hidrologia e oceanografia (KUROSAWA YUSUKE UCHIYAMA, 2020).

F.1.2 Dado filtrados, processados e convertidos

F.1.2.1 Base de dados WRF

Esta base de dados é a junção de todas as planilhas diárias de Natal e Santa Vitória com as previsões de um dia a frente. Além dos dados meteorológicos descritos na Tabela 1, esta planilha contém:

- colunas adicionais com a hora local, temperatura em °C, cálculo da velocidade do vento resultante (W_{speed}) a 10 metros de altura que corresponde a altura das estações automáticas e o cálculo da direção do vento; e
- colunas adicionais com as variáveis U_{10} , V_{10} , W_{speed} , Dir , SWD , e T_2 amostrados a cada hora.

O modelo WRF não gerou a previsão nos dias 14/03/2020 a 16/03/2020, 28/03/2020 a 30/03/2020, 05/04/2020 a 06/04/2020 e dia 06/06/2020 por falta de energia elétrica. Assim os dias faltantes estão destacados de vermelho na planilha.

F.1.2.2 Base de dados meteorológicos

São planilhas que contém todos as informações do banco de dados meteorológicos medidos mais a inclusão das seguintes variáveis:

- hora local (horário de Brasília);
- temperatura prevista;
- velocidade do vento prevista;
- direção do vento prevista;
- irradiância convertida de kJ/m^2 para W/m^2 ; e
- irradiância prevista.

Ressalta-se que, devido aos problemas com o modelo WRF por falta de energia elétrica, os dados previstos estão em branco nos dias 14/03/2020 a 16/03/2020, 28/03/2020 a 30/03/2020, 05/04/2020 a 06/04/2020 e dia 06/06/2020.

F.1.2.3 Base de dados de temperatura, irradiância e velocidade dos ventos

Os arquivos foram obtidos através de filtragem de variáveis e de intervalo de tempo da base de dados meteorológica. Os dados foram filtrados entre os dias 10/02/2020 até 10/03/2020 para Natal e do dia 15/02/2020 até 13/03/2020 para Santa Vitória do Palmar. A coluna 1 se refere a hora local (horário de Brasília). As colunas 2, 4 e 6 se referem aos dados medidos de temperatura, irradiância e velocidade dos ventos, respectivamente. As colunas 3, 5 e 7 são os dados previstos de temperatura, irradiância e velocidade dos ventos, respectivamente. A taxa de amostragem é de 1 hora. Os gráficos, tabelas e figuras de Silva et al. (2020a) foram elaborados baseado na simulação de uma semana de dados entre os meses de fevereiro e março de 2020.

F.1.2.4 Base de dados das potências fotovoltaica e eólica

Estes dados foram obtidos através dos modelos matemáticos de geração solar e eólico em Silva et al. (2020a) em conjunto com os dados de temperatura, irradiância e velocidade dos ventos. Os dados foram calculados entre os dias 10/02/2020 até 10/03/2020 para Natal e do dia 15/02/2020 até 13/03/2020 para Santa Vitória do Palmar. As colunas 1 e 3 se referem a potência eólica medida e prevista respectivamente. As colunas 2 e 4 representam a potência fotovoltaica medida e prevista respectivamente.

F.2 Metodologia de Obtenção dos Dados

Para gerar os arquivos de dados meteorológicos, foram utilizadas as seguintes metodologias (veja Fig. F.1).

- A – Download através de *webpage* ou geração de arquivos através de um código (*script*). No site das estações automáticas do INMET escolhemos qual a localidade, a data de início e data final dos dados. O site do INMET gera os dados e um *link* para download no formato .csv. O modelo global WRF consiste em códigos desenvolvidos por localidade escolhida através das coordenadas geográficas. No código do WRF é configurado quais variáveis meteorológicas são escolhidas, o tempo de previsão e a taxa de amostragem. O código foi configurado para gerar arquivos .dat diários com taxa de amostragem de 10 minutos;
- B – Junção de arquivos. Os dados do modelo WRF foram gerados diariamente em vários arquivos. Foi necessário juntar este conjunto de dados em um único arquivo para representar um intervalo de tempo total. Neste caso os dados foram obtidos em planilhas diárias da seguinte forma:
 - Natal: entre os dias 08/01/2020 à meia noite até 06/07/2020 as 11:50 P.M; e

- Santa Vitória do Palmar: entre os dias 15/02/2020 à meia noite até 06/07/2020 as 11:50 P.M.

C – O processamento de dados consiste em:

- fórmulas matemáticas para conversão de unidades. A temperatura fornecida em Kelvin foi convertida em Celsius. A Irradiância em W/m^2 foi calculada a partir da radiação solar fornecida em $kJ/(h*m^2)$. Conversão: $1,0 W/m^2 = 3,6kJ/(h*m^2)$);
- fórmulas matemáticas para o cálculo de grandezas. A velocidade do vento resultante foi obtida pela seguinte equação: $W_{speed} = \sqrt{U_{10}^2 + V_{10}^2}$. A direção do vento foi obtida pela seguinte equação: $Dir = 90 - \arctan(V_{10}/U_{10}) * (180/\pi) + \alpha_0$, onde $\alpha_0 = 180$ se $U_{10} > 0$, caso contrário $\alpha_0 = 0$; e
- tratamento de dados com valores fora do padrão. Alguns valores medidos da radiação solar na madrugada estavam muito maiores que os valores medidos ao meio dia, indicando uma inconsistência. Estes valores espúrios foram substituídos pelos dados previstos pelo modelo WRF da respectiva localidade;

D – Filtragem dos dados. Os dados brutos contêm grandezas que não foram usadas para a simulação do gerenciamento da MG em (SILVA et al., 2020a). Somente os dados de temperatura, irradiância e velocidade dos ventos foram considerados. A filtragem de dados foi feita com o comando filtro do MS Excel;

E – Conversão de arquivos. Os dados brutos foram convertidos para formatos mais amigáveis como a extensão .xlsx. Nestes formatos foi possível desenvolver fórmulas matemáticas e a filtragem de dados diretamente na planilha. Em outros casos os arquivos foram convertidos para .mat, extensão usada no Matlab para a simulação do algoritmo de otimização da MG em (SILVA et al., 2020a) e no formato .dat para dar opções aos leitores qual dado é mais amigável a sua aplicação;

F – Copiar e colar dados. Os dados de previsão WRF foram copiados para um mesmo arquivo de dados que contém os dados meteorológicos. A unificação destes dados facilita a extração e conversão dos dados previstos e medidos por softwares de simulação como o Matlab e facilita a plotagem de gráficos.

APÊNDICE G – Descrição dos Modelos DHA no HYSDEL

G.1 Painéis Fotovoltaicos

```

1 SYSTEM PV {
2   INTERFACE {
3     STATE {
4       /* Estados continuos do modelo PV */
5       REAL x1 [-1500, 1500], x2 [-1500, 1500];
6       REAL x3 [-1500, 1500], x4 [-1500, 1500];
7       /* em Whatts */
8     }
9
10    INPUT {
11      /* Setpoint MPPT que varia a cada instante k com a
12      temperatura e irradiancia */
13      REAL u [0, 1500];
14    }
15
16    PARAMETER{
17      /* coeficientes das matrizes espaco de estados */
18      REAL a11, a12, a13, a14;
19      REAL a21, a22, a23, a24;
20      REAL a31, a32, a33, a34;
21      REAL a41, a42, a43, a44;
22      REAL b1, b2, b3, b4;
23      REAL c1, c2, c3, c4;
24    }
25
26    OUTPUT {
27      /* Potencia fotovoltaica */
28      REAL Ppvout;
29    }
30  } /* Fim interface */
31
32  IMPLEMENTATION {
33
34    AUX{
35      REAL z1, z2, z3;
36      BOOL d, p, q;
37    }
38

```

```

39 AD {
40     /* Saturacoes de potencia */
41     d = u >= 1500;
42     p = u >=0;
43 }
44 LOGIC {
45     /* Condicao do MPPT */
46     q = ~d & p; /*u >=0 & u < 1500 */
47 }
48
49 DA {
50     z1 = {IF d THEN 1500 ELSE 0};
51     z2 = {IF ~p THEN 0 };
52     z3 = {IF q THEN u ELSE 0};
53 }
54
55 CONTINUOUS {
56     x1 = a11*x1+a12*x2+ a13*x3+a14*x4+b1*(z1+z2+z3);
57     x2 = a21*x1+a22*x2+ a23*x3+a24*x4+b2*(z1+z2+z3);
58     x3 = a31*x1+a32*x2+ a33*x3+a34*x4+b3*(z1+z2+z3);
59     x4 = a41*x1+a42*x2+ a43*x3+a44*x4+b4*(z1+z2+z3);
60 }
61
62 OUTPUT {
63     Ppvout = c1*x1+c2*x2+c3*x3+c4*x4;
64 }
65 } /* Fim implementatacao */
66 } /* Fim algoritmo*/

```

G.2 Turbina Eólica

```

1 SYSTEM eolico {
2     INTERFACE {
3         STATE {
4             /* Potencia eolica*/
5             REAL Pw [0, 1000];
6             /* Estados de geracao da turbina eolica */
7             BOOL parado, operando, nominal, falha;
8             }
9
10        INPUT {
11            /* Setpoint da malha de potencia*/
12            REAL Pg [0, 1000];
13            /* velocidade do vento em m/s */
14            REAL vel [0, 50];
15        }

```

```

16     } /* Fim interface */
17
18 IMPLEMENTATION {
19     AUX {
20         BOOL d1, d2, d3, op, pn;
21         REAL xnominal, xfail, xo, xop;
22     }
23
24     /* declaracao dos eventos em funcao da velocidade */
25     AD {
26         d1 = vel >= 2; /* Velocidade de cut-in */
27         d2 = vel >= 12; /* Pot. Nominal turbina */
28         d3 = vel >= 16; /* Velocidade de cut-off */
29     }
30
31     LOGIC {
32         /* Evento de maxima eficiencia (MPPT) */
33         op = d1 & ~d2; /*vel >=2 & vel < 12 */
34         /* Evento potencia nominal */
35         pn = d2 & ~d3; /*vel >=12 & vel < 16 */
36     }
37
38     AUTOMATA {
39         parado = (~d1 & operando) | (parado & ~d1) | (falha & ~d1) | (nominal
& ~d1);
40         operando = (operando & op) | (parado & d1) | (nominal & ~d2) | (falha
& op);
41         nominal = (nominal & pn) | (operando & d2) | (falha & ~d3) | (parado
& pn);
42         falha = (falha & d3) | (nominal & d3) | (operando & d3) | (parado &
d3);
43     }
44
45     /* Descrevendo a dinamica do automato hibrido por estado de operacao da
turbina eolica*/
46     DA {
47         xo = {IF parado THEN 0 ELSE 0};
48         /* Se refere ao MPPT */
49         xop = {IF operando THEN Pg ELSE 0};
50         xnominal = {IF nominal THEN 1000 ELSE 0};
51         /* Se refere ao cut-off */
52         xfail = {IF falha THEN 50 ELSE 0};
53     }
54
55     CONTINUOUS{
56         Pw = xop + xfail + xo + xnominal;
57     }

```

```

58 } /* Fim implementatacao */
59 } /* Fim algoritmo*/

```

G.3 Banco de Baterias

```

1 SYSTEM bateria {
2
3 INTERFACE {
4   PARAMETER {
5     REAL Ts, Tsmpc, Q, V, xsb, Prectifier, ures, ubalance;
6     /* Minimo e maximo soc */
7     REAL Smin, Smax;
8     /* Demanda das cargas */
9     REAL Dc1, Dc2, Dc3, Dc4, Dc5;
10    }
11   STATE {
12     /* Balanco de potencia em kW*/
13     REAL Pbalance[-ubalance, ubalance];
14     REAL soc[Smin-0.1,Smax+0.2];
15     /* Temporizador dos estados reset */
16     REAL tt[0, 5];
17     /* Estados discretos */
18     BOOL descarregado, ciclico_isolado, ciclico_conectado;
19     BOOL carregado, reset_carregado, reset_descarregado;}
20   INPUT {
21     /* soma das potencias PV + WT */
22     REAL Pres [0, ures];
23     /* Cargas */
24     REAL zc1[0, Dc1], zc2[0, Dc2], zc3[0, Dc3], zc4[0, Dc4], zc5[0, Dc5];
25     BOOL urede;
26   }
27
28   OUTPUT {
29     REAL s;}
30   }
31   IMPLEMENTATION {
32     AUX{
33     /* Bateria */
34     REAL z1, z2, z3, z4, z5, z6, z7;
35     /* Variavel aux. carregador da bateria como carga */
36     REAL zret;
37     /* Bateria */
38     BOOL d1, d2, d3, d7;
39     /* Carga do controlador de carga das baterias */
40     BOOL dret;
41   }

```

```

42
43 AD {
44     /* Bateria */
45     d1 = soc <= 0; /* — */
46     d2 = soc >= 1; /* — */
47     d3 = Pbalance>=0; /* Potencia das cargas maior que das fontes*/
48     /* HYSDEL nao aceita o chaveamento dos estados discretos no proximo
instante.
49     Necessita de um temporizador para chaver n instantes depois */
50     d7 = tt <= Ts;
51 }
52
53 LOGIC {
54     /* Condicao do controlador de carga para carregar as baterias*/
55     dret = urede & ~d2;
56 }
57
58 AUTOMATA {
59     descarregado = (descarregado & (~urede & d3)) | (ciclico_isolado & d1
) | (ciclico_conectado & d1) ;
60     ciclico_isolado = ((ciclico_isolado & ~d1 & ~d2)|(reset_descarregado
& ~d7)|(reset_carregado & ~d7)|(ciclico_conectado & ~d1 & ~d2)& ~urede;
61     ciclico_conectado = ((ciclico_conectado & ~d1 & ~d2)|(
reset_descarregado & ~d7)|(reset_carregado & ~d7)|(ciclico_isolado & ~d1
& ~d2)) & urede;
62     carregado = (carregado & (urede | ~d3))| (ciclico_isolado & d2) | (
ciclico_conectado & d2);
63     /* A funcao dos resets eh garantir que o sistema consiga entrar
64     em uma regio valida do SOC */
65     reset_carregado = (~(urede | ~d3) & carregado) | (reset_carregado &
d7);
66     reset_descarregado = (~(~urede | (urede & ~d3)) & descarregado) | (
reset_descarregado & d7);
67 }
68
69 DA {
70     z1 = {IF descarregado THEN 0 ELSE 0};
71     z2 = {IF ciclico_isolado THEN soc-Tsmpc*1000*(-Pres + zc1 + zc2 +
zc3 + zc4 + zc5 + zret)/(sqrt(3)*V)/Q - xsb
72     ELSE 0};
73     z3 = {IF ciclico_conectado THEN soc+Tsmpc*(1/Q)*(Prectifier/V) - xsb
74     ELSE 0};
75     z4 = {IF carregado THEN 1.001 ELSE 0};
76     z5 = {IF reset_carregado THEN 0.99 ELSE 0};
77     z6 = {IF reset_descarregado THEN 0.01 ELSE 0};
78     /* Mantem o modelo nos estados reset por alguns instantes para evitar
um chaveamento brusco e erro na atualizacao de variaveis */

```

```

79     z7 = {IF (reset_carregado | reset_descarregado) THEN tt+Ts ELSE 0};
80     /* O controlador de carga das baterias so eh considerado uma carga
81     com a rede conectada */
82     zret = {IF dret THEN Prectifier ELSE 0};
83     }
84     CONTINUOUS {
85     /* balanço de potencia */
86     Pbalance = -Pres + zc1 + zc2 + zc3 + zc4 + zc5 + zret;
87     soc = z1+z2+z3+z4+z5+z6;
88     tt = z7;
89     }
90     OUTPUT {
91     s=soc;
92     } /* Fim implementatacao */
93 } /* Fim algoritmo*/

```

G.4 Controlador de Carga

```

1 SYSTEM controlador_carga {
2     INTERFACE {
3
4         STATE {
5             BOOL desabilitado , habilitado;
6         }
7         INPUT {
8             REAL soc[-0.1, 1.1];
9         }
10
11        OUTPUT {
12            BOOL habilita_carga;
13        }
14    }
15    IMPLEMENTATION {
16        AUX {
17            BOOL desabilita , habilita;
18        }
19
20        /* declaracao dos eventos em funcao do soc */
21        AD {
22            desabilita = soc <= 0.25; /* — */
23            habilita = soc >= 0.8; /* — */
24        }
25
26        AUTOMATA {
27            desabilitado = (desabilita & habilitado) | (desabilitado & ~habilita);

```

```

28     habilitado = (habilita & desabilitado) | (habilitado & ~desabilita)
29     ;
30     }
31     OUTPUT {
32     habilita_carga = habilitado;
33     }
34
35 } /* Fim implementatacao */
36 } /* Fim algoritmo*/

```

G.5 Tarifas de Energia

```

1 SYSTEM preco_energia {
2     INTERFACE {
3         PARAMETER {
4             /* preco de venda e preco de compra, limites do balanço de potencia ,
5             potencia do controlador de carga e das fontes RES */
6             REAL compra, venda, ubalance, Prectifier, ures;
7             REAL Dc1, Dc2, Dc3, Dc4, Dc5;
8             }
9         STATE {
10            /* Estados de custo instantaneo de energia em US$ e temporizacao em
11            segundos */
12            REAL Pbalance[-ubalance, ubalance];
13            REAL custo[-2,2];
14            }
15        INPUT {
16            /* Soma das potencias PV + WT */
17            REAL Pres [0, ures];
18            /* Cargas electricas */
19            REAL zc1[0, Dc1], zc2[0, Dc2], zc3[0, Dc3], zc4[0, Dc4], zc5[0, Dc5];
20            /* Cargas */
21            /* Entradas que vem do banco de baterias */
22            BOOL urede, dret;
23            }
24        OUTPUT {
25            /* compra dg = 0 ou venda de energia dg = 1 */
26            BOOL dg;
27            }
28        } /* end interface */
29
30    IMPLEMENTATION {
31        AUX {

```

```

32  /* Custo de energia */
33  REAL zp1, zp2;
34  REAL zret; /* Variavel aux. carregador da bateria como carga */
35  BOOL d3;
36  }
37
38  /* declaracao dos eventos em funcao do balanco de potencia */
39  AD {
40    /* Corrente das cargas maior que das fontes*/
41    d3 = Pbalance >= 0;
42  }
43
44  DA {
45    /* OBS: devido ao hysdel aceitar somente funcoes afins, o calculo do
46    preco
47    sera feito fora do hysdel. Nao aceita Pg(k)*venda(k) */
48    /* O carregador soh eh considerado uma carga com a rede conectada */
49    zret = {IF dret THEN Prectifier ELSE 0};
50    /* Custo de energia */
51    zp1 = {IF ~d3 THEN (-Pres + zc1 + zc2 + zc3 + zc4 + zc5 + zret)*
52    venda
53    ELSE (-Pres + zc1 + zc2 + zc3 + zc4 + zc5 + zret)*compra};
54    zp2 = {IF urede THEN zp1 ELSE 0};
55  }
56
57  CONTINUOUS{
58    Pbalance = -Pres + zc1 + zc2 + zc3 + zc4 + zc5 + zret;
59    custo = zp2;
60  }
61
62  OUTPUT {
63    /* compra dg = 0 ou venda de energia dg = 1 */
64    dg = d3;
65  }
66 } /* Fim implementatacao */
67 } /* Fim algoritmo*/

```

G.6 Cargas Elétricas

```

1 SYSTEM cargas {
2   INTERFACE {
3     PARAMETER {
4       REAL Dc1, Dc2, Dc3, Dc4, Dc5;
5     }
6   STATE {

```

```
7      /* Demanda individual de cada carga */
8      REAL D2[0, Dc2], D3[0, Dc3], D4[0, Dc4], D5[0, Dc5];
9      /* Potencia total consumida pelas cargas */
10     REAL P1;
11     }
12
13     INPUT {
14         /* Liga cargas 2, 3, 4 e 5. Carga 1 sempre ligada */
15         BOOL c2, c3, c4, c5;
16     }
17
18     } /* end interface */
19
20     IMPLEMENTATION {
21         AUX {
22             /* Cargas */
23             REAL zc1, zc2, zc3, zc4, zc5; /* Retira zc1 */
24         }
25
26         LINEAR {
27             zc1 = Dc1; /* Carga critica constante */
28         }
29     /* Condicao de ligacao das cargas */
30     DA {
31         zc2 = {IF c2 THEN 0 ELSE Dc2};
32         zc3 = {IF c3 THEN 0 ELSE Dc3};
33         zc4 = {IF c4 THEN 0 ELSE Dc4};
34         zc5 = {IF c5 THEN 0 ELSE Dc5};
35     }
36
37     CONTINUOUS {
38         P1 = zc1 + zc2 + zc3 + zc4 + zc5;
39     }
40
41     } /* Fim implementacao */
42 } /* Fim algoritmo*/
```


APÊNDICE H – Produção Científica

H.1 Artigo em Periódico Indexado Internacional Padrão Capes

Qualis A1: Revista Applied Energy, fator de impacto 8,8. Danilo P. e Silva, José L. Félix Salles, Jussara F. Fardin, Maxsuel M. Rocha Pereira, *Management of an island and grid-connected microgrid using hybrid economic model predictive control with weather data*, Volume 278, 2020, ISSN 0306-2619, <https://doi.org/10.1016/j.apenergy.2020.115581>.

H.2 Trabalhos Completos Publicados em Eventos Internacionais

Hybrid modeling of energy storage system and electrical loads in a pilot-microgrid, in: 2018 13th IEEE Int. Conf. Ind. Appl., BR, 2018. <https://doi.org/10.1109/induscon.2018.8627180>.

D. De Souza Martins, D.P. e Silva, J.F. Fardin, *Hybrid Model of Electric Vehicle*, in: 2019 IEEE 15th Brazilian Power Electron. Conf. 5th IEEE South., 2019: pp. 1–6. <https://doi.org/10.1109/COBEP/SPEC44138.2019.9065399>.

H.3 Trabalhos Completos Publicados em Eventos Nacionais

D.P. e Silva, D. Carletti, T.M. de Christo, R.C. Basoni, M.D. Queiroz, I.O. Barbosa, M.T.D. Orlando, J.F. Fardin, *Project of a Pilot-Microgrid connected to the Main Grid*, in: Blucher Phys. Proc., Editora Blucher, São Paulo, 2017: pp. 96–101. <https://doi.org/10.5151/phypro-viii-efa-23>.

D.P. e Silva, G.F. Fraga, J.L.F. Salles, J.F. Fardin, V.B. de Oliveira Junior, *Modeling and simulation of firing the boiler igniters of a gas-fired thermoelectric*, in: Blucher Phys. Proc., BR, 2018: pp. 232–237. <https://doi.org/10.5151/phypro-viii-efa-49>.

C.A.C. Passos, D.P. e Silva, D. Carletti, T.M. de Christo, R.C. Basoni, M.D. Queiroz, I.O. Barbosa, M.T.D. Orlando, J.F. Fardin, *Teste de um protótipo limitador de corrente falta supercondutor de cerâmica SmBaCuO*, in: Blucher Phys. Proc., BR, 2018: pp. 248–253. <https://doi.org/10.5151/phypro-viii-efa-52>.

H.4 Base de Dados Meteorológicos

P. e Silva, Danilo; L. F. Salles, Jose; R. Pereira, Maxsuel; F. Fardin, Jussara; Ottz, Vinicius 2020, *Measured weather and power dataset for management of an island and grid-connected microgrid*, Mendeley Data, V1. <https://doi.org/10.17632/skxgmkc64k.1>

H.5 Trabalhos Prontos para Submissão

P. e Silva, Danilo; L. F. Salles, Jose; R. Pereira, Maxsuel; F. Fardin, Jussara; Ottz, Vinicius 2020, *Measured weather and power dataset for management of an island and grid-connected microgrid*

Um resumo deste trabalho consta no Apêndice F.