

Guilherme Henrique Alves

**Sistema de Gerenciamento de Energia Orientado
à Arbitragem Energética e Recomendações para
Operação Isolada de Microrredes**

Uberlândia

2023

Guilherme Henrique Alves

**Sistema de Gerenciamento de Energia Orientado à
Arbitragem Energética e Recomendações para Operação
Isolada de Microrredes**

Defesa de Tese apresentado à Universidade Federal de Uberlândia como parte dos requisitos para obtenção do título de Doutor em Ciências na área de concentração de Engenharia Elétrica.

Universidade Federal de Uberlândia - UFU
Faculdade de Engenharia Elétrica
Programa de Pós-Graduação em Engenharia Elétrica

Orientador: Geraldo Caixeta Guimarães

Uberlândia
2023

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

A474
2023

Alves, Guilherme Henrique, 1989-
Sistema de Gerenciamento de Energia Orientado à
Arbitragem Energética e Recomendações para Operação
Isolada de Microrredes [recurso eletrônico] / Guilherme
Henrique Alves. - 2023.

Orientador: Geraldo Caixeta Guimarães.
Tese (Doutorado) - Universidade Federal de Uberlândia,
Pós-graduação em Engenharia Elétrica.
Modo de acesso: Internet.
Disponível em: <http://doi.org/10.14393/ufu.te.2023.457>
Inclui bibliografia.

1. Engenharia elétrica. I. Guimarães, Geraldo Caixeta,
1954-, (Orient.). II. Universidade Federal de
Uberlândia. Pós-graduação em Engenharia Elétrica. III.
Título.

CDU: 621.3

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074

Guilherme Henrique Alves

Sistema de Gerenciamento de Energia Orientado à Arbitragem Energética e Recomendações para Operação Isolada de Microrredes

Defesa de Tese apresentado à Universidade Federal de Uberlândia como parte dos requisitos para obtenção do título de Doutor em Ciências na área de concentração de Engenharia Elétrica.

Trabalho _____. Uberlândia, ____ de _____ de _____ :

Geraldo Caixeta Guimarães
Professor Dr. Orientador

Fabício Augusto Matheus Moura
Professor Dr.

Alexandre Rasi Aoki
Professor Dr.

Paulo Henrique Oliveira Rezende
Professor Dr.

Thales Lima Oliveira
Professor Dr.

Uberlândia
2023

Dedico este trabalho a minha família, pois sem eles, eu não teria capacidade para vencer mais este desafio.

Agradecimentos

Agradeço primeiro a Deus por estar ao meu lado nos momentos de fraqueza, nas lutas e controvérsias, vitórias, derrotas e por todas as oportunidades que tive em minha vida.

Aos meus pais, Veronice e Sergio que me deram a vida e me ensinaram a vivê-la com dignidade. Que me compartilharam os ideais e os alimentaram, incentivando-me a prosseguir na jornada, seja quais fossem os obstáculos.

À minha irmã Amanda e meu cunhado Denis, pelo incentivo a continuar focado nos meus objetivos.

À minha namorada, Maikelly, por estar ao meu lado me incentivando, ouvindo e sempre pronta a oferecer-me suas palavras de apoio e carinho.

Aos meus avós que neste momento de conquista não estão presentes para comemorar comigo, e hoje não tenho os seus abraços fortes e carinhosos, mas guardo os ensinamentos que deixaram.

Ao meu orientador Dr. Geraldo Caixeta Guimarães, pelas orientações, dedicações, paciência e principalmente pelas amizades durante todo o processo.

Aos demais professores do Programa de Pós-Graduação em Engenharia Elétrica (PPGEELT), Universidade Federal de Uberlândia (UFU) - Faculdade de Engenharia Elétrica (FEELT), agradeço pelos seus ensinamentos em sala de aula.

A todos os amigos do Núcleo de Dinâmica de Sistemas Elétricos (NDSE), em especial: Thales, Jaqueline e Mateus.

Aos amigos da FEELT: Arthur Costa, Júlia Rosenthal e Lúcio Rogério, pela contribuição nos desafios da pesquisa.

Aos amigos da Universidade de Uberaba (UNIUBE) onde ministrei aulas, em especial, a Marco Antônio, Leandro Aureliano, Marcelo Lucas, Luís César, Antônio Manoel, Eduardo Mangucci, Edilberto Teixeira, Isaías de Jesus, Ana Cláudia Chesca, José Renato, Francis de Almeida, Cíntia Resende, Humberto Ritt, Florisvaldo Cardozo, Marcelo Costa, Cristiano Dorsa, Kleverton Rodrigues, Paulo Limírio, Welington Mrad e Sandro Ferreira.

Aos funcionários da FEELT, em especial, Caio Siqueira, Caio Guimarães e Andressa pelo profissionalismo prestado.

Aos demais amigos das cidades de Uberaba e Uberlândia.

*“Se as coisas são inatingíveis... ora!
Não é motivo para não querê-las...
Que tristes os caminhos, se não fora
a presença distante das estrelas!”*

Mário Quintana – Poema: Das Utopias, 2005

Resumo

Sistema de Gerenciamento de Energia Orientado à Arbitragem Energética e Recomendações para Operação Isolada de Microrredes

A fim de otimizar a operação e o planejamento de microrredes (MR), torna-se necessário proceder a um conjunto de análises de dados técnicos e econométricos. Neste aspecto, enquadram-se métricas de tomadas de decisão orientadas à arbitragem energética, dentre outras. Essa abordagem é importante para o desenvolvimento do sistema elétrico moderno, pois permite a melhor integração da geração distribuída (GD) e o sistemas de armazenamento de energia em baterias (SAEB). O uso de algoritmos baseados em inteligência artificial (IA) para o sistema de gerenciamento de energia (SGE) podem ajudar no aprimoramento da operação de MR para alcançar o menor custo possível no processo da compra e venda de energia elétrica, e por consequência, elevar os níveis de sustentabilidade. Com isso, na primeira etapa desta Tese são propostas duas estratégias para o gerenciamento de energia na MR, com o objetivo de determinar os instantes de carga e descarga do SAEB. É utilizado um método heurístico simples para servir de referência na comparação com a operação da lógica nebulosa (LN) desenvolvida. Além disso, são propostos outros algoritmos baseados em redes neurais artificiais (RNAs) por meio da técnica autorregressiva não linear para prever as variáveis da MR. Durante a pesquisa, os algoritmos desenvolvidos foram avaliados por meio de extensos estudos de caso, com simulações que utilizaram dados do sistema fotovoltaico (FV), demandas de cargas e preços de eletricidade. Para todos os casos, os algoritmos em IA para previsões e atuações conseguiram reduzir o custo e consumo diário de energia elétrica da rede principal, em comparação com o método heurístico ou com a MR sem a utilização do SAEB. Isso indica que as estratégias para gerenciamento de energia elétrica desenvolvidas podem ser aplicadas na redução de custos da operação de MR conectada à rede principal. Na outra etapa desta pesquisa é proposta uma alternativa para manter a MR operando por meio do ilhamento intencional, em caso de falhas que provoquem o corte do fornecimento de energia, com o objetivo de garantir a continuidade do serviço de atendimento das cargas prioritárias por meio de um contrato entre a concessionária local e o gestor de GD-MR, conforme as orientações técnicas IEEE 1547. Os resultados de simulações confirmam que esta proposta atende às diretrizes técnicas do IEEE 1547, garantindo alta qualidade no fornecimento de energia elétrica após o ilhamento intencional das cargas da MR estabilizada.

Palavras-chave: Gerenciamento de energia. Incerteza. Mercados de energia. Microrredes. Interoperabilidade. Ilhamento intencional. Tarifa dinâmica de eletricidade.

Abstract

Energy Management System Oriented to Energy Arbitrage and Recommendations for Isolated Operation of Microgrids

In order to optimize the operation and planning of microgrids (MG), it is necessary to carry out a set of analyzes of technical and econometric data. In this aspect, decision-making metrics oriented to energy arbitrage can fit, among others. This approach is important for the development of the modern electrical system, as it allows better integration of distributed generation (DG) and battery energy storage systems (BESS). The use of algorithms based on artificial intelligence (AI) for the energy management system (EMS) can help to improve the MG operation to achieve the lowest possible cost in the process of buying and selling electricity, and consequently, increase sustainability levels. Thus, in the first stage of the Thesis, two strategies are proposed for energy management in the MG to determine the instants of charge and discharge of the SAEB. A simple heuristic method is used to serve as a reference for comparison with the fuzzy logic (FL) operation developed. Furthermore, other algorithms based on artificial neural networks (ANNs) are proposed using the nonlinear autoregressive technique to predict MG variables. During the research, the developed algorithms were evaluated through extensive case studies, with simulations that used data from the photovoltaic (PV) system, load demands, and electricity prices. For all cases, the AI algorithms for predictions and actions managed to reduce the cost and daily consumption of electricity from the main network, compared with the heuristic method or the MG without using BESS. This indicates that the developed power management strategies can be applied to reduce the costs of grid-connected MG operations. In the other stage of this research, an alternative is proposed to keep the MG operating through intentional islanding, in case of failures that cause the disconnection of the energy supply, aiming to guarantee the continuity of the service of priority loads through a contract between the utility and the manager of GD-MG, according to the IEEE 1547 technical guidelines. The results obtained by the simulations have shown excellent levels in the quality of electric energy supply for the input situation of the stabilized MG loads, after the intentional islanding, thus confirming that this proposal is within the technical guidelines of IEEE 1547. The simulations results confirm that this proposal comply with the technical guidelines of IEEE 1547, guaranteeing high quality in supplying electrical energy after the intentional islanding of the stabilized MG loads.

Keywords: Energy management. Uncertainty. Power markets. Microgrids. Interoperability. Intentional islanding. Dynamic electricity pricing.

Lista de ilustrações

Figura 1 – Sistema elétrico tradicional em comparação ao sistema elétrico decorrente.	30
Figura 2 – Exemplo de uma MR-CA básica composta por geradores, SAEB, conversores eletrônicos de potência e cargas.	38
Figura 3 – Visão geral das arquiteturas de controle centralizado, descentralizado e distribuído.	40
Figura 4 – Estrutura hierárquica de controle para uma MR.	41
Figura 5 – Funções de gerenciamento de energia da MR.	42
Figura 6 – Imagem representativa do modelo adaptado de 14 barras CIGRÈ adotado na plataforma <i>Simulink</i> da MR trifásica CA conectada à rede. . .	46
Figura 7 – Modelo de bateria utilizado.	47
Figura 8 – Bloco com as duas rotinas de programações do SGE proposto.	48
Figura 9 – Ilustração da topologia de acoplamento do sistema de armazenamento de energia da bateria conectado em CA.	48
Figura 10 – Modelo <i>Simulink</i> do sistema FV simplificado.	50
Figura 11 – Modelo <i>Simulink</i> de uma carga variável com controle dinâmico de carga.	51
Figura 12 – Fluxograma do algoritmo heurístico.	54
Figura 13 – Ilustração mostrando a convenção de sinal positivo para fluxos de energia na MR.	54
Figura 14 – Rede autorregressiva não linear.	55
Figura 15 – RNA proposta.	55
Figura 16 – Metodologia de realização do modelo proposto em LN. Adaptado de (SII; RUXTON; WANG, 2001).	58
Figura 17 – O sistema adotado de inferência difuso do tipo <i>Mamdani</i> com quatro módulos de entrada e um de saída.	58
Figura 18 – A arquitetura de funcionamento do controlador LN.	59
Figura 19 – Dados da potência gerada FV. Em (a) a potência FV gerada para o céu claro, e em (b) a potência FV gerada para o céu nublado.	63
Figura 20 – A curva referente as cargas adotadas. De (LESAGE, 2020)	63
Figura 21 – Os preços de tarifação dinâmica adotados nos estudos de caso. De (NORDPOOLAS, 2020).	64
Figura 22 – Os módulos para previsões das variáveis de Demanda (kW), Preços (EUR/kWh) e Potência gerada FV (kW). E a saída dos módulos de previsões, conectadas no controlador de LN.	65
Figura 23 – Resultados do caso de referência heurística para o período de simulação com o dia de céu claro.	66

Figura 24 – Resultados do caso de referência heurística para o período de simulação com o dia de céu nublado.	66
Figura 25 – Resultados do caso com o modelo proposto para o período de simulação com o dia de céu claro.	67
Figura 26 – Resultados do caso com o modelo proposto para o período de simulação com o dia de céu nublado.	68
Figura 27 – Comparação dos métodos utilizados céu claro.	69
Figura 28 – Comparação dos métodos utilizados com o céu nublado.	70
Figura 29 – Modelo de 14 barras utilizado.	74
Figura 30 – Estrutura lógica do bloco TVF do relé.	76
Figura 31 – Estrutura lógica do relé de sub/sobre frequência.	76
Figura 32 – Estrutura lógica do bloco da tensão de bloqueio.	77
Figura 33 – Comparação da função de tensão de bloqueio em queda de tensão típica.	78
Figura 34 – Estrutura lógica do relé proposto.	79
Figura 35 – Modelo típico de uma estrutura de controle mestre-escravo.	80
Figura 36 – Característica <i>Droop</i>	81
Figura 37 – Característica Isócrona.	81
Figura 38 – Malha de controle do regulador de velocidade usada para o GS.	82
Figura 39 – Modelo Clássico para Máquina Síncrona.	83
Figura 40 – Diagramas derivados dos fasores.	83
Figura 41 – Malha de controle da excitação usada para o GS.	85
Figura 42 – Tempo de atuação do relé TVF.	87
Figura 43 – Níveis das tensões nas barras 5 e 8.	88
Figura 44 – Valores da velocidade de rotação do GS para os três modos de controle.	91
Figura 45 – Níveis das potências das MDs.	91
Figura 46 – Alteração do sinal do regulador de velocidade para o modo isócrono do GS.	92
Figura 47 – Alteração do sinal de excitação para o modo regulador de tensão do GS.	92
Figura 48 – Níveis de tensão nas barras 5 e 8 ao inserir a carga no cenário de ilhamento.	93
Figura 49 – Valores da velocidade de rotação do GS para três casos.	94
Figura 50 – Níveis de potência dos MDs.	94
Figura 51 – Valor do regulador de velocidade do GS.	95
Figura 52 – Valor do sinal do regulador de excitação do GS.	95
Figura 53 – Curva utilizada no treinamento da RNA previsões da carga.	131
Figura 54 – Curva utilizada no treinamento da RNA previsões da preços dinâmicos.	132
Figura 55 – Curva utilizada no treinamento da RNA previsões da geração de energia FV para o céu claro.	132
Figura 56 – Curva utilizada no treinamento da RNA previsões da geração de energia FV para o céu nublado.	133

Figura 57 – Previsões da carga por meio da RNA treinada.	133
Figura 58 – Previsões dos custos de energia elétrica, por meio da RNA treinada. . .	134
Figura 59 – Previsões da geração FV em situações do céu claro, pela RNA treinada.	134
Figura 60 – Previsões da geração FV em situações do céu nublado, pela RNA treinada.	135

Lista de tabelas

Tabela 1 – Tabela base de regras do controlador LN.	60
Tabela 2 – Parâmetros do SAEB e do gerador FV.	62
Tabela 3 – Comparação dos custos das simulações céu claro	70
Tabela 4 – Comparação dos custos das simulações com o céu nublado	70
Tabela 5 – Parâmetros Utilizados no relé TVF.	78
Tabela 6 – Limites de Operação dos PRODIST - Módulo 8	79
Tabela 7 – Descrição Utilizadas para Entrada e Saída, das Malhas de Controle do GS	85
Tabela 8 – Nível de Potência dos Barramentos Contendo as Cargas Alimentadas no Ilhamento	89
Tabela 9 – Resultados para os níveis de tensão nos estudos realizados após o ilhamento	90
Tabela 10 – Bloco <i>Simple Solar Inverter</i>	111
Tabela 11 – Bloco <i>Three-Phase Source</i>	111
Tabela 12 – Dados Utilizados nos Transformadores Trifásicos	112
Tabela 13 – Parâmetros Utilizados para a Máquina Síncrona	113
Tabela 14 – Parâmetros Utilizados no Regulador de Fator de Potência	113
Tabela 15 – Parâmetros Utilizados no Regulador de Tensão	114
Tabela 16 – Parâmetros Utilizados no Regulador de Velocidade <i>Droop</i>	114
Tabela 17 – Parâmetros Utilizados no Regulador de Velocidade Isócrono	114
Tabela 18 – Dados Utilizados	115
Tabela 19 – Valores Nominiais de cada Inversor da Fazenda FV - Valores Nominiais - Estudo de caso para o ilhamento intencional	116
Tabela 20 – Parâmetros Utilizados no Controlador MPPT	116
Tabela 21 – Regulador de tensão DC	116
Tabela 22 – Dados importantes do regulador	116

Lista de abreviaturas e siglas

ABNT	Associação Brasileira de Normas Técnicas
CIGRÈ	<i>Conseil International des Grandes Réseaux Électriques</i>
EDC	Estado de Carga
EQM	Erro Quadrático Médio
FER	Fonte de Energia Renovável
FV	Fotovoltaico
GD	Geração Distribuída
GS	Gerador Síncrono
IA	Inteligência Artificial
LN	Lógica Nebulosa
MD	Minigeração Distribuída
MR	Microrrede
NAR	<i>Nonlinear Autoregressive</i>
PAC	Ponto de Acoplamento Comum
PD	Previsão de Demanda
PPEE	Previsão de Preço de Energia Elétrica
PPGFV	Previsão da Potência Gerada FV
PRODIST	Procedimento de Distribuição
RNA	Rede Neural Artificial
ROCOF	<i>Rate of Change of Frequency</i>
SAE	Sistema de Armazenamento de Energia
SAEB	Sistema de Armazenamento de Energia em Baterias
SGE	Sistema de Gerenciamento de Energia
SQR	Soma dos Quadrados Residuais

TIC Tecnologia da Informação e Comunicação

TVF Taxa de Variação de Frequência

Lista de símbolos

Hz	<i>Hertz</i> , unidade de medida de frequência.
V	Volt, unidade de medida de tensão elétrica.
VA	Volt ampere, unidade de medida da potência aparente.
W	<i>Watt</i> , unidade de medida de potência ativa.
H	<i>Henrys</i> , unidade de medida de indutância elétrica.
s	Segundo, unidade de medida de tempo.
Wh	Watt hora, unidade de medida de energia.
m	Mili, é um prefixo multiplicador equivalente a um por um mil.
k	Quilo, é um prefixo multiplicador equivalente a um mil unidades.
M	Mega, é um prefixo multiplicador equivalente a um milhão de unidades.
G	Giga, é um prefixo multiplicador equivalente a um bilhão de unidades.
T	Tera, é um prefixo multiplicador equivalente a um trilhão de unidades.
pu	pu, é uma unidade adimensional que significa que se refere a proporcionalidade.
ω_m	rad/s, velocidade de rotação do Gerador Síncrono.

Sumário

1	INTRODUÇÃO	29
1.1	O contexto histórico e a motivação	29
1.2	A formulação do problema - SGE	31
1.3	Objetivos	33
1.4	Metodologia	33
1.5	As principais premissas	34
1.6	As principais contribuições	35
1.7	A estrutura desta Tese	35
2	ASPECTOS ESSENCIAIS DO SGE DA MR	37
2.1	A MR e o sistema de energia moderno	37
2.1.1	O controle de MR	39
2.2	O SGE de MR	42
2.3	Revisão dos métodos de gestão de energia	43
2.3.1	Método heurístico	43
2.3.2	Método de IA	44
2.4	Resumo	44
3	O MODELO DE MR	45
3.1	Método do sistema de resolução	45
3.2	Descrição do modelo de 14 barras CIGRÈ	45
3.2.1	O Modelo do SAEB	46
3.2.1.1	EDC das baterias	48
3.2.2	O Modelo FV simplificado	49
3.2.3	Os Modelos de carga	50
3.2.4	Ponto de conexão de alimentação principal	51
3.3	Resumo	51
4	DESCRICHÃO DO SGE	53
4.1	O método heurístico desenvolvido	53
4.2	A RNA com o modelo autorregressivo não linear para predições das variáveis	53
4.2.1	Definição dos dados da rede	57
4.3	LN para as tomadas de decisões	57
4.3.1	A arquitetura do modelo	57
4.3.2	A metodologia do controlador de LN proposto	59

4.3.3	Conjunto de regras difusas	59
4.4	Resumo	60
5	COMPARAÇÃO ENTRE O ALGORITMO PROPOSTO E O HEURÍSTICO: ABORDAGENS DE CONTROLE E ESTUDOS DE CASO	61
5.1	Os parâmetros	61
5.2	Os dados	62
5.2.1	Os módulos para previsões das variáveis	64
5.3	Estudos de caso	64
5.3.1	Os casos 1 e 3 de referência método heurístico aplicado para condições de céu claro e nublado	65
5.3.2	Os casos 2 e 4, métodos propostos aplicados para condições de céu claro e nublado	67
5.4	Análise dos resultados dos quatro estudos de casos	67
5.4.1	Discussões dos casos 1 e 3 com o método heurístico	67
5.4.2	Discussões dos casos 2 e 4 com o método proposto	68
5.4.3	Comparação entre os algoritmos heurístico e o proposto	69
5.5	Resumo	71
6	ELEMENTOS UTILIZADOS PARA O ILHAMENTO INTENCIONAL DA MR	73
6.1	Considerações iniciais	73
6.2	As GDs adotadas e o modelo de 14 barras para o ilhamento intencional	73
6.2.1	A modelagem das cargas	74
6.3	Deteccção do ilhamento	75
6.3.1	Técnica de deteccção ativa	75
6.3.2	Técnica de deteccção passiva	75
6.4	Implementação do relé TVF proposto	75
6.4.1	Relé de taxa de variação de frequência (TVF)	76
6.4.2	Relé sub/sobre frequência	76
6.4.3	Tensão de bloqueio	77
6.4.4	Parâmetros pré-ajustados no relé proposto	77
6.5	Modos de controle para a GD	78
6.6	Regulador de velocidade - modo <i>droop</i>	80
6.7	Regulador de velocidade - modo isócrono	81
6.8	Regulador de fator de potência/reactivo	82
6.9	Regulador de tensão	84
6.10	Resumo	85

7	RESULTADOS E DISCUSSÕES PARA O ILHAMENTO INTENCIONAL	87
7.1	Estudo de caso 1: Sem o alimentador principal com o ilhamento intencional	87
7.2	Estudo de caso 2: Operação em modo ilhado da MR	93
7.3	Resumo	96
8	CONCLUSÕES	97
8.1	Orientações e recomendações para o desenvolvimento de aplicações práticas futuras	98
	REFERÊNCIAS	101
	 APÊNDICES	 109
	APÊNDICE A – DADOS E PARÂMETROS DAS SIMULAÇÕES	111
	APÊNDICE B – CÓDIGOS DO BLOCO <i>MATLAB FUNCTION</i>	117
	APÊNDICE C – DADOS UTILIZADOS PARA O TREINAMENTO DA RNA E PREVISÕES OBTIDAS	131
C.0.1	Dados utilizados para o treinamento das RNA de previsões	131
C.0.2	As previsões realizadas	133
	APÊNDICE D – PUBLICAÇÕES	137
D.1	Apresentações em conferências	137
D.2	Publicações em periódicos	137

1 Introdução

Este Capítulo visa apresentar o contexto inicial da pesquisa juntamente com a motivação da tese e utilizá-los para formular as bases do problema geral. Além disso, este Capítulo descreve os objetivos da pesquisa, indicando a metodologia adotada para alcançá-los, apontando o escopo da pesquisa, destacando as contribuições, e por fim, delineando o conteúdo da redação.

1.1 O contexto histórico e a motivação

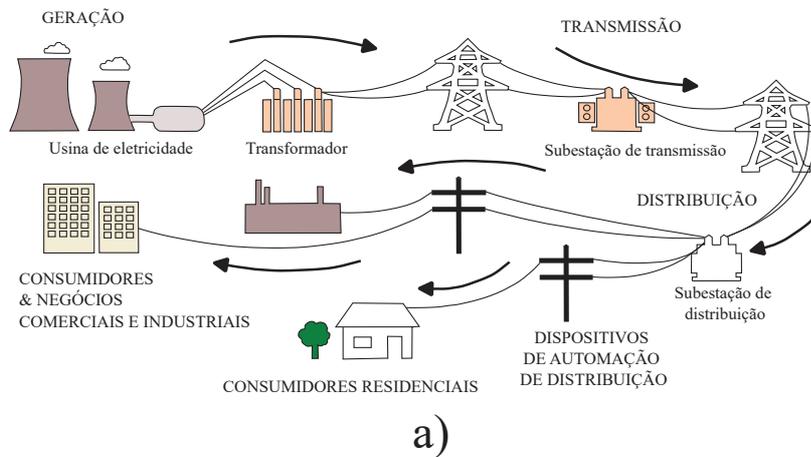
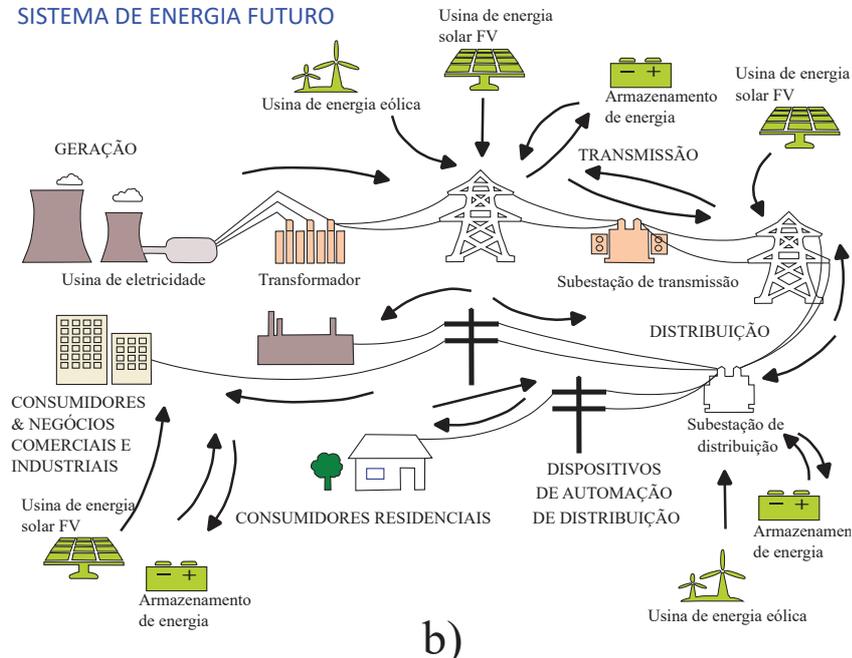
O sistema elétrico de potência tradicional é composto de equipamentos e infraestrutura que geram energia elétrica por meio de estruturas centralizadas e transmissão por longas distâncias para conectar a distribuição e chegar ao consumidor final (MIGLIAVACCA, 2012), como é mostrado na Figura 1(a).

Já o atual sistema elétrico de potência tem evoluído ao longo do tempo, com o uso de tecnologias avançadas para aumentar a eficiência, confiabilidade e segurança no fornecimento de energia elétrica. Entre essas tecnologias pode-se destacar: a automação e digitalização dos sistemas de controle, a utilização de fontes de energia renováveis (FERs), o desenvolvimento de sistema de armazenamento de energia (SAE) e a implementação de soluções inteligentes para o gerenciamento de carga e redução de perdas (HOVDEN, 2021) (KUMAR et al., 2020b), como é exemplificado na Figura 1(b). Isso leva além de menores perdas nas linhas de transmissão, também aos fluxos de potência bidirecionais (MASSIGNAN; PEREIRA; LONDON, 2017). É importante enfatizar que os SAEs têm um papel fundamental no desenvolvimento deste modelo de sistema de energia elétrica.

Neste aspecto a Microrrede (MR) ganhou espaço no cenário, pois combinam diferentes recursos, como painéis solares, turbinas eólicas, geradores a diesel, SAEs e cargas controláveis, que operam em conjunto para fornecer energia elétrica confiável e sustentável aos consumidores locais (CHALAH et al., 2022). Sendo uma alternativa em relação aos sistemas centralizados de geração de energia, que dependem de grandes usinas e linhas de transmissão de alta tensão para fornecer eletricidade a áreas remotas. Com as MRs, é possível fornecer eletricidade de forma mais eficiente e com alto nível de confiabilidade (ALVES et al., 2023). O resultado disso, é o lado da distribuição mais ativo que participa da operação do sistema elétrico. Isso pode ser vantajoso para integrar a FER, otimizar a operação, proporcionar um fornecimento de energia seguro e atender aos desafios relacionados às fontes renováveis não despacháveis, fluxos de energia bidirecionais e consumidores mais ativos (ILYUSHIN et al., 2023).

Existem benefícios para o gerenciamento da energia na MR, e seus desafios garantem

Figura 1 – Sistema elétrico tradicional em comparação ao sistema elétrico decorrente.

SISTEMA DE ENERGIA TRADICIONAL**SISTEMA DE ENERGIA FUTURO**

Fonte: adaptado de (STOKER, 2016).

a estabilidade e confiabilidade no sistema elétrico. O sistema de gerenciamento de energia (SGE) pode incluir tecnologias como sensores de monitoramento, sistemas de controle de energia, *software* de análise de dados e estratégias de gerenciamento de carga. Essas tecnologias permitem que as operadoras da MR monitorem a demanda de energia em tempo real, otimizem o uso da energia disponível, fornecendo a energia confiável, sustentável, econômica e que possam responder a picos da demanda de energia (YAO et al., 2022).

Com base no histórico e motivação mencionados, este trabalho pretende contribuir para a área de pesquisa ao desenvolver, implementar e testar na plataforma computacional *Simulink* integrada ao *Matlab*, um SGE de MR para a gestão da compra e venda da energia elétrica, e outra proposta de identificação e alteração do modo de controle dos geradores para o caso de ilhamento intencional. A Seção 1.2 formulará o problema geral

desta tese, incluindo os componentes da MR que foram estudados e os requisitos colocados nos estudos referente ao SGE. Os componentes utilizados para a proposta de operação no ilhamento intencional são abordadas com mais detalhes no Capítulo 6.

1.2 A formulação do problema - SGE

Motivado pelos desafios da MR relacionados ao controle e melhor gerenciamento, para atingir os objetivos são desenvolvidos algoritmos para Rede Neural Artificial (RNA) por meio da técnica autorregressiva não linear para previsões das variáveis, e por meio da Lógica Nebulosa (LN) para tomar as decisões referente a compra ou venda da energia elétrica para maximizar a eficiência energética e reduzir os custos. A MR das simulações utiliza um sistema de geração FV, cargas fixas/variáveis e um Sistemas de Armazenamento de Energia em Baterias (SAEB). O SGE proposto é capaz de:

- Ponderar a natureza variável e incerta da geração FV, as entradas e saídas imprevisíveis das cargas a nível da distribuição e o preço da eletricidade no cenário dinâmico para uma operação diária;
- Apresentar soluções simultâneas para múltiplos objetivos desejados, com a minimização dos custos operacionais diários, melhoria da utilização de energia FV gerada e melhor emprego da bateria, mantendo-a dentro dos seus limites operacionais;
- Incorporar um modelo de bateria que não inclui o processo de degradação da simulação para evitar o aumento no processamento da simulação. No entanto, é importante ressaltar que o modelo de bateria utilizada na simulação é realista o suficiente para fornecer resultados precisos na gestão da compra e venda de energia elétrica, qualidade dos níveis de tensões e frequência nas barras (ALVES et al., 2023);
- Apresentar as sugestões de algoritmos de previsões, com o treinamento da RNA sendo realizado por meio dos dados da programação do dia seguinte, e simulações de controle e operação para a compra/venda de energia elétrica na MR em cenário de tarifação dinâmica. Com esses algoritmos, é possível alcançar um equilíbrio adequado entre a precisão no controle para fornecer índices de qualidade de energia elétrica e baixo esforço computacional, para o desenvolvimento de um SGE eficiente e sustentável.
- Aplicar método de natureza de curto prazo no horizonte de previsão, para as tomadas de decisões da compra ou venda de energia elétrica elétrica.

Os métodos baseados em RNAs, podem ser utilizados para as previsões dos custos de preços da eletricidade no varejo, baseando nos dados históricos para alcançar um melhor

desempenho geral da operação da MR quando comparados aos métodos heurísticos. A pesquisa (BORALESSA et al., 2022) investiga o efeito dos erros de previsões de FER no gerenciamento de energia de MR baseado em modelo de controle preditivo. Isto posto, nesta Tese são incluídos vários recursos adequados para atender aos requisitos de previsão. Algumas dessas características são apresentadas abaixo (outras pesquisas semelhantes são tratadas em (BORDONS; GARCIA-TORRES; RIDAO, 2020) e (CABRERA-TOBAR et al., 2022)):

- É desenvolvido em RNA com técnica autoregressiva não linear formuladas e treinadas para as previsões das variáveis de:
 - Demanda das cargas;
 - Potência gerada FV;
 - Preço da energia elétrica.
- Já no controlador é usado o algoritmo de LN para tomar as decisões referente a compra ou venda da energia elétrica. Desta forma, os algoritmos de resoluções propostos podem ser sintonizados e implementados para lidar eficazmente com as restrições associadas as particularidades das MR;
- O funcionamento é dinâmico, ou seja, estes algoritmos são adequados para tomar as decisões de controle de SGE em tempo real.

Com base na extensa revisão dos métodos de gerenciamento de energia realizada no Capítulo 2 desta tese, os algoritmos utilizados são selecionados para obter um elevado nível de precisão. Algumas lacunas observadas referente ao estado da arte da pesquisa são:

- A capacidade da bateria é assumida como constante neste modelo. Isso porque a capacidade nominal da bateria é determinada por sua construção física e química e não muda significativamente durante o intervalo de curto prazo;
- A pesquisa não teve como objetivo a limitação de degradação da bateria, mas sim, a compra ou venda da energia elétrica. A construção, desenvolvimento, sintonização e simulação do SGE proposto utiliza o modelo de bateria adaptado de (LESAGE, 2020);
- As simulações são realizadas por períodos diários, portanto não consideram os efeitos das degradações das baterias como em outras pesquisas (ANSEÁN et al., 2019) e (ZHANG et al., 2022);
- Os tempos de simulações variam de 4 a 8 horas, sendo considerados convenientes para a utilização. Pois intervalos mais curtos que o intervalo de 24 horas são preferíveis,

porque permitem garantir que o SGE observe e responda as pequenas mudanças na carga, geração ou no preço da eletricidade para uma aplicação prática com o intervalo diário;

- Para não elevar o nível de processamento a variável eficiência dos conversores é desconsiderada por conta da sua alta não linearidade.

1.3 Objetivos

Com base na formulação do problema acima, o objetivo geral desta tese é desenvolver uma proposta de SGE para MR que combine a predição das variáveis por meio da RNA com aplicação da técnica autorregressiva não linear, e por intermédio de uma LN tomar as decisões, e assim contabilizar efetivamente as incertezas referente ao contexto da compra e venda de energia elétrica e capturar algumas das dinâmicas estocásticas. São quatro objetivos secundários, derivados do objetivo principal:

- Realizar uma revisão da literatura para investigar o estado da arte do SGE para selecionar um método aplicável para controlar a MR;
- Modelar um sistema de distribuição padrão para MRs com o modelo adaptado do *Conseil International des Grandes Réseaux Électriques* (CIGRÈ) para média tensão de 14 barras no *MATLAB/Simulink* adequado para implementação e teste do SGE proposto. A plataforma de simulação deve confrontar o método proposto com um modelo heurístico convencional, para comparar a economia financeira e o nível de sustentabilidade em relação a energia consumida do alimentador principal;
- Propor e implementar duas estratégias de gerenciamento de energia, ou seja, lógicas de predições utilizando técnica autorregressiva não linear e outra LN para tomar as decisões na compra ou venda da energia elétrica. E por fim, uma segunda estratégia de gestão heurística para fins de comparação com os algoritmos propostos;
- Investigar o desempenho das propostas por meio de extensos estudos de caso durante o período de simulação diário, usando dados FV, curva de carga divulgada pela (ALVES et al., 2021) e os dados referentes a programação de preços da energia do próximo dia e dados faturados de energia elétrica da Nordpool, na França, dia 10 de novembro de 2022 (NORDPOOLAS, 2020).

1.4 Metodologia

O passo a passo adotado na metodologia para alcançar os objetivos almejados desta tese foram:

1. Realizar uma revisão detalhada da literatura sobre o SGE de MRs para obter uma base teórica sólida e compreender as principais lacunas e desafios (GIRALDO et al., 2019), (JAFARI et al., 2020), (ARCOS-AVILES et al., 2021) e (MA; LI; ZHANG, 2022);
2. Desenvolver o algoritmo para predição de variáveis da MR aplicando RNA por meio da técnica autorregressiva não linear com base na revisão da literatura (ALIBERTI et al., 2019) e (AHMED; KHALID, 2017);
3. Projetar e implementar uma abordagem utilizando IA com o objetivo de formular e resolver alguns problemas com intervalo de 24 horas de gerenciamento de energia desenvolvido na plataforma *MATLAB/Simulink*;
4. Projetar e implementar um método de controle heurístico para servir como referência de comparação do desempenho do algoritmo proposto;
5. Realizar estudos de caso de simulações com intervalo de 24 horas para cenários de dia claro e nublado;
6. Analisar os resultados dos estudos de caso.

1.5 As principais premissas

Para atingir os objetivos da tese, a pesquisa é limitada pelas seguintes premissas:

- O SGE utiliza IA para operar a MR com o intuito de realizar a diminuição no custo de operação, com o controle de frequência, qualidade de energia e estabilidade de tensão, dentro dos parâmetros adequados definidos pelo PRODIST módulo 8 (MODULO8, 2016) em regime permanente. Já a avaliação do comportamento dinâmico é realizada no Capítulo 6, referente ao ilhamento intencional;
- O modelo da MR foi desenvolvido para ser simulado nos modos conectado à rede e ilhado, conforme o objetivo dos estudos tratados na tese;
- O modelo de bateria utilizado nesta etapa para a gestão da energia, não inclui a sua degradação. Está fora do escopo da pesquisa construir novos modelos de baterias;
- O modelo desenvolvido que é adaptado do CIGRÈ para média tensão de 14 barras no *MATLAB/Simulink* foi usado com sucesso em duas publicações da pesquisa (ALVES et al., 2023) e (ALVES et al., 2021);
- O desenvolvimento de um algoritmo de predição para prever a geração de potência ativa FV, as demandas de cargas e os preços da eletricidade na tarifação dinâmica é realizado por meio da RNA com a técnica autorregressiva não linear;

- Uma análise de custo mais abrangente, incluindo o investimento nas baterias e valor total bruto com os impostos, estão fora do escopo da pesquisa. Os custos de energia elétrica são calculados, comparados e discutidos levando em consideração, para fins de comparação a relação de 1:1 dos preços de compra e venda.

1.6 As principais contribuições

As principais contribuições desta tese de doutorado são:

- As orientações e sugestões de estratégias para gestão energética;
- O desenvolvimento de uma modelagem para simulação de MR construída para ser adequada na execução e avaliação de estratégias da gestão de energia. Essa plataforma emprega um método fasorial de passo variável para simular uma MR conectada à rede elétrica, que é composta por um sistema FV, cargas variáveis e um modelo de bateria sem incluir a sua degradação.
- O projeto contempla uma estratégia de SGE que utiliza a IA, para tarifação dinâmica da MR conectada que considera efetivamente as incertezas nas previsões: de carga, geração FV e preços de eletricidade, para obter o um menor custo diário;
- A apresentação dos resultados das simulações mostram a eficácia das previsões com os algoritmos de RNA com técnica autorregressiva não linear, e a LN para as tomadas de decisões na compra ou venda da energia elétrica, onde usou-se com sucesso os dados com o tempo de simulação consideravelmente apropriado, em relação ao intervalo de simulação de 24 horas.

1.7 A estrutura desta Tese

A tese de doutorado está organizada em diferentes capítulos, e o objetivo principal de cada Capítulo é descrito abaixo:

- O Capítulo 2 apresenta informações sobre o controle e gerenciamento de MR e realiza uma extensa revisão das metodologias de gerenciamento de energia existentes;
- O Capítulo 3 apresenta o desenvolvimento da modelagem para simulação de MR em *MATLAB/Simulink* e os modelos de:
 - Gerador FV;
 - Cargas fixas/variáveis;
 - O SAEB.

- O Capítulo 4 propõe duas estratégias de gerenciamento de energia para o SGE conectado na MR:
 - Uma desenvolvida com programação heurística;
 - A outra composta por dois tipos de algoritmos:
 - * Um para previsões da demanda, geração FV e preços da energia elétrica;
 - * E outra para as tomadas de decisões do despacho descentralizado em MR conectada à rede, sendo utilizado algoritmos de IA;
- O Capítulo 5 investiga o desempenho do SGE proposto por meio de extensos estudos de caso na plataforma desenvolvida do *MATLAB/Simulink* e na Seção 5.4 apresenta a análise de resultados dos estudos de caso deste Capítulo;
- O Capítulo 6 é dedicado para apresentar os fundamentos importantes referente a identificação e alterações nos modos de controle das GDs na MR para o atendimento das cargas no ilhamento intencional;
- O Capítulo 7 apresenta os resultados e discussões referentes ao Capítulo 6 através de estudos de caso para o cenário de atendimento das cargas prioritárias em um eventual ilhamento intencional;
- O Capítulo 8 apresenta as principais conclusões e sugestões para aplicação prática em pesquisas futuras.

2 Aspectos essenciais do SGE da MR

Este Capítulo fornece primeiramente uma definição de MR e concede uma visão geral das abordagens de controle típicas para a operação de MR. Em seguida, é apresentado o SGE para ser definido seu papel na estrutura de controle da MR. Finalmente, uma revisão das estratégias de gerenciamento de energia é conduzida para definir um método apropriado para controlar a MR considerada nesta tese.

2.1 A MR e o sistema de energia moderno

Várias etapas devem ser tomadas antes que a estrutura de rede tradicional possa ser transformada em uma rede moderna, mais inteligente, sustentável e eficiente. Essas etapas incluem a implantação da unidade GD, com ênfase em FER. Além disso, os problemas associados à alta penetração de GDs com gerações FV podem ser mitigados pela conexão do SAE, consumidores mais ativos, maior uso da Tecnologia da Informação e Comunicação (TIC) e desenvolvimento de novos sistemas de controle. Uma MR composta pelos componentes mencionados pode atuar de maneira mais eficiente, confiável e sustentável no sistema de energia.

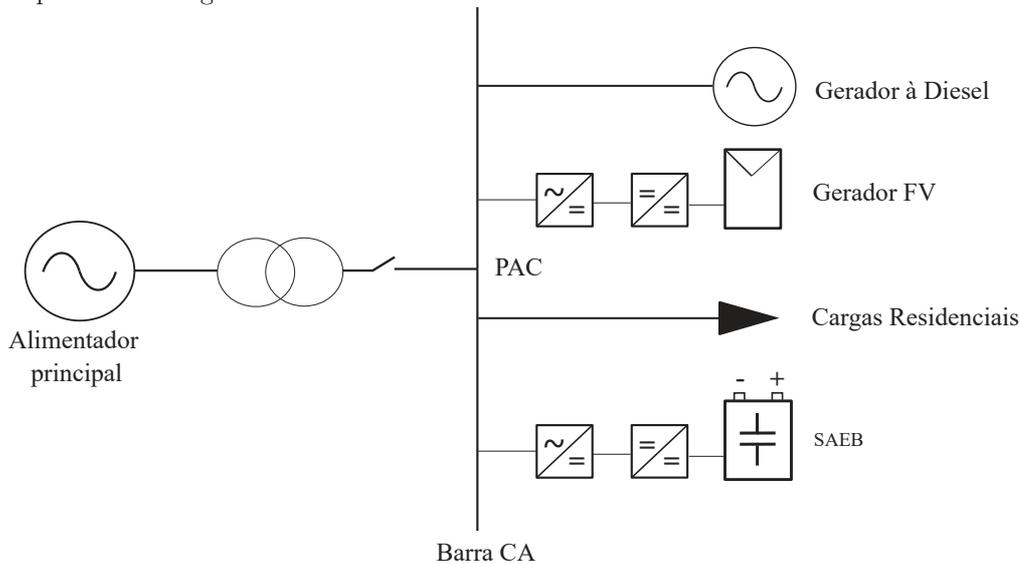
A literatura fornece várias definições do que é uma MR e, embora as diferentes definições variem, todas incluem as mesmas características principais. Para o propósito desta tese, é usada a definição de MR estabelecida pelo CIGRÈ:

"As MRs são sistemas de distribuição de eletricidade contendo cargas e recursos energéticos distribuídos (como geradores distribuídos, dispositivos de armazenamento ou cargas controláveis) que podem ser operados de forma controlada e coordenada, conectados à rede elétrica principal ou em operação ilhada (MARNAY et al., 2015)".

A MR é um pequeno sistema elétrico que pode funcionar conectado à rede principal ou de forma autônoma em modo isolado. Ele se conecta à rede principal através do ponto de acoplamento comum (PAC) e engloba sistemas de controle local, GD, SAEs distribuídos e cargas controláveis/não controláveis. Além disso, uma MR tem limites elétricos e se comporta como uma única entidade controlada em relação à rede principal. A Figura 2 mostra um exemplo de uma MR.

Existem várias vantagens em configurar um sistema de energia de MR. Essa configuração é essencial na mudança para uma rede mais inteligente e vai funcionar como uma solução benéfica para projetos pilotos, permitindo o teste de tecnologias modernas de rede inteligente (HIRSCH; PARAG; GUERRERO, 2018). As MRs também facilitam a implementação de GDs ao utilizar a FER, como turbinas eólicas, sistema FV e a energia hidrelétrica de pequena escala (PARHIZI et al., 2015), (OLIVARES et al., 2014). Além

Figura 2 – Exemplo de uma MR-CA básica composta por geradores, SAEB, conversores eletrônicos de potência e cargas.



Fonte: Adaptado de Buchmann (2018).

disso, a capacidade de alternar para o modo de operação ilhado quando ocorrem falhas e contingências na rede principal, melhora a sua confiabilidade. Com estrutura de controle autônoma, geração própria e armazenamento local de energia, a MR alivia a dependência e, conseqüentemente, o estresse de fluxo de carga na rede existente. Além disso, a gerência, coordenação de maneira correta, a geração e o armazenamento local de energia reduzem as perdas e os custos nas linhas de distribuição. No entanto, para utilizar todo o potencial das MRs, vários desafios devem ser enfrentados. Os desafios técnicos principais encontrados na literatura atual consistem em:

- Fluxo de potência bidirecional - A geração de energia elétrica em MRs apresenta uma particularidade em relação às redes convencionais, o fluxo de potência é bidirecional e ocorre no nível de distribuição, ou seja, mais próximo do consumidor final. Essa característica pode gerar complicações nos sistemas de proteção (PARHIZI et al., 2015)(HIRSCH; PARAG; GUERRERO, 2018);
- Baixa inércia - Quando as MRs são construídas com fontes renováveis não despacháveis, a ausência do Gerador Síncrono (GS) e o elevado número de conversores eletrônicos de potência resultam em uma baixa constante de inércia. Isso significa que as MRs, nestas condições, não apresentam um grau de estabilidade inerente e podem sofrer grandes desvios de tensão e frequência quando operados em modo ilhado. Nesses casos, é necessário implementar o SAEB com um controle adequado ou retornar o uso do GS para evitar essas complicações (PARHIZI et al., 2015) e (ALVES et al., 2023);
- Incerteza - As MRs enfrentam uma incerteza considerável em relação à demanda e

geração de energia, já que o uso de FER vincula a produção de energia elétrica às condições ambientais. Para garantir uma operação econômica e confiável, o sistema de controle deve incluir previsões precisas para a geração, demanda e preços de energia elétrica (PARISIO; RIKOS; GLIELMO, 2014);

- Coordenação entre entidades - A coordenação das unidades em MRs pode ser um desafio adicional, especialmente quando se considera fatores como o balanço de energia, taxas de falhas de componentes, previsão do clima/tempo, perfis de carga e gerações variáveis e incertas. Para garantir o funcionamento adequado da MR, é necessário confirmar a compatibilidade de comunicação entre todos os componentes. (BORDONS; GARCIA-TORRES; RIDAO, 2020) (OLIVARES et al., 2014);
- Estabilidade - Os desequilíbrios entre geração e demanda em MRs dão origem a oscilações locais, bem como problemas de estabilidade de tensão e frequência durante a transição entre os modos de operação conectados à rede e ilhado (HIRSCH; PARAG; GUERRERO, 2018). Para lidar com eficácia com esses desafios, é essencial que os sistemas de controle sejam ajustados de forma rigorosa, garantindo uma operação confiável da MR (ALVES et al., 2021) (ALVES et al., 2021). A Subseção 2.1.1 fornece uma visão geral do sistema de controle da MR e seleciona uma área de controle para investigação adicional. No Capítulo 6 são apresentados os fundamentos dos controladores das GDs na MR para o atendimento das cargas para o ilhamento intencional.

2.1.1 O controle de MR

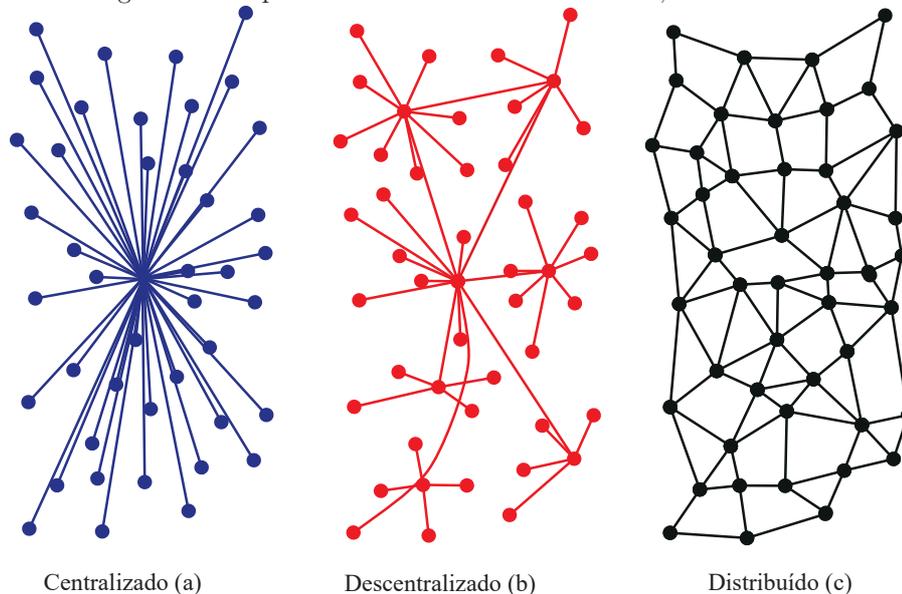
Os controles são cruciais na operação da MR. Nessa conjuntura, pode-se destacar que:

- O sistema de controle de MR deve ser capaz de lidar com as características acima mencionadas, garantindo simultaneamente uma operação confiável e econômica;
- As características desejáveis do sistema de controle incluem a regulação da frequência e tensão para ambos os modos operacionais (conectado na rede principal ou ilhada);
- A arquitetura adotada seja capaz de realizar a transição entre os modos operacionais;
- A métrica de controle adotada deve se orientar a mitigar os custos operacionais da MR, prezando pelo compartilhamento de energia entre as unidades.

A operação da MR pode ser gerenciada por meio de diversas arquiteturas de controle, conforme ilustrado na Figura 3. Um sistema de controle é centralizado se houver um controlador central que envia sinais para cada agente controlável com base

nos dados dos componentes da MR e da rede externa, como mostra a Figura 3 (a). Já na Figura 3 (b), o controle é descentralizado, ou seja, o controle local de cada unidade da MR é realizado sem a troca de informações com outras unidades, com a exceção de alguns agentes líderes que transmitem e recebem informações através de um centro. Quando os controladores locais utilizam uma rede de comunicação para trocar informações e encontrar uma solução cooperativa para o problema geral de controle, o sistema é considerado distribuído como mostra a Figura 3 (c). Finalmente, um compromisso entre uma arquitetura de controle totalmente centralizada e totalmente descentralizada pode ser obtido através da implementação de um esquema de controle hierárquico, onde métodos centralizados e descentralizados podem ser utilizados dentro de cada nível de hierarquia (ZHANG; GATSIS; GIANNAKIS, 2013), (MARNAY et al., 2015), (HIRSCH; PARAG; GUERRERO, 2018), (OLIVARES et al., 2014) e (PARISIO; RIKOS; GLIELMO, 2014).

Figura 3 – Visão geral das arquiteturas de controle centralizado, descentralizado e distribuído.



Fonte: Adaptado de Hirsch, Parag e Guerrero (2018).

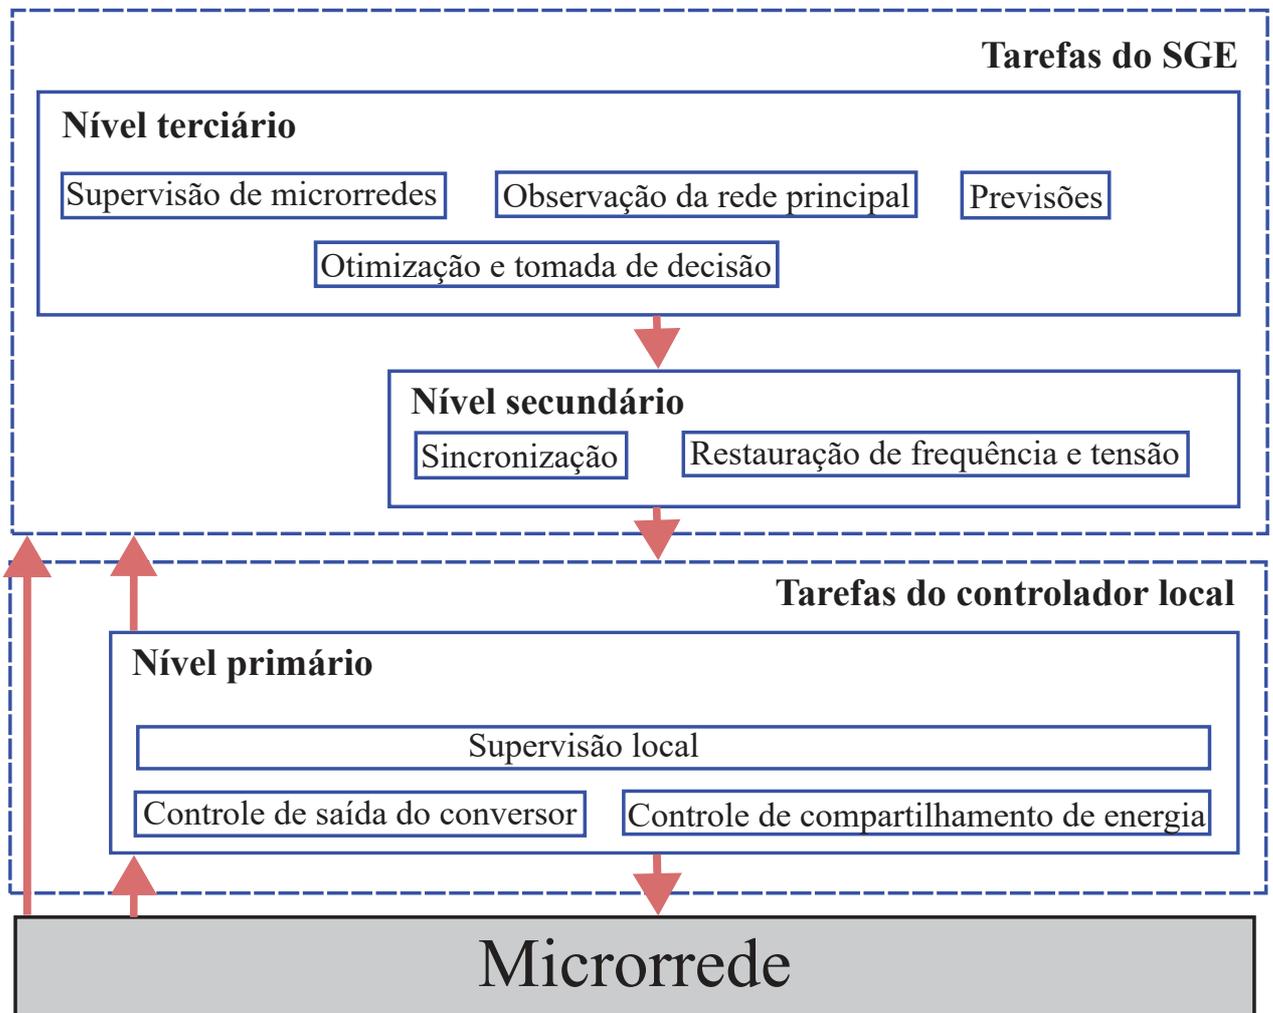
A estratégia de controle hierárquico tem sido amplamente aceita como a abordagem de controle padronizada para MRs (AHMED; KHALID, 2017), (PARISIO; RIKOS; GLIELMO, 2014), (MENG et al., 2016), (BIDRAM; DAVOUDI, 2012), devido às diferentes escalas de tempo presentes na MR. Embora essa hierarquia seja comumente usada, a definição das camadas dada pela literatura se difere bastante. Para esta tese, é utilizada a representação da Figura 4, esta imagem mostra que a estratégia de controle hierárquica consiste nas três camadas a seguir com seus tempos de resposta designados e funções no controle da MR:

1. O controle primário funciona de forma descentralizada e consiste em controladores locais implementados nas interfaces dos conversores de energia dos componentes da MR. Essa camada de controle executa funções que exigem um tempo de resposta

rápido, como controle de saída do conversor, compartilhamento de energia e detecção de ilhamento.

2. O controle secundário opera a uma velocidade mais lenta do que a camada de controle primário e visa corrigir os desvios de estado estacionário ajustando a tensão e frequência conforme os pontos de referência do controle primário. Além disso, esta camada é responsável pela sincronização e troca de energia com a rede externa.
3. O controle terciário é mais alto nível e se dedica a inspecionar o comportamento da MR ao longo prazo. Essa camada introduz inteligência ao sistema, para melhorar a operação da MR.

Figura 4 – Estrutura hierárquica de controle para uma MR.



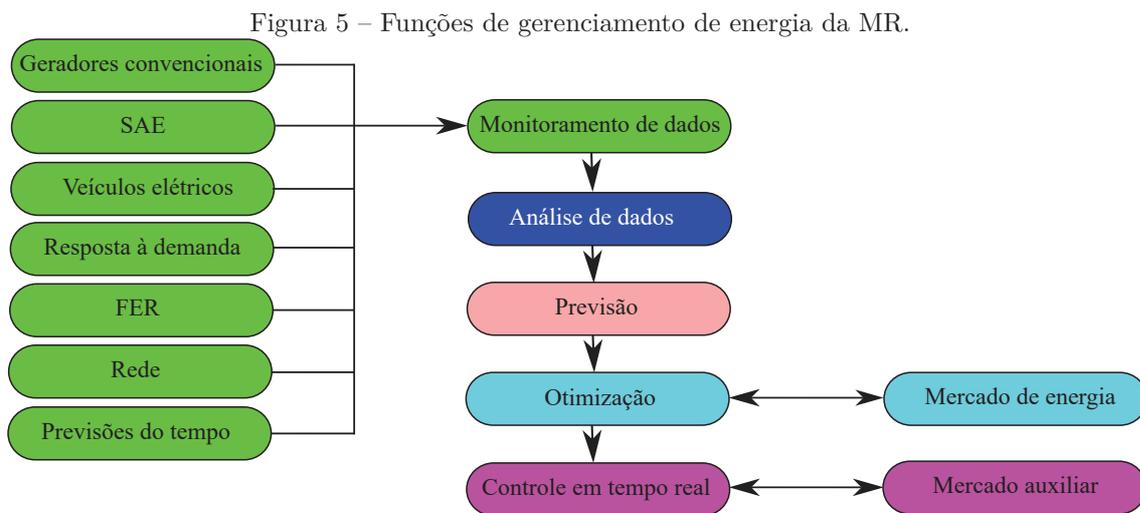
Fonte: Adaptado de Meng et al. (2016).

Com base na descrição dada referente ao controle de MR, o foco dessa investigação é o SGE. Este sistema para MR tem sido objeto de extensos estudos nos últimos anos entre os pesquisadores, e a sua definição e funções dentro da estrutura hierárquica de controle

variam ligeiramente de pesquisa para pesquisa. Na estrutura de controle apresentada na Figura 4, ambos os níveis de controle secundário e terciário são implementados no SGE, de acordo com os trabalhos realizados em (MENG et al., 2016), (BIDRAM; DAVOUDI, 2012), (GUERRERO et al., 2011), (ULLAH et al., 2023). Outros trabalhos, como (OLIVARES et al., 2014), colocam as funções de gerenciamento de energia no nível de controle secundário e definem o controle terciário apenas para o modo de operação conectado à rede.

2.2 O SGE de MR

Um dos requisitos fundamentais para que uma MR opere de forma ideal é a correta utilização do SGE. O SGE é um sistema que utiliza as TICs para garantir uma coordenação otimizada entre as unidades da MR, com o objetivo de fornecer energia elétrica confiável, sustentável, de alta qualidade e de maneira econômica (MENG et al., 2016). Para alcançar essa meta, o SGE executa diversas funções, tais como coleta e monitoramento de dados, análise de dados, previsão e controle em tempo real, como exemplificado na Figura 5.



Fonte: Adaptado de Zia, Elbouchikhi e Benbouzid (2018).

As funções de gerenciamento de energia desempenham um papel fundamental na otimização da operação das MRs. O SGE utiliza dados históricos e previstos para monitorar e analisar a operação das unidades da MR, com o objetivo de melhorar o desempenho e lidar com as restrições do sistema. Esses dados são usados para ajustar os modelos de previsão e otimização, aprimorando o planejamento e a execução da compra e venda de energia elétrica. Além disso, a análise dessas informações pode ajudar a maximizar a eficiência energética da MR e desenvolver novas metodologias de controle e algoritmos de previsões mais precisos para estimar (THIRUNAVUKKARASU et al., 2022):

- Demanda;

- Geração FV;
- Preços de eletricidade.

Além disso, é importante monitorar conjuntos de informações coletadas a partir da análise de dados recentes e previstos para melhorar a operação da MR (HOVDEN, 2021). Esses dados são usados nas estratégias avançadas de tomadas de decisões e alcançar uma operação mais eficiente. Por fim, a saída aperfeiçoada é empregada para realizar o controle em tempo real da MR.

2.3 Revisão dos métodos de gestão de energia

Os métodos usados no SGE de MRs variam de algoritmos simples baseados em regras a técnicas complexas de otimização. Na revisão a seguir, dois grupos de métodos são considerados, os heurísticos e os baseados em IA. Para o último, vale destacar a utilização do conjunto de abordagens de algoritmos preditivos por meio da RNA com aplicação da técnica autorregressiva não linear, e LN para tomadas de decisões em relação a compra ou venda de energia elétrica com o menor custo de mercado. O objetivo da revisão é apresentar o método definido para ordenar a atuação do SAEB na MR considerada, ou seja, uma MR conectada à rede composta por um sistema FV, cargas para representar o consumo e um SAEB.

2.3.1 Método heurístico

Os algoritmos heurísticos são uma categoria de métodos usados no gerenciamento de energia em MR. Eles são conhecidos por serem fáceis de implementar, e computacionalmente eficientes, tornando-os uma opção popular para MR de menor escala (HU et al., 2021).

O método heurístico conhecido como comparador com histerese é um dos mais utilizados em sistemas de gerenciamento de energia em MR (HU et al., 2021). Esse método, descrito em pesquisas como (KUMAR et al., 2020a) (BEHERA; SAIKIA, 2023), utiliza uma banda de histerese para controlar a operação dos SAEBs, com limites definidos de acordo com o estado de carga (EDC). O CCH é especialmente eficiente quando apenas um SAEB é utilizado para tratar equilíbrios entre geração e demanda de energia na MR, desde que o EDC esteja dentro da faixa de limites. Quando o EDC atinge um dos limites, o SAEB é desconectado e outras unidades ou a rede externa devem ser utilizados em seu local. Esse método é rápido, simples e adequado para controle em tempo real.

Os métodos heurísticos são frequentemente usados como referência para avaliar o desempenho de um novo algoritmo desenvolvido. É apresentado em (SEYDENSCHWANZ et al., 2020) um exemplo de um algoritmo baseado em regras para controlar MR híbridas, onde os resultados podem ser facilmente compreendidos pelos usuários. Além disso, em

(PARISIO; RIKOS; GLIELMO, 2014), um algoritmo heurístico é usado como uma das quatro estratégias de gerenciamento de energia para controlar uma MR, com o objetivo de minimizar o consumo de energia da MR. Embora o algoritmo heurístico tenha resultado em economias de custo, ele foi superado por outras estratégias em termos de desempenho geral.

Para concluir, as principais características dos métodos heurísticos são (HU et al., 2021)(BORDONS; GARCIA-TORRES; RIDAO, 2020):

- Simplicidade;
- Velocidade computacional.

Não obstante, a solução fornecida por esses métodos não é ótima. Além disso, os métodos heurísticos consideram apenas o tempo atual e não são de natureza para longo prazo. Outra questão importante, é que a inclusão de muitos detalhes e recursos adicionais para serem executados no algoritmo, torna o problema muito complicado para ser resolvido usando métodos heurísticos tradicionais. Para superar esses problemas, métodos baseados em IA podem ser utilizados, conforme é abordado na próxima Subseção 2.3.2 .

2.3.2 Método de IA

Existe na literatura diversas investigações sobre séries temporais. É sugerido por (NAGY et al., 2016), uma abordagem generalizada para prever a geração de energia solar e eólica. Na mesma perspectiva o (GIORGI; CONGEDO; MALVONI, 2014), utiliza uma RNA recorrente para prever a potência FV gerada nas próximas 24 horas, ao usar também a potência histórica FV e a previsão da temperatura. Já o trabalho apresentado em (HUANG et al., 2015) propõe um modelo híbrido de previsão de energia FV, para um dia de antecedência.

Sendo assim, o segundo método desta pesquisa são algoritmos baseados em IA para predições das seguintes variáveis da MR: demanda de cargas (kW), potência gerada FV (kW) e o valor do preço da energia elétrica da rede (EUR/kWh), e outro algoritmo para realizar as tomadas de decisões pertinentes a compra e venda da energia elétrica com o propósito de diminuir o custo total do consumo de energia elétrica e aumentar o nível de sustentabilidade da MR, com uma menor quantidade de potência consumida.

2.4 Resumo

Este Capítulo forneceu uma definição básica de MR e do SGE para a essência na realização de operação do sistema de energia inteligente, com alto nível de eficiência, sustentabilidade e inovação. No entanto, embora a introdução de MRs resulte em múltiplos

benefícios, existem vários outros desafios a serem enfrentados antes que todo o seu potencial possa ser explorado. Sendo motivado pelos desafios da MR relacionados ao gerenciamento em elevados níveis, os SGEs foram definidos como o foco desta tese. Além disso, este Capítulo realizou uma extensa revisão dos métodos de gerenciamento de energia para apresentar o método definido a resolver o problema de gerenciamento de energia. Nesta revisão, foram considerados dois grupos principais de métodos: Heurísticos e outra proposta baseada na técnica autorregressiva não linear para predição e LN para o despacho descentralizado em MRs conectadas à rede principal.

3 O modelo de MR

Neste capítulo é apresentada a plataforma de simulação para MR desenvolvida no *software MATLAB/Simulink*, que é apropriada para a implementação e teste de um SGE. Também são fornecidos os recursos usados para construir o modelo. Na Seção 3.1, é explicado o objetivo da plataforma de simulação e selecionado um método adequado de resolução do sistema. Na Seção 3.2, é descrito o modelo e seus componentes, incluindo os modelos: de carga, o FV, de baterias e o CIGRÉ de 14 barras adaptado.

3.1 Método do sistema de resolução

Para desenvolver o modelo de MR, é utilizado o ambiente *MATLAB/Simulink*, que oferece bibliotecas com componentes elétricos para construção e execução de simulações de sistemas elétricos e de controle. Antes de construir o modelo, é necessário escolher um método adequado de resolução. O bloco *powergui* do *Simulink* oferece três abordagens diferentes de sistema de resolução, que podem ser escolhidas de acordo com as necessidades do modelo (MATHWORKS, 2006b) (MATHWORKS, 2006a). A escolha do método adequado é importante para garantir a precisão e eficiência do modelo de MR. Isto posto, apresentam-se abaixo os métodos de simulação disponíveis:

- Contínuo, que usa um *solver* de passo variável do *Simulink*.
- Discretização do sistema elétrico para uma solução em passos de tempo fixos.
- Solução de fasores contínuos ou discretos.

Um dos objetivos desta tese é desenvolver uma plataforma de simulação de MR para possibilitar a implementação e teste de um SGE no nível superior de controle da operação da MR. Como o nível superior de controle se preocupa principalmente com o comportamento a longo prazo do sistema, não há necessidade de avaliar os efeitos transitórios. Além disso, como a frequência de trabalho dos dispositivos de corrente alternada na MR é de 60 Hz, a solução fasorial é uma abordagem adequada para o sistema de resolução do modelo de MR desenvolvido nesta tese. A velocidade de simulação também é considerada importante para obter resultados precisos.

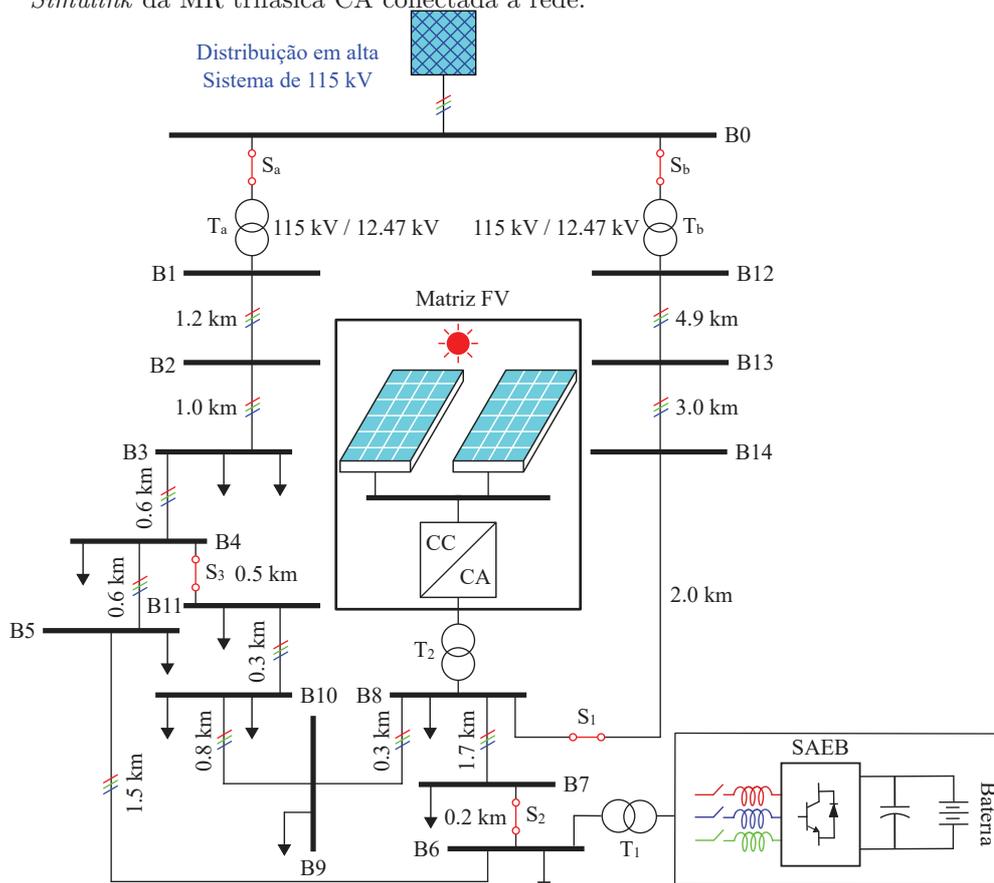
3.2 Descrição do modelo de 14 barras CIGRÉ

Nesta seção, é apresentado o modelo de simulação de uma MR juntamente com seus componentes. O modelo utilizado é o adaptado de 14 barras CIGRÉ, descrito por

(FARHANGI; JOÓS, 2019) (ALVES et al., 2023), e pode ser visualizado na Figura 6. A MR é trifásica e conectada à rede, o que significa que a rede principal tem um papel importante na manutenção dos níveis de tensão e regulação da frequência, conforme o módulo 8 do PRODIST (MODULO8, 2016). O modelo contém os elementos-chave de uma MR, é coerente com uma aplicação real e adequada para testar um SGE.

A MR em questão é composta por um sistema FV, cargas estáticas, cargas variáveis e um SAEB. O painel fotovoltaico, e o SAEB são modelados usando a biblioteca MR desenvolvida pelo *MathWorks* (LESAGE, 2020). Os blocos desta biblioteca de MRs são construídos usando componentes do *Simscape Electrical*, que é uma biblioteca *MATLAB/Simulink* desenvolvida para fornecer componentes para modelagem e simulação de sistemas eletrônicos, mecatrônicos e elétricos de energia (MATHWORKSSIMSCAPE, 2020). Mais detalhes sobre os componentes da MR são fornecidos nas subseções a seguir.

Figura 6 – Imagem representativa do modelo adaptado de 14 barras CIGRÈ adotado na plataforma *Simulink* da MR trifásica CA conectada à rede.



Fonte: Adaptado de (FARHANGI; JOÓS, 2019).

3.2.1 O Modelo do SAEB

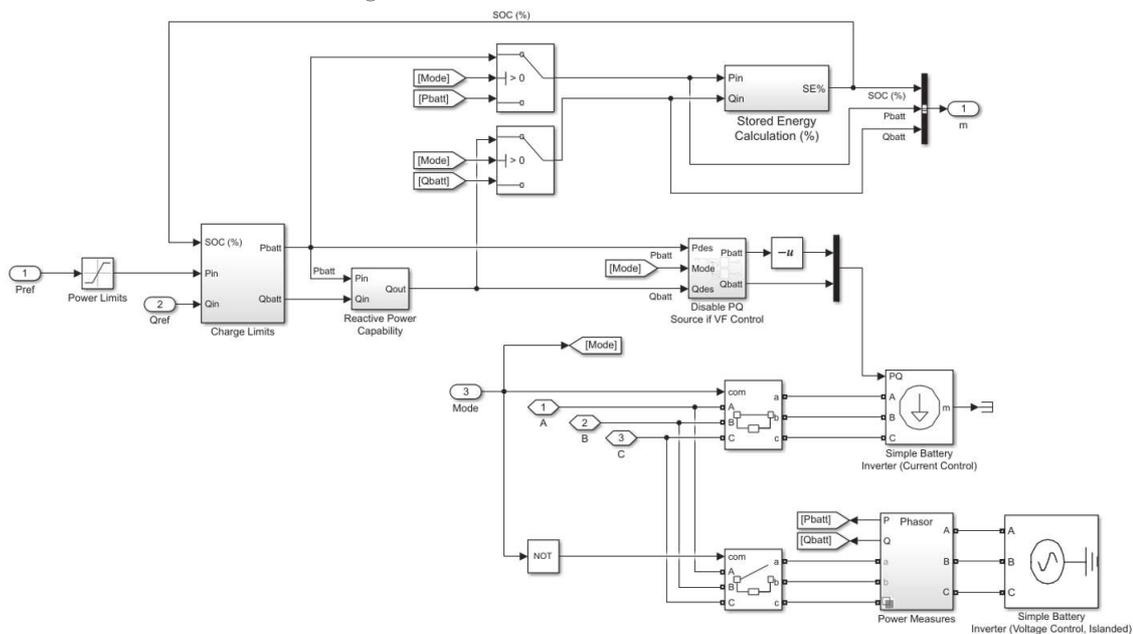
A utilização do SAEB é crucial para reduzir os custos da MR, no entanto, o seu uso excessivo pode encurtar significativamente a sua vida útil. O modelo SAEB adotado

na biblioteca de MR mencionada anteriormente não leva em conta a degradação, mas é apropriado para fins de pesquisa, uma vez que as simulações são limitadas a um intervalo de tempo curto, representando cenários diários. Vale ressaltar que o foco da pesquisa se concentra na proposta de controle do SAEB.

Assim sendo, a plataforma de simulação livre da *Mathworks*, desenvolvida por (LESAGE, 2020), é utilizada para a implementação dos algoritmos desenvolvidos e para testar a proposta desta tese. A ferramenta oferece uma abordagem modular, flexível e abstrata para o SAE, sem incorporar modelos de envelhecimento e degradação de baterias. Todos os *scripts* apresentados para esta pesquisa podem ser encontrados no Apêndice B.

O modelo de baterias usa três entradas relativas a potência ativa/reactiva de referência, e outra para determinar o modo de utilização: ilhado ou conectado a rede, para complementar o modelo do SAEB com os parâmetros técnicos e funções relevantes. O modelo de bateria é apresentado Figura 7.

Figura 7 – Modelo de bateria utilizado.

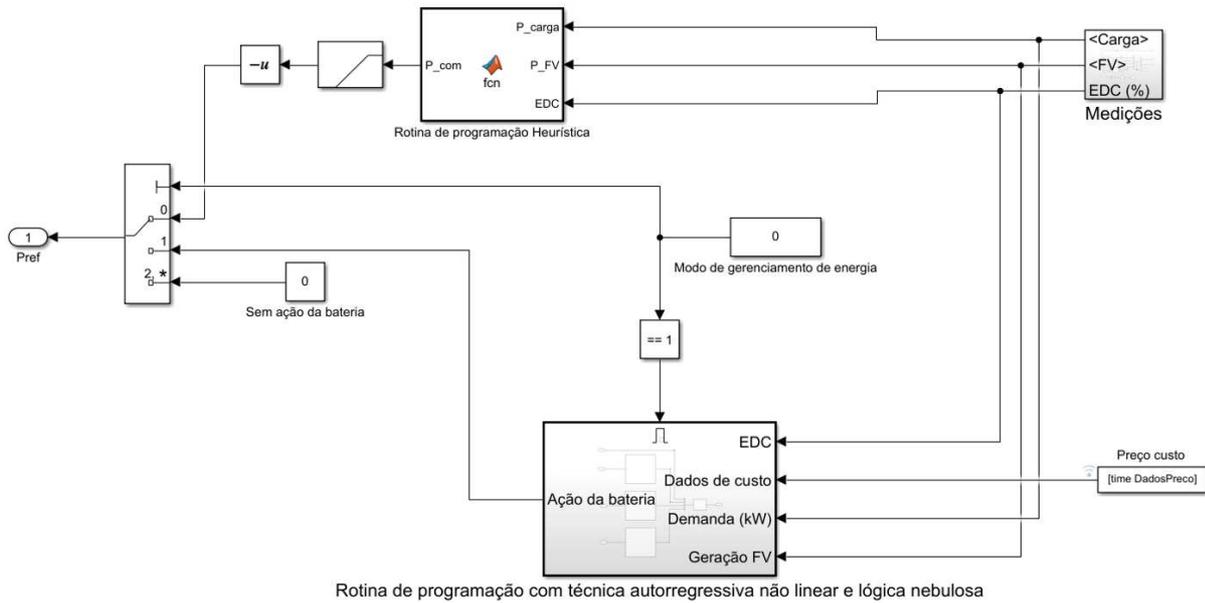


Fonte: Retirado de (LESAGE, 2020).

Este modelo de baterias é controlado através da porta de ajustes da potência ativa, nela é conectado ao *Multiport Switch*, para selecionar o tipo de controle a ser utilizado, como é mostrado na Figura 8. Nesta imagem é apresentado o SAEB com dois blocos de rotinas desenvolvidos, conectados as entradas referente a: Nível de potência demandada pelas cargas, potência FV gerada, nível do EDC e dados de custo da energia.

O modelo de bateria usa a simulação tipo fasorial, leva em consideração o fluxo de potência, a fim de reduzir custos e consumo de energia elétrica. É importante ressaltar que esta tese não considera um tipo de bateria em específico, sendo a proposta da pesquisa referente a estratégia de gestão para a compra e venda de energia no mercado.

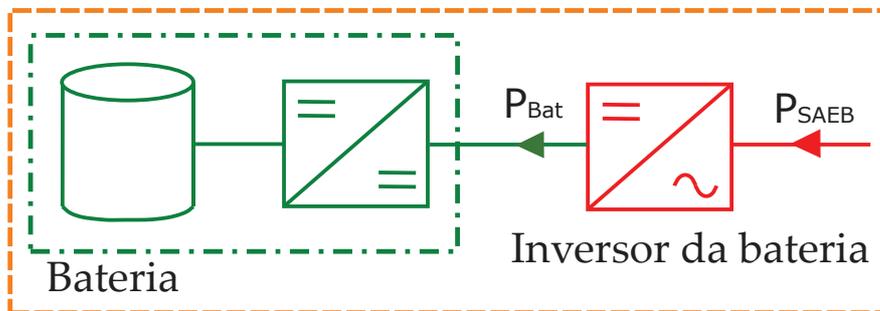
Figura 8 – Bloco com as duas rotinas de programações do SGE proposto.



Fonte: o autor.

Figura 9 – Ilustração da topologia de acoplamento do sistema de armazenamento de energia da bateria conectado em CA.

Sistemas de Armazenamento de Energia em Baterias



Fonte: Inspirado na Figura 1 de (TRUONG et al., 2016).

A figura 9 mostra a topologia de acoplamento do SAEB conectado em CA considerado. O SAEB é controlado por um sinal de potência ativa de referência fornecida pelo SGE e seus algoritmos de controle são apresentados no Apêndice B.

3.2.1.1 EDC das baterias

O EDC é a quantidade de carga restante na bateria e está diretamente relacionado à energia disponível. Não é possível medir o EDC e, portanto, deve ser estimado. No modelo utilizado o EDC é estimado pela seguinte equação:

$$EDC(k) = \frac{E_{bat}(k)}{E_{cap}(k)} \quad (3.1)$$

onde:

- $EDC(k)$ é o estado de carga na etapa de amostragem k ;
- $E_{bat}(k)$ é a energia armazenada na bateria para a etapa de amostragem k ;
- $E_{cap}(k)$ é a capacidade total da bateria na etapa de amostragem k .

A energia armazenada na bateria é calculada conforme a equação abaixo, e depende do modo de operação selecionado, ou seja, se a bateria está carregando ou descarregando, conforme a equação abaixo (HOVDEN, 2021):

$$E_{bat}(k) = \begin{cases} E_{bat}(k-1) + \sqrt{\eta_{bat}} \cdot P_{bat}(k) \cdot \Delta t - E_{SD}, & P_{bat}(k) \geq 0 \\ E_{bat}(k-1) + \frac{P_{bat}(k) \cdot \Delta t}{\sqrt{\eta_{bat}}} - E_{SD}, & P_{bat}(k) < 0 \end{cases} \quad (3.2)$$

onde:

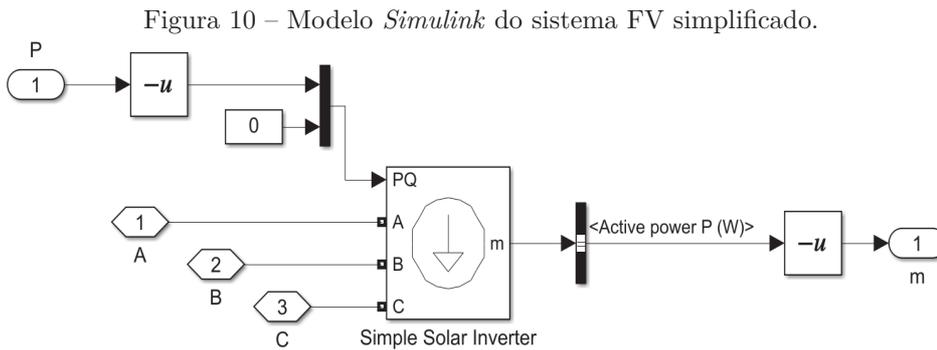
- E_{bat} e $E_{bat}(k-1)$ são as energias armazenadas na bateria nas etapas de amostra k e $k-1$, respectivamente;
- η_{bat} é a eficiência de ida e volta da bateria que é assumida igual para os processos de carga e descarga;
- Δt é o tempo de amostragem;
- $P_{bat}(k)$ é o fluxo de energia que entra e sai da bateria na etapa de amostragem k (positivo para o carregamento e negativo para o descarregamento)
- E_{SD} é a auto-descarga da bateria.

O EDC é mantido dentro de seus limites:

$$EDC_{min} \leq EDC \leq SOC_{max} \quad (3.3)$$

3.2.2 O Modelo FV simplificado

O sistema FV é modelado usando o *Simple Solar Inverter* da biblioteca (LESAGE, 2020) construída com um conjunto de blocos de componentes do *Simscape Electrical*, para fluxos de potência ativa e reativa, conforme mostrado na Figura 10. A entrada para este bloco são perfis de potência FV (ou poderia ser padronizado em por unidade) e não perfis de irradiância, com o objetivo da diminuição no processo de simulação. Para garantir desse modo, que o bloco de carga produza correntes no sentido de uma fonte de alimentação e



não como correntes de carga, a potência FV é invertida quando injetada no bloco como é apresentado pela Figura 10.

É descrito no Apêndice A os parâmetros definidos e configurados para o bloco *Simple Solar Inverter* adotado na simulação.

3.2.3 Os Modelos de carga

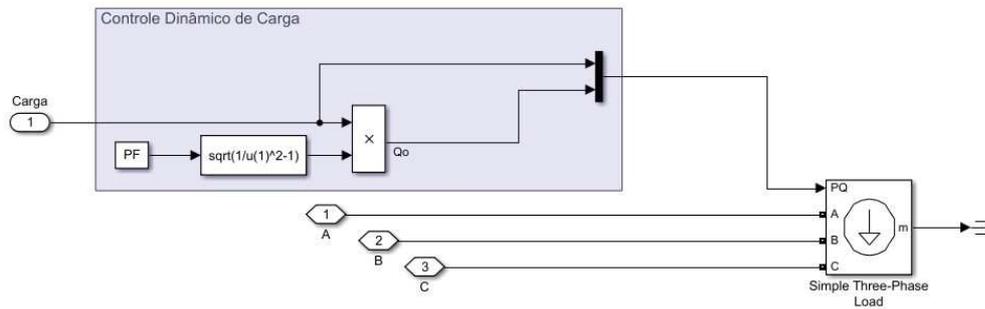
Para montar o cenário de teste dos algoritmos desenvolvidos, a MR é composta por dois tipos de cargas: a carga variável e a carga estática, sendo ambas não controláveis. Sendo que as cargas não controláveis não podem reduzir seu consumo de energia, e a sua demanda de energia deve sempre ser atendida. A carga estática não muda com o tempo e representa a carga base do sistema, enquanto a carga variável representa consumo de residências. Conforme a Equação 3.4, a demanda total de carga, P_{load} , em cada intervalo de tempo t pode ser expressa como a somatória das cargas variáveis, P_{lv} , e as cargas constantes, P_{lc} :

$$P_{load}(t) = P_{lv}(t) + P_{lc} \quad (3.4)$$

O bloco de Carga *Three-Phase Series RLC Load* da biblioteca de componentes no *Simscape Electrical* é usado para modelar as cargas estáticas. A carga variável é modelada usando o bloco de *Three-Phase Dynamic Load*. A potência ativa e reativa deste bloco pode ser inserida por meio de sinais de controle externos. Destaca-se que o gerenciamento no lado da demanda está fora do escopo deste projeto. Em relação ao bloco apresentado na Figura 11, a carga variável é inserida pela porta 1, destaca-se a opção de alteração para o caso de um fator de potência não unitário. Em seguida, o bloco *Simple Three-Phase Load* garante que a entrada de energia ativa seja dimensionada para gerar a carga desejada.

É descrito no Apêndice A os parâmetros definidos e configuradas para o bloco *Three-Phase Dynamic Load* adotado na simulação.

Figura 11 – Modelo *Simulink* de uma carga variável com controle dinâmico de carga.



3.2.4 Ponto de conexão de alimentação principal

A conexão da MR com a alimentação principal é modelada com um bloco *Three-Phase Source*, com uma tensão de 1,0387 pu, sendo a base de 115 kV e uma frequência de 60 Hz, com o nível de curto circuito 250 MVA, mais detalhes dos parâmetros podem ser observada no Apêndice A. Para a conexão com o alimentador principal, dois transformadores abaixadores T_a e T_b de 15 MVA conforme apresentado na Figura 6 de 115/12,47 kV é conectada após as chaves S_a e S_b , estes blocos garantem a redução da tensão em média conforme o modelo CIGRÈ 14 barras para ser adequado na operação de MR. A MR neste trabalho é projetada para operar conectada ao alimentador principal onde essa rede ajuda a manter a tensão, frequência e o equilíbrio de energia.

3.3 Resumo

Este Capítulo apresentou a plataforma de simulação de MR modelada, composta por um sistema FV, cargas variáveis, cargas estáticas e um SAEB para implementar e testar o SGE. A plataforma de simulação é desenvolvida em *MATLAB/Simulink* e possui as seguintes características principais:

- O modelo usa o método de resolução de fasores para aumentar a velocidade da simulação e garantir a coleta de dados pertinentes para o funcionamento do SGE;
- O modelo é de uma MR trifásica conectada, com a garantia da regulação de tensão e frequência estabelecido pela rede principal. No Capítulo 6 é apresentado outra proposta para a permanência de alimentação das cargas prioritárias em condições de operação após perder a conexão com o alimentador principal e realização do Ilhamento Intencional, após a identificação do evento e alterações nos modos de controle dos reguladores de um GS;
- O sistema FV, o SAEB, as cargas variáveis e estáticas são modelados usando a biblioteca MR da *MathWorks* (LESAGE, 2020). Embora as cargas não sejam controláveis, é possível controlar a carga variável através de sinais de controle

externos, o que permite a implementação de uma estratégia de gerenciamento do lado da demanda em trabalhos futuros.

4 Descrição do SGE

O objetivo deste Capítulo é apresentar os modelos de componentes e da rede utilizada para permitir o desenvolvimento de estratégias de gerenciamento de energia para determinar os pontos de ajuste de carga e descarga da bateria no modelo de MR apresentado no Capítulo 3. A Seção 4.1 desenvolve um algoritmo heurístico baseado em regras simples. Este algoritmo funciona como referência para comparação. A Seção 4.2 desenvolve uma abordagem para previsões de variáveis da MR aplicando RNA por meio da técnica autorregressiva não linear e outra sequência de instruções da Seção 4.3 empregando LN para tomada de decisões referente a compra ou venda de energia elétrica.

4.1 O método heurístico desenvolvido

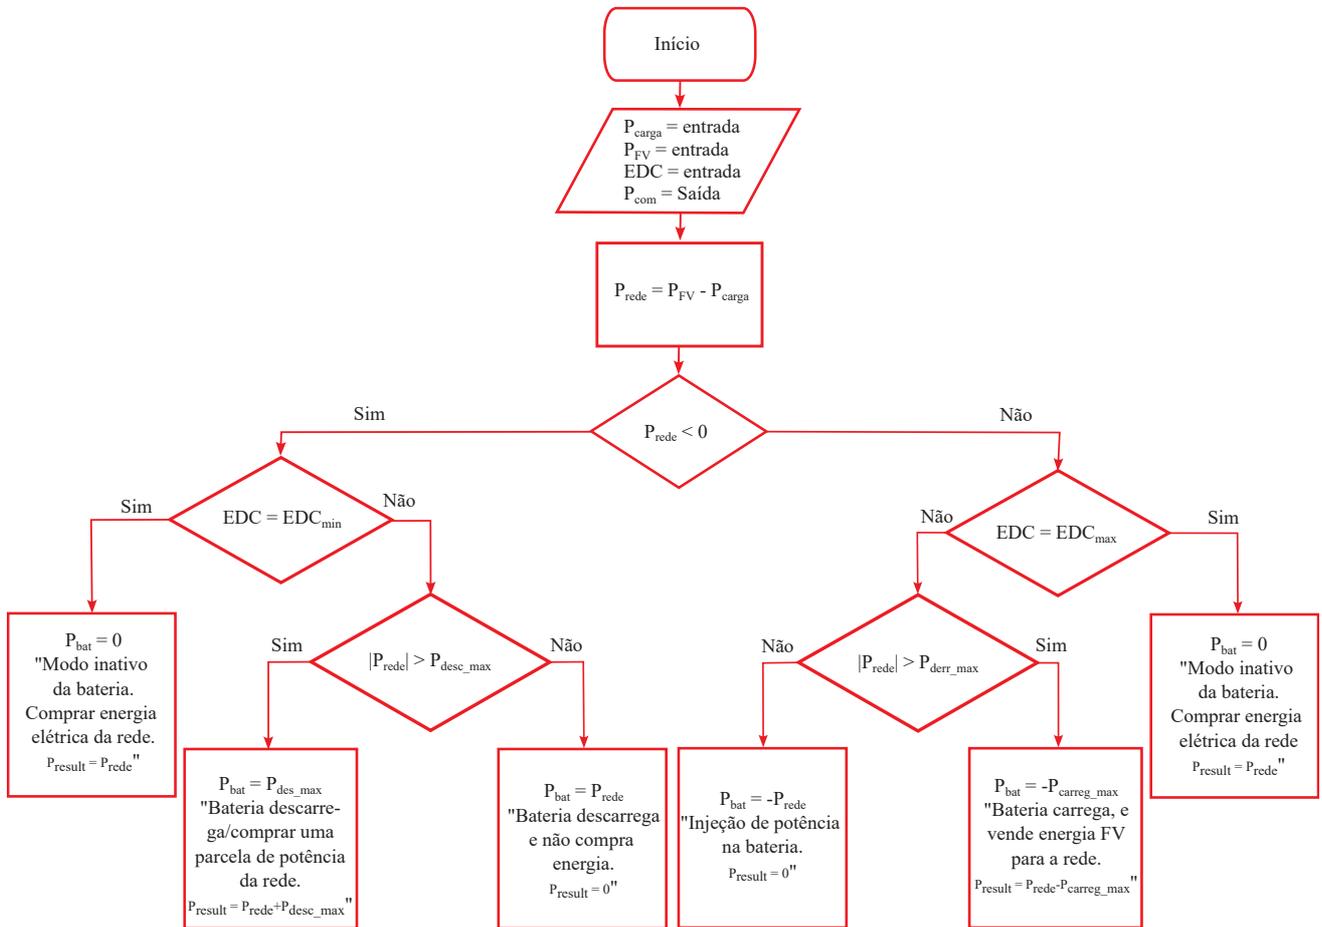
Como primeiro passo, é desenvolvido um método heurístico para realizar o gerenciamento de energia na MR e servir de referência para avaliar o desempenho do algoritmo proposto na Subseção 2.3.2. O algoritmo heurístico determina a referência de energia da bateria com base em uma série de regras projetadas para garantir que o sistema sempre opere dentro das restrições definidas. Esse método heurístico simples considera apenas o tempo presente e não é de natureza de longo prazo em um horizonte de previsão especificado. Além disso, nenhuma função de custo é considerada no algoritmo.

A Figura 12 apresenta o fluxograma do algoritmo heurístico, onde a comunicação de sinais dos fluxos de potência é ilustrada pela Figura 13. O algoritmo recebe informações de energia e potência do SGE. Essas informações são usadas para calcular a potência líquida disponível. Primeiramente, o sinal da potência líquida é verificado e, se for negativo, significa que não há energia solar FV suficiente para atender à demanda e a bateria deve ser descarregada para suprir a carga. No entanto, uma bateria não pode descarregar se isso violar a restrição de carga mínima do EDC ou se a potência exceder o limite máximo de descarga. Nesse caso, a demanda de carga deve ser suprida pelo alimentador principal. Por outro lado, se a potência líquida for positiva, significa que há um excesso de potência FV disponível que pode ser usado para carregar a bateria. No entanto, isso só pode ser feito se o EDC ainda não tiver atingido seu limite máximo.

4.2 A RNA com o modelo autorregressivo não linear para previsões das variáveis

As aplicações de séries temporais são caracterizadas por altas variações com breves períodos transitórios. Este fato dificulta a modelagem de séries temporais usando um

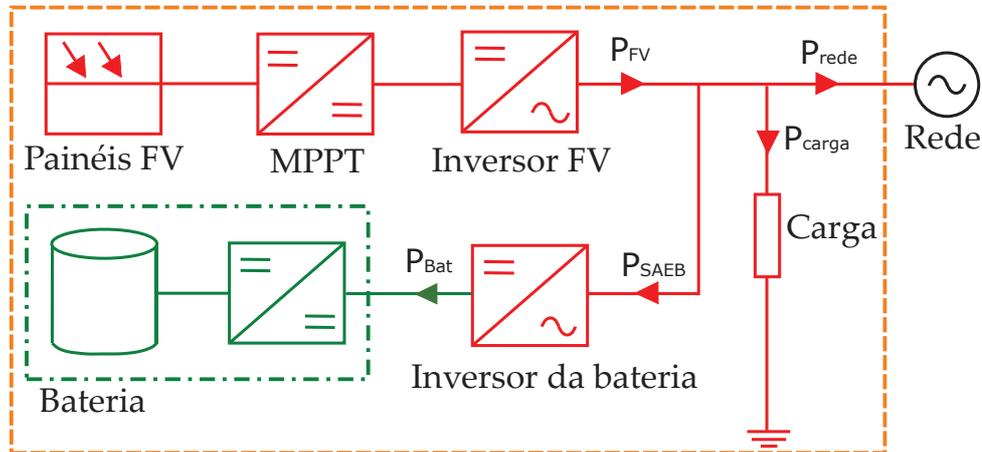
Figura 12 – Fluxograma do algoritmo heurístico.



Fonte: Adaptado de (HOVDEN, 2021)

Figura 13 – Ilustração mostrando a convenção de sinal positivo para fluxos de energia na MR.

Microrrede



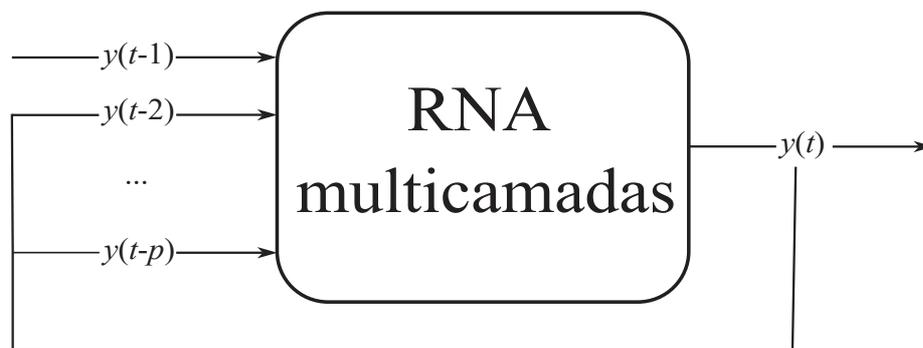
Fonte: Adaptado de (HOVDEN, 2021)

modelo linear. Portanto, uma abordagem não linear pode ser utilizada. Uma RNA com o modelo autorregressivo não linear, aplicado à previsão de séries temporais, descreve um modelo discreto, não linear e autorregressivo conforme é mostrado em (IBRAHIM et al., 2016)(MATHWORKS, 2022)(BENRHMACH et al., 2020)(LUIZ et al., 2016):

$$y(t) = h(y(t-1), y(t-2), \dots, y(t-p)) + \epsilon(t) \quad (4.1)$$

Na previsão de valores futuros de uma série temporal $y(t)$, somente os valores anteriores dessa série são utilizados. A função $h()$ que realiza a previsão é desconhecida e o RNA é treinado para melhorá-la otimizando os pesos e *bias* dos neurônios. O erro de aproximação da série temporal y no tempo t é representado pelo termo $\epsilon(t)$ (MATHWORKS, 2022). É válido enfatizar que esse modelo utiliza apenas uma série temporal.

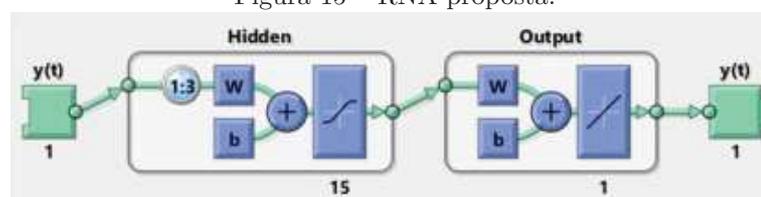
Figura 14 – Rede autorregressiva não linear.



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

A topologia de uma rede autorregressiva não linear é apresentada na Figura 14. Os valores de p são os atrasos de realimentação. O número de camadas ocultas e neurônios por camada são otimizados por meio de um procedimento de tentativas para obter a topologia de rede com o melhor desempenho. Não obstante, é importante considerar que aumentar o número de neurônios pode tornar o sistema mais complexo, enquanto um número muito baixo de neurônios pode afetar a capacidade de generalização da rede(LUIZ et al., 2016). Nesta pesquisa é utilizado uma camada oculta composta por 15 neurônios, com 3 números de atrasos p , como mostra a Figura 15.

Figura 15 – RNA proposta.



Fonte: Retirado de (MATHWORKS, 2023a)

A técnica de aprendizado utilizada na rede autorregressiva não linear é a retropropagação de *Levenberg-Marquardt* (ALWAKEEL; SHAABAN, 2010) (HAGAN; MENHAJ, 1994), que é conhecida por ser a mais rápida entre os algoritmos de retropropagação. Essa técnica foi desenvolvida para aproximar a derivada de segunda ordem sem a necessidade de calcular a matriz hessiana, o que acelera o processo de treinamento. Quando a função de desempenho é uma soma de quadrados, como geralmente ocorre no treinamento de redes *feedforward*, a matriz hessiana pode ser aproximada como mostrada na primeira equação abaixo e o gradiente pode ser calculado como descrito na segunda equação abaixo (LUIZ et al., 2016).

$$H = J^T J \quad (4.2)$$

$$g = J^T e \quad (4.3)$$

Conforme as Equações 4.2 e 4.3:

\mathbf{J} é a matriz jacobiana que contém as primeiras derivadas dos erros da rede em relação aos pesos e bias;

\mathbf{e} é um vetor de erros da rede em todas as amostras de treinamento.

O artigo (HAGAN; MENHAJ, 1994) emprega um algoritmo de retropropagação convencional para estimar a matriz jacobiana para aproximar a matriz hessiana. Essa metodologia é menos complexa e mais eficiente. O algoritmo de atualização utilizado na técnica de *Levenberg-Marquardt* é descrito no artigo (LUIZ et al., 2016):

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (4.4)$$

É importante ressaltar que este método emprega a matriz jacobiana nos cálculos, considerando que a função de desempenho é a média da soma dos erros quadráticos. Por isso, as redes devem utilizar o erro quadrático médio (*EQM*) ou a soma dos quadrados residuais (*SQR*), conforme demonstrado nas equações abaixo:

$$SQR = \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (4.5)$$

$$EQM = \frac{SQR}{n} \quad (4.6)$$

onde:

y_i representa i-ésima amostra de dados;

\hat{y}_i são os dados aproximados obtidos pela rede para o valor de y_i ;

n o número de amostras de dados para o treinamento da rede.

4.2.1 Definição dos dados da rede

Para auxiliar na criação da rede, utiliza-se o aplicativo *Neural Network Time Series* do *MATLAB* função rede autoregressiva não Linear (do inglês *Nonlinear Autoregressive - (NAR)*) que permite, visualizar e treinar redes neurais dinâmicas para resolver problemas de rede autoregressiva não Linear e Autorregressiva Não Linear Exógena de séries temporais não lineares. A definição das divisões percentuais dos dados dos conjuntos:

- Treinamento (70%):

São apresentados à rede durante o treinamento, e a rede é ajustada de acordo com seu erro.

- Validação (15%):

São usados para medir a generalização da rede e interromper o treinamento.

- Teste (15%):

Estes não têm efeito no treinamento e, portanto, fornecem uma medida independente do desempenho da rede durante e após o treinamento

O Apêndice B apresenta as funções do *MATLAB* para aplicação de treinamento da RNA para previsões dos preços de energia elétrica no mercado, consumo das cargas e a geração da potência FV. Esses *scripts* da RNA podem reproduzir os resultados ou ser personalizado para qualquer processo de treinamento.

4.3 LN para as tomadas de decisões

Esta Subseção descreve o modelo LN. Primeiro, a arquitetura do modelo da LN para tomadas de decisões é apresentada, além disso, uma explicação detalhada do desenvolvimento de cada etapa da arquitetura do modelo é comentada juntamente com uma discussão e avaliação.

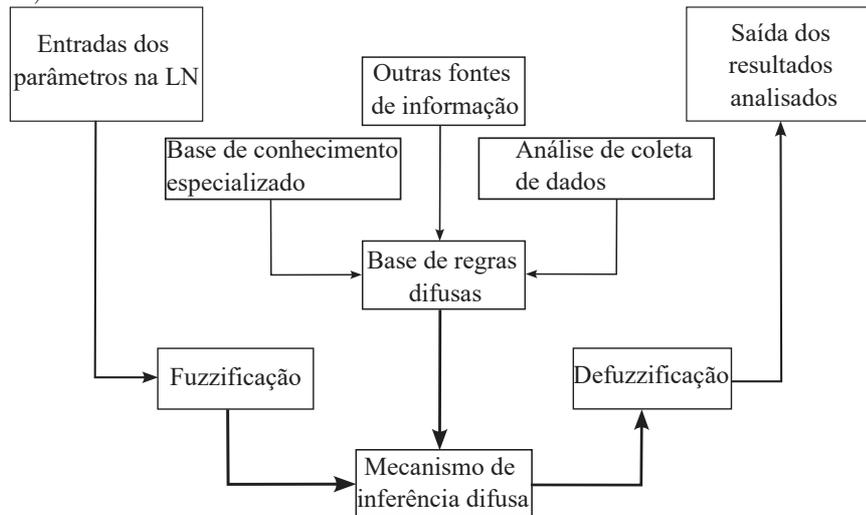
4.3.1 A arquitetura do modelo

O modelo da metodologia para criação da LN adaptada de (SII; RUXTON; WANG, 2001), é apresentado na Figura 16.

Nesta Subseção é desenvolvida a base de conhecimento para a criação da metodologia apresentada na Figura 16. Para que o modelo seja facilmente interpretável, gerenciável e modificável, é desenvolvido uma estrutura integrando a LN com módulos de entradas referente a:

- Previsões das demandas de energia;

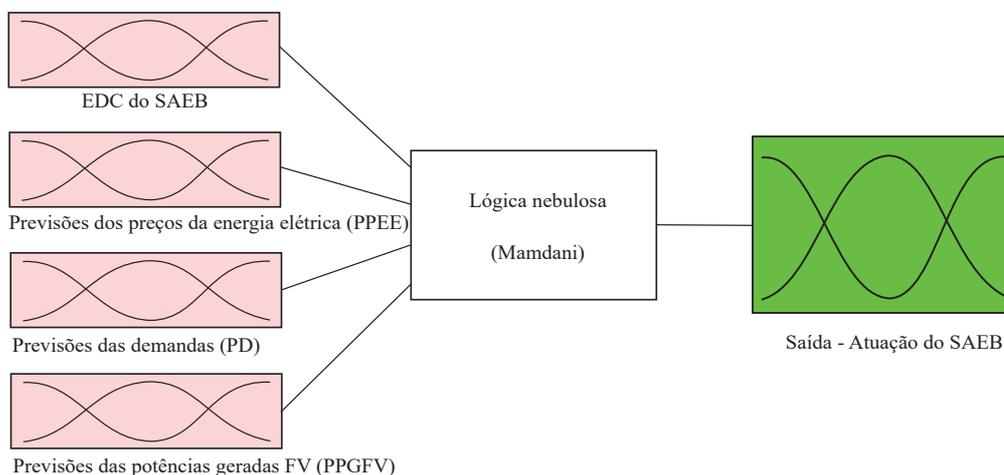
Figura 16 – Metodologia de realização do modelo proposto em LN. Adaptado de (SII; RUXTON; WANG, 2001).



- Previsões dos valores de preços da energia elétrica;
- Previsão da potência gerada FV;
- Nível do EDC das baterias.

A teoria avaliada neste Capítulo, considera importante o nível das variáveis de entrada do SGE. Uma estrutura de modelo com quatro módulos de entrada como mostra a Figura 17, é escolhida devido a importância da facilidade de alterações nos ajustes da base de regras difusas. O modelo altera a única saída referente a atuação do SAEB a partir de níveis dos valores das variáveis de entrada conforme a base de regras *if-then* do sistema de inferência nebulosa tipo *Mamdani* (MAMDANI, 1977) e os pesos definidos.

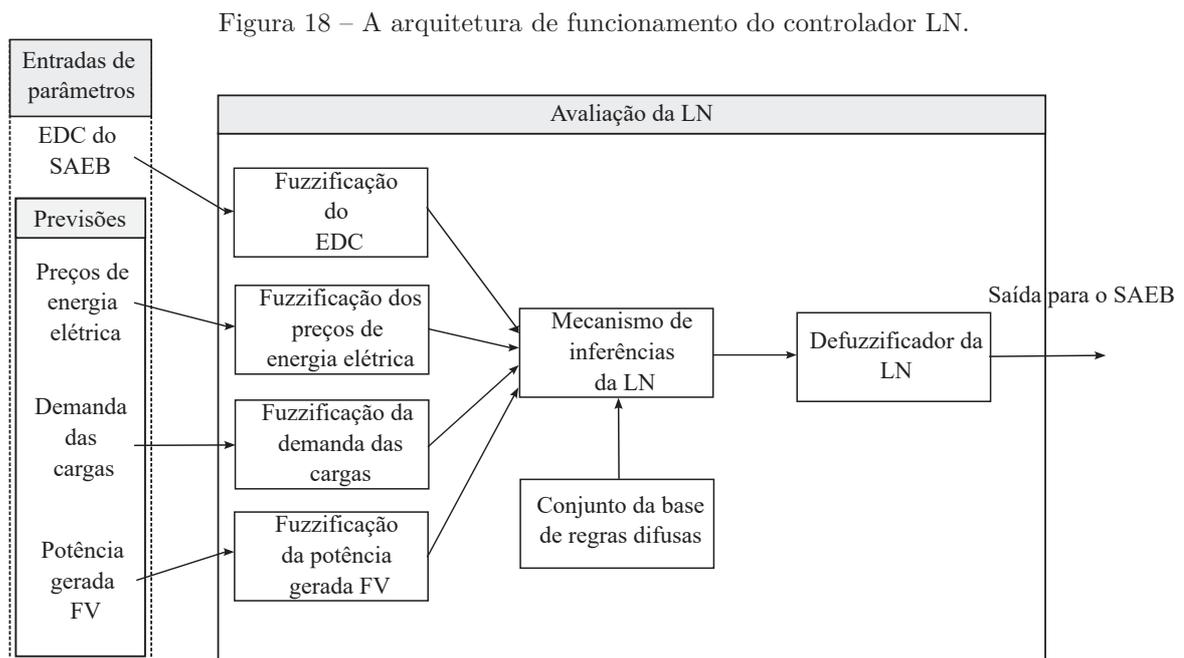
Figura 17 – O sistema adotado de inferência difuso do tipo *Mamdani* com quatro módulos de entrada e um de saída.



O modelo de LN apresentado na Figura 17 foi a escolha definida após uma cuidadosa pesquisa de diferentes estruturas. Para implementar os fatores no modelo proposto, o controlador LN é desenvolvido para atender as estruturas consideradas módulos de entradas. O controlador LN recebe quatro variáveis na entrada, que através da base de regras do controlador de LN, define apenas um único valor de saída linguística para atuação do SAEB. Isso torna o modelo facilmente interpretável, flexível e facilita o processo para avaliação e calibração do usuário. O controlador LN pode responder a diferentes conjuntos de valores de entrada, como é descrito com mais detalhes na Seção 4.3.2.

4.3.2 A metodologia do controlador de LN proposto

Para entender melhor a combinação dos módulos do controlador LN a arquitetura é apresentada. O controlador LN é desenvolvido para atender as estruturas modulares das entradas, sendo assim, a LN recebe quatro valores na entrada para enviar à base de regras, em seguida transformá-las em um único valor na saída linguístico. Isso é exemplificado na Figura 18.



4.3.3 Conjunto de regras difusas

Para avaliar os parâmetros das entradas difusas, um conjunto de regras para o mecanismo de inferência de estado deve ser definido. A base de regras visto na Tabela 1 mostra as especificidades usadas para o processo de *defuzzificação* que compreende uma base de regras utilizando a AND. É importante mencionar que alguns pesos são utilizados em determinadas regras.

Tabela 1 – Tabela base de regras do controlador LN.

EDC	PPEE	PD	PPGFV	Saída	Peso
low	low	low	low	low	1,0
low	low	low	high	medium	1,0
low	low	high	low	low	1,0
low	low	high	high	medium	1,0
low	high	low	low	high	1,0
low	high	low	high	high	1,0
low	high	high	low	high	1,0
low	high	high	high	high	1,0
high	low	low	low	low	1,0
high	low	low	high	medium	1,0
high	low	high	low	low	1,0
high	low	high	high	medium	1,0
high	high	low	low	high	1,0
high	high	low	high	high	1,0
high	high	high	low	high	1,0
high	high	high	high	high	1,0

Fonte: o autor.

4.4 Resumo

Este capítulo apresentou o algoritmo heurístico criado para avaliar o desempenho da abordagem proposta, bem como os métodos de controle sugeridos para operar o SGE de MR. Como mencionado ao longo do capítulo, os algoritmos são compostos por RNA's com os modelos autorregressivos não lineares para previsões das variáveis e uma LN para tomar decisões de compra ou venda de energia elétrica da rede principal.

5 Comparação entre o algoritmo proposto e o heurístico: abordagens de controle e estudos de caso

Esta Seção apresenta o desempenho das abordagens de controle propostas por meio de extensos estudos de caso durante o período de simulação diária ao usar dados de gerações FV (LESAGE, 2020) com o céu claro e nublado, demanda de carga (LESAGE, 2020) e perfis de preços de eletricidade da Nordpool (NORDPOOLAS, 2020). As Seções 5.1 e 5.2 apresentam os parâmetros, dados e método de previsão usados no processo de simulação. A Seção 5.3 apresenta, os resultados de quatro casos de simulações. Na Seção 5.3 é analisado o desempenho do método desenvolvido, os efeitos dos algoritmos na MR em termos de fluxo de potência de acordo com os horários. E por fim, na Subseção 5.4.3 é realizada a comparação de custos entre os algoritmos heurístico e proposto.

5.1 Os parâmetros

No processo de simulação, foram utilizados dados coletados a partir da programação de preços do dia seguinte e dados faturados de energia elétrica da Nordpool na França, referente ao dia 10 de novembro de 2022 (NORDPOOLAS, 2020). O modelo de simulação adotado é o de 14 barras do CIGRÈ, como descrito na Seção 3.2. A Tabela 2 apresenta os parâmetros do SAEB e sistema FV instalado na MR. A simulação abrange um período de 24 horas para avaliar a capacidade do algoritmo em operar a MR sob diferentes condições climáticas, incluindo períodos com céu claro e nublado.

A simulação adotada é do tipo fasorial na frequência especificada definida como 60 Hz, a fim de equilibrar o esforço computacional e o desempenho dos algoritmos. Para preservar a vida útil da bateria e evitar sobrecargas ou descargas profundas, a faixa do EDC é limitada. De acordo com alguns experimentos, carregar baterias de íon-lítio a 85% prolonga sua vida útil em comparação com carregá-las a 100% (BATTERYUNIVERSITY.COM, 2003). Descarregar a bateria completamente também é desaconselhável, pois muitos produtos químicos celulares não toleram descargas profundas, e as células podem ser permanentemente danificadas. Assim, os limites mínimo e máximo de EDC considerados neste estudo são de 20% e 80%, respectivamente.

Tabela 2 – Parâmetros do SAEB e do gerador FV.

Parâmetros	Valores
Tensão da MR	12470
Frequência nominal	60
Tipo de bateria	Íon de lítio
Potência nominal (kW)	400
Capacidade nominal (kWh)	2500
Eficiência geral do sistema %	95.5
Limites superiores de carga %	80
Limites de carga inferior %	20
EDC para recarregar %	11
Estado de carga inicial (0-100%)	50
<i>Cmds</i> ativos iniciais (kW)	400
Potência FV máxima (kW)	1000
Tipo de simulação	Fasor

Fonte: o autor.

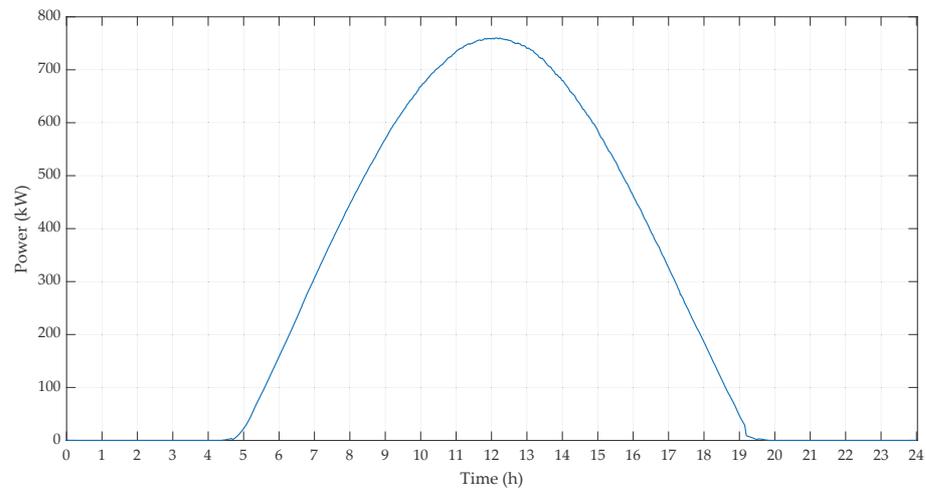
5.2 Os dados

O processo de simulação considera os dados de geração FV para a situação de dia de céu claro e nublado, como mostra a Figura 19. Esses conjuntos de dados utilizados têm uma resolução de tempo das variáveis de aproximadamente 1441 pontos, e em seguida é utilizado uma transição dos dados (com o bloco *Rate Transition*) para uma taxa de 86104 pontos, para uma melhor resolução, e representando resultados de aproximadamente 86400 segundos, referente a um dia.

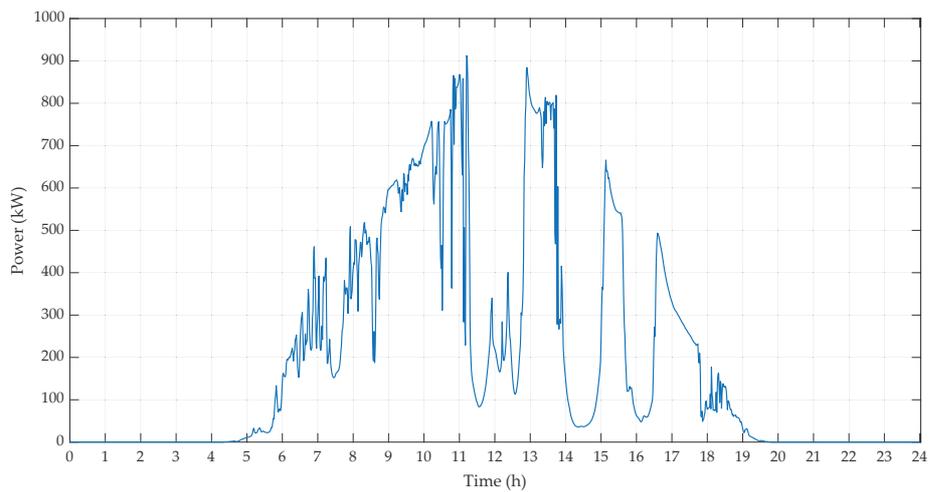
A demanda adotada no modelo são compostas por cargas fixas e variáveis instaladas ao longo das barras, conforme o modelo de 14 barras CIGRÈ da Figura 6. Na Figura 20, é apresentada a curva de carga adotada.

Os dados de custos referentes a programação de preços da energia elétrica do dia seguinte e dados faturados em tempo real são coletados da *Nordpool* área Francesa, do dia 10 de novembro de 2022 (NORDPOOLAS, 2020), em euro (EUR). Esses dados são do tipo de tarifação dinâmica e têm a resolução de uma hora sendo representadas na Figura 21. Nesse tipo de tarifação dinâmica para comprar a energia elétrica da rede principal, o custo por kWh depende do tempo em hora e o seu valor naquele instante em EUR/kWh. Para

Figura 19 – Dados da potência gerada FV. Em (a) a potência FV gerada para o céu claro, e em (b) a potência FV gerada para o céu nublado.

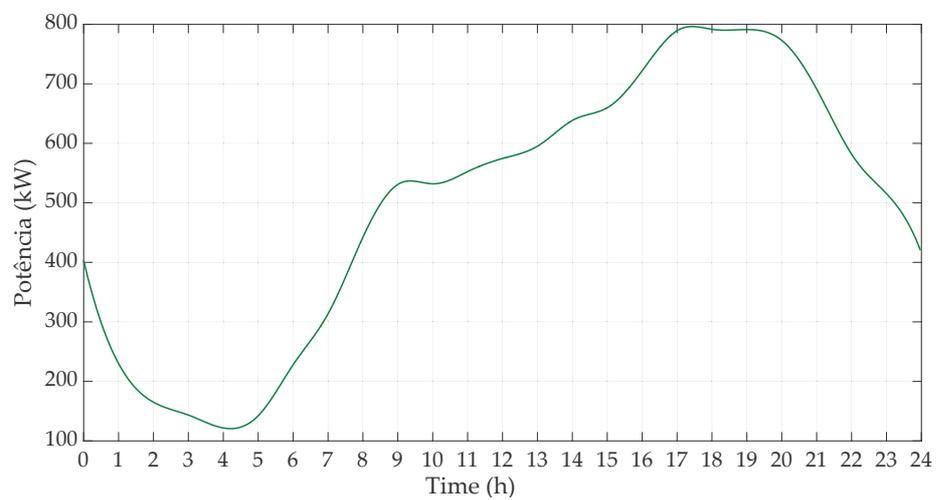


(a)



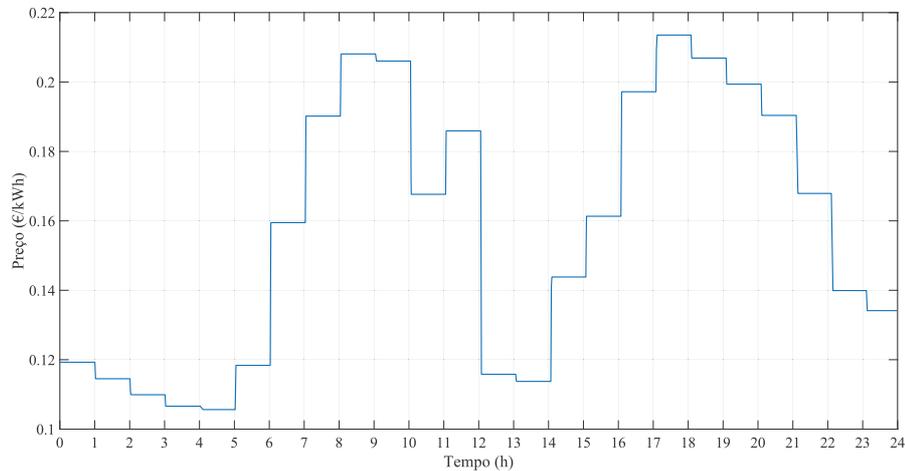
(b)

Figura 20 – A curva referente as cargas adotadas. De (LESAGE, 2020)



fins de comparação, o preço recebido pela venda de energia à rede principal foi assumido igual ao preço de compra para todos os casos, sendo excluído quaisquer encargos aplicados a nível nacional.

Figura 21 – Os preços de tarifação dinâmica adotados nos estudos de caso. De (NORDPOOLAS, 2020).



5.2.1 Os módulos para previsões das variáveis

Os dados de FV, carga e preço de eletricidade apresentados nas Seção 5.2 não são conhecidos pelo sistema de gerenciamento de energia com antecedência. Portanto, a proposta permite a implementação de módulos de previsões. São utilizadas outras curvas FV e de demanda (LESAGE, 2020), e a curva de custos da programação faturadas do dia anterior (NORDPOOLAS, 2020) para o treinamento das RNA's. A Figura 22 mostra os módulos de previsões conectados na entrada do bloco de LN.

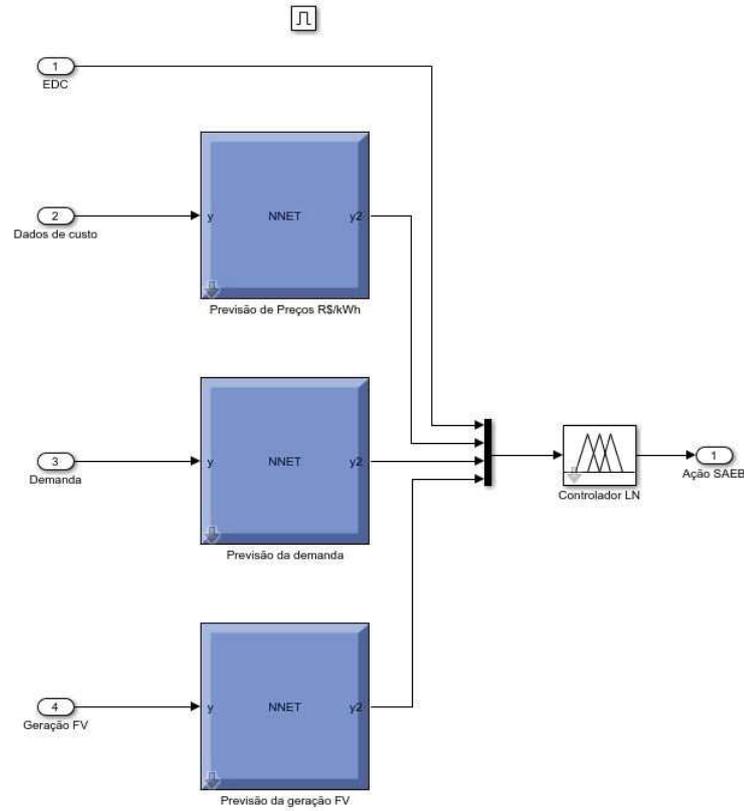
O Apêndice B incluiu os *script's MATLAB* usados para treinar os módulos de previsões das RNA's. Já o Apêndice C, apresenta os dados para os treinamentos das RNA's e as preprevisões realizadas.

5.3 Estudos de caso

É avaliada a capacidade de resposta do SGE proposto no modelo de MR para diferentes cenários:

- Caso 1: Método heurístico para o céu claro;
- Caso 2: Método proposto para o céu claro;
- Caso 3: Método heurístico para o céu nublado;
- Caso 4: Método proposto para o céu nublado;

Figura 22 – Os módulos para previsões das variáveis de Demanda (kW), Preços (EUR/kWh) e Potência gerada FV (kW). E a saída dos módulos de previsões, conectadas no controlador de LN.



Fonte: Imagem retirada de *Simulink* construída por meio do recurso (MATHWORKS, 2023b).

As subseções a seguir fornecem os resultados de simulações dos casos propostos. Todos foram simulados para um período de tempo referente a um dia, e os resultados numéricos são plotados no mesmo intervalo de tempo, para todas variáveis estudadas. Uma resolução diária é considerada ao plotar o EDC da bateria, o preço da eletricidade e as potências geradas FV. Finalmente, os custos e quantidade de energia totais consumidas da rede para cada caso são usados para comparar os tipos de algoritmos discutidos na Tese.

5.3.1 Os casos 1 e 3 de referência método heurístico aplicado para condições de céu claro e nublado

Dois casos heurísticos são incluídos nos estudos de caso para fornecer uma base mais ampla para as comparações, onde os resultados dos algoritmos com IA's podem ser comparados aos resultados de algoritmos heurísticos baseados em regras simples. Desta forma, destacam-se as vantagens de utilizar uma técnica de gerenciamento de energia baseado em IA para programar a ação do SAEB. O algoritmo heurístico é descrito na Seção 4.1, o *script MATLAB* correspondente está anexado no Apêndice B. As Figuras 23 e 24 mostram os resultados das simulações dos casos heurísticos de céu claro e nublado referente ao período de 24 horas.

Figura 23 – Resultados do caso de referência heurística para o período de simulação com o dia de céu claro.

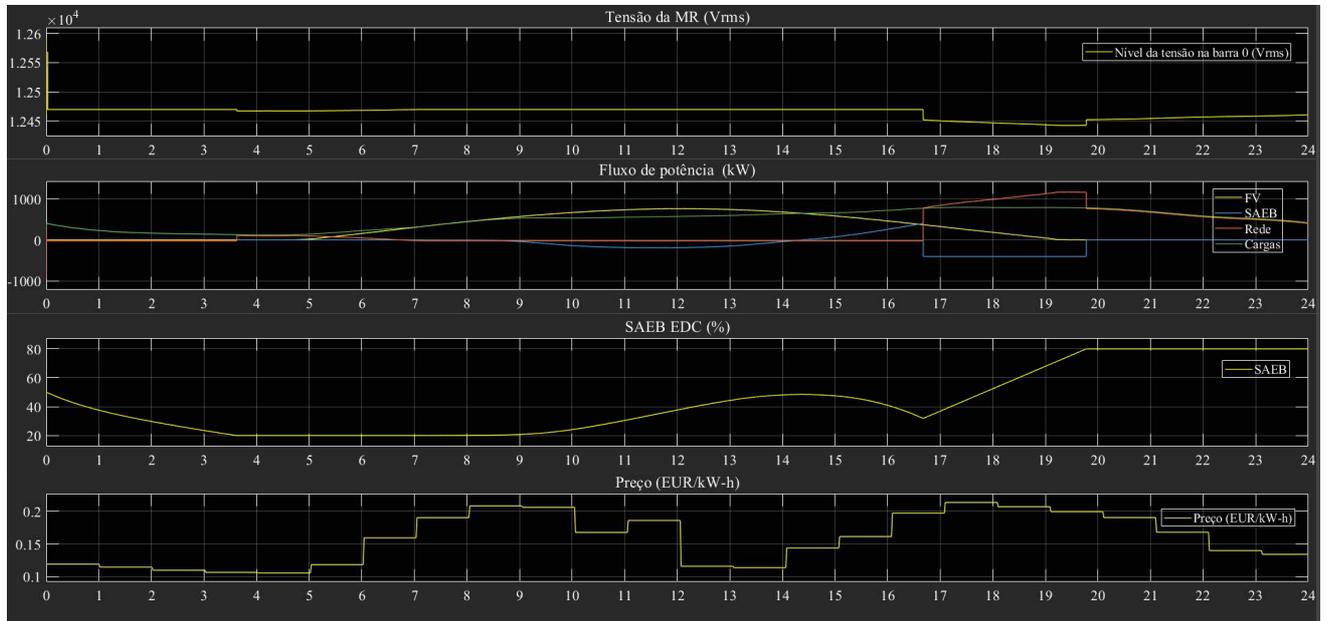
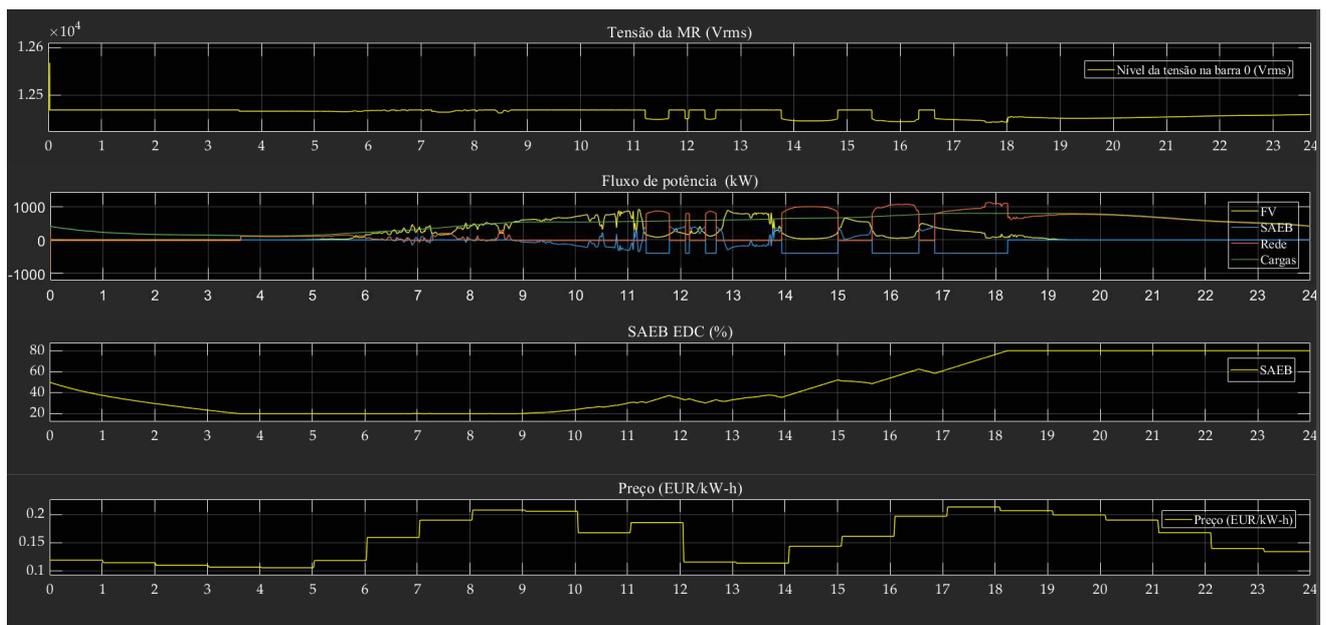


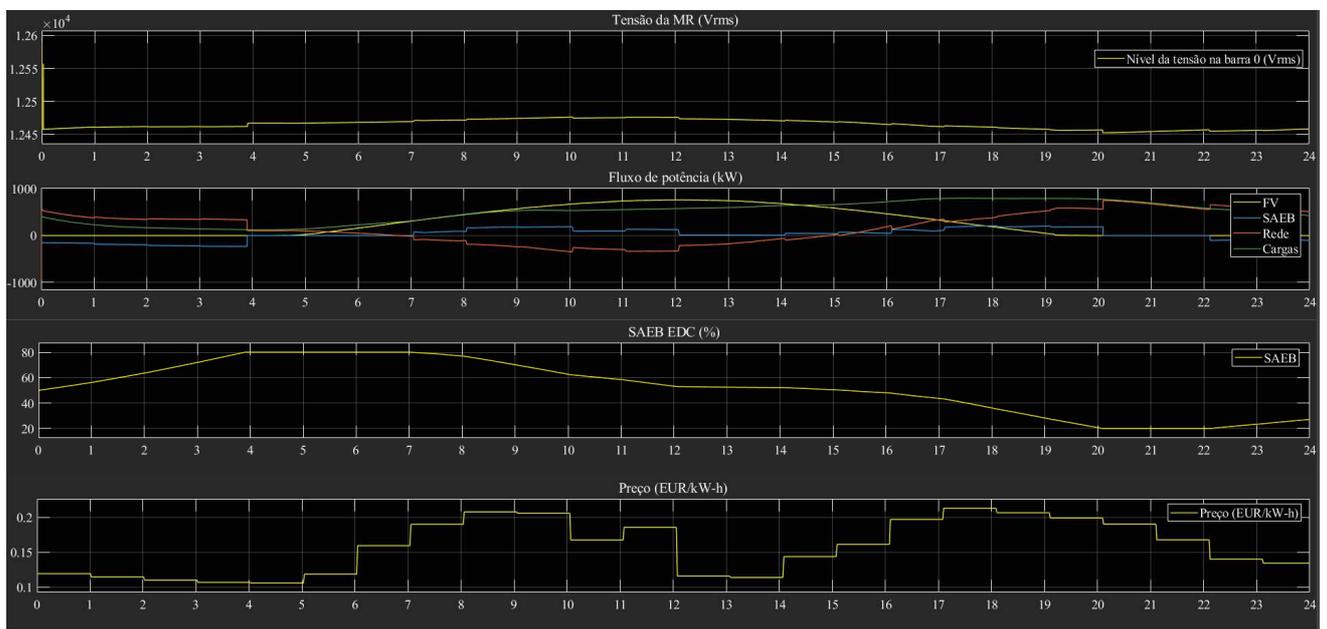
Figura 24 – Resultados do caso de referência heurística para o período de simulação com o dia de céu nublado.



5.3.2 Os casos 2 e 4, métodos propostos aplicados para condições de céu claro e nublado

Os casos dois e quatro, incorporam as precisões ao mostrar o quão bem o algoritmo de LN em conjunto com as previsões das RNA's treinadas lidam com as alterações das variáveis ao longo do dia em condições de céu claro e nublado. As curvas para os resultados da simulação do algoritmo proposto para o período de 24 horas são apresentadas nas Figuras 25 e 26.

Figura 25 – Resultados do caso com o modelo proposto para o período de simulação com o dia de céu claro.



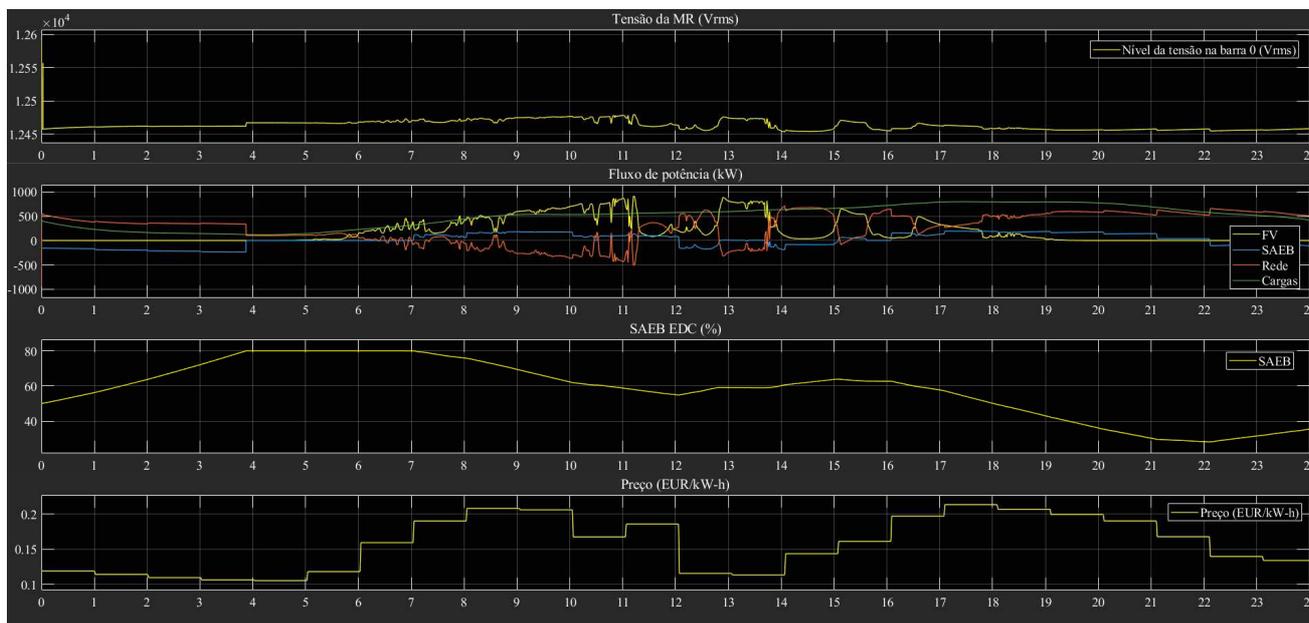
5.4 Análise dos resultados dos quatro estudos de casos

Nesta seção, são discutidos os resultados obtidos nos quatro casos de simulação apresentados na Seção 5.3. Além disso, são feitas comparações entre os custos e o uso de energia elétrica do alimentador principal nos cenários de céu claro e nublado, para os algoritmos propostos e heurísticos.

5.4.1 Discussões dos casos 1 e 3 com o método heurístico

Observa-se na Figura 23, o comportamento do estudo de caso heurístico para o céu claro, ao iniciar a simulação sem a geração FV, a bateria fornece energia demandada pelas cargas até o instante de 03:45 onde o limite mínimo de EDC é alcançado. Após um período ocioso, observa-se que a bateria carrega quando há excesso de potência FV disponível, das 9:00 até aproximadamente 14:25, como é esperado, porque após este intervalo as regras

Figura 26 – Resultados do caso com o modelo proposto para o período de simulação com o dia de céu nublado.



definidas no algoritmo Figura 12 não permitem que as baterias carreguem da rede elétrica nestas condições. Em seguida, após um breve período de descarga do intervalo de 14:26 até por volta das 16:45. Em seguida, acontece um período para o carregamento das baterias pela rede principal até o seu limite EDC máximo (80%), o que implica em seguida, na condição de bateria ociosa para o restante do dia. É importante destacar que a bateria finaliza o dia com o valor o EDC máximo (80%).

Na Figura 24, um comportamento semelhante no início da simulação foi observado, porém ao iniciar a geração de energia FV na condição de céu dublado, uma alteração no comportamento é observado, sendo carregada as baterias nos instantes que acontecem os excessos de potência FV em relação a demanda das cargas, como é observado no período da tarde. É evidente que o alimentador principal atua na falta de potência FV gerada. Da mesma forma que o caso da Figura 23, o dia é finalizado com as baterias ociosas e no seu limite de EDC máximo (80%).

5.4.2 Discussões dos casos 2 e 4 com o método proposto

Conforme a Figura 25, é notável a diferença de atuação do SGE com o algoritmo de LN em comparação com os resultados do método de referência. Pela Figura 25, referente ao céu claro observa-se que no início a bateria carrega até atingir o seu limite de EDC máximo (80%) às 03:50, isso acontece pelo fato do baixo valor no preço de energia elétrica do mercado, permanecendo neste período até por volta das 07:10. Em seguida, com o aumento no preço, duas inclinações da curva referente a descarga são observadas, até

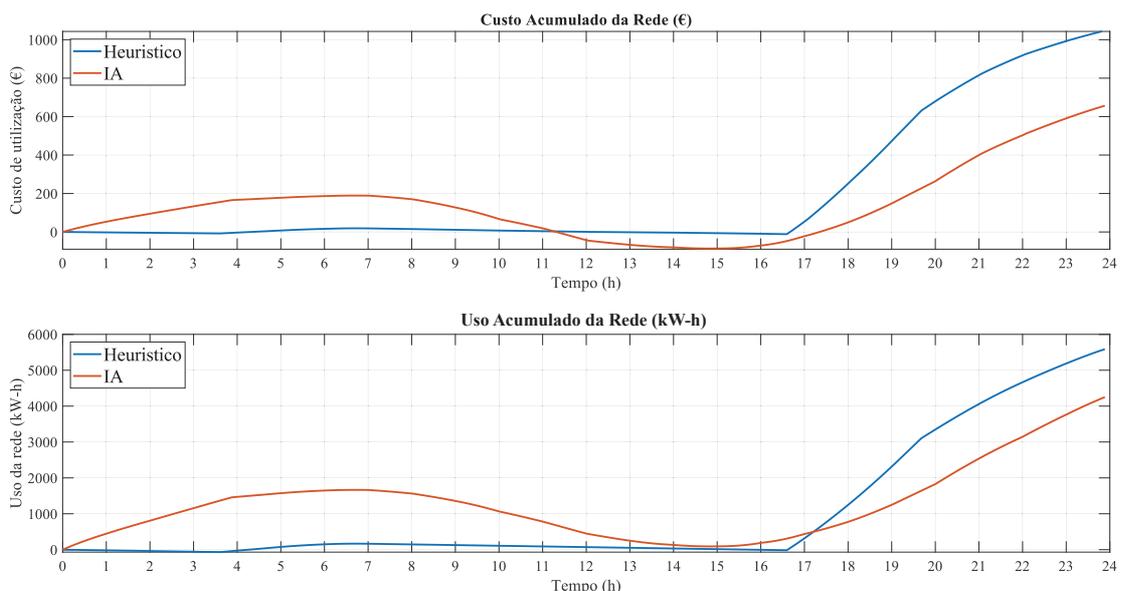
aproximadamente às 12:00, onde ocorre osciosidade até aproximadamente às 14:10. Em seguida há outro período de leve descarregamento da bateria, até às 16:00. Em seguida acontece o processo de descarga por conta do alto preço da energia elétrica no mercado até às 20:00, atingindo o nível do EDC mínimo. Em seguida, após um período ocioso, por volta das 22:30, é retornado o processo de recarga por conta da diminuição do preço da energia elétrica no mercado e das outras condições conforme a Tabela 1.

A Figura 26, referente ao céu nublado, o SGE se comporta semelhante ao cenário de céu claro. Observa-se que no início a bateria carrega até atingir o seu limite de EDC máximo (80%), e permanece, até às 03:50. Já o próximo intervalo com descargas (contendo pequenos intervalos de carregamento), permanece até aproximadamente às 21:00. Isso se deve à base de regras definida para condições elevadas no preço da energia elétrica do mercado, como é mostrado na Tabela 1. Mas o fato da diminuição da potência FV gerada para o céu nublado, reflete na diferença de custos acumulados entre os dois cenários, como é mostrado na Subseção 5.4.3.

5.4.3 Comparação entre os algoritmos heurístico e o proposto

Esta Subseção investiga os efeitos das variações no valor do custo em euro (EUR) e o uso da energia da rede (kWh) ao longo de 24 horas de simulações para os cenários de céu claro e nublado com o algoritmo: heurístico e a proposta com IA. Na Figura 27 é apresentado os resultados para os três algoritmos IA simulados com o céu claro:

Figura 27 – Comparação dos métodos utilizados céu claro.



A Tabela 3 mostra os resultados de custos acumulados ao longo de 24 horas com o céu claro para os dois métodos. É importante destacar que a diferença entre os dois

métodos é de aproximadamente 37,1409%, sem considerar as diferenças finais de EDC para os dois casos.

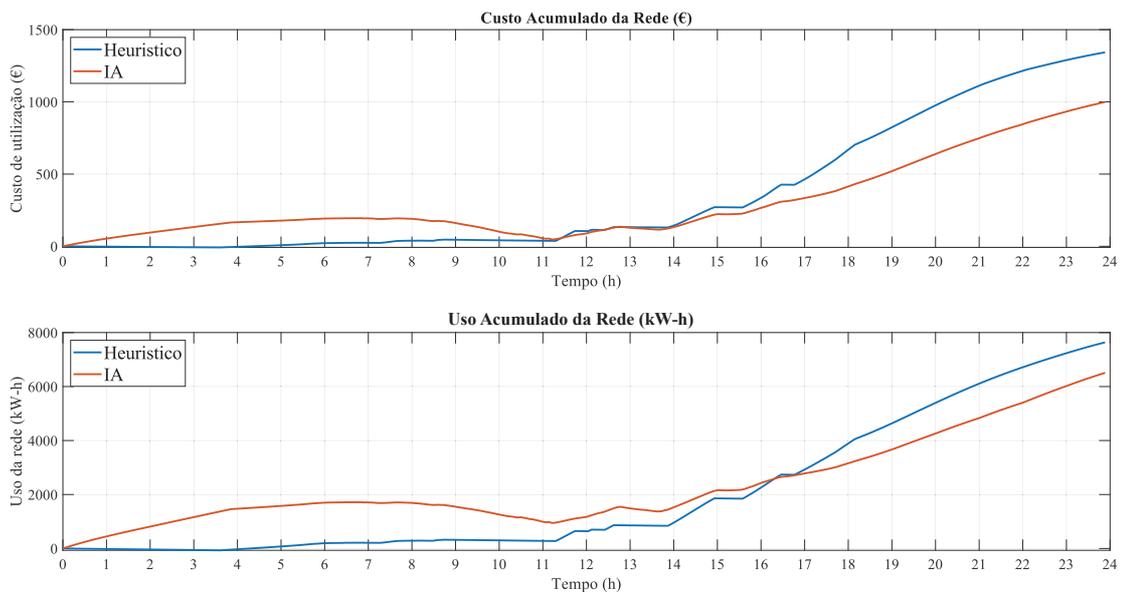
Tabela 3 – Comparação dos custos das simulações céu claro

Custos nas simulações	Valores EUR
Custo do SGE com método heurístico	1046,6575
Custo do SGE com o método de IA	656,7683

Fonte: o autor.

Na Figura 28 é apresentado os resultados para as duas condições simuladas com o céu nublado:

Figura 28 – Comparação dos métodos utilizados com o céu nublado.



Já na Tabela 4 mostra os resultados de custos acumulados ao longo de 24 horas com o céu nublado para os dois métodos. É importante destacar que a diferença entre os dois métodos é de aproximadamente 25,6453%, sem considerar as diferenças finais de EDC para os dois casos.

Tabela 4 – Comparação dos custos das simulações com o céu nublado

Custo nas simulações	Valores EUR
Custo do SGE com método heurístico	1343,3987
Custo do SGE com método IA	998,8799

Fonte: o autor.

Pode-se destacar que em cenários de céu claro a economia e a sustentabilidade são maiores.

5.5 Resumo

Neste capítulo, foram apresentados os parâmetros dos modelos FV e SAEB, a simulação adotada com seus limites de EDC, dados de geração FV, demanda e custos de energia elétrica, bem como particularidades da resolução dos pontos na simulação. Uma figura ilustrativa apresentou os módulos para previsão das variáveis de entrada da LN. Além disso, foram realizadas discussões sobre as comparações dos resultados obtidos com os algoritmos propostos baseados em IA e heurística.

6 Elementos utilizados para o ilhamento intencional da MR

6.1 Considerações iniciais

Neste capítulo, são apresentados os detalhes sobre as GDs escolhidas para o ilhamento intencional no modelo de 14 barras do CIGRÈ, as técnicas de detecção de ilhamento, incluindo o relé de Taxa de Variação de Frequência (TVF, do inglês *Rate of Change of Frequency*, ROCOF), sub/sobrefrequência e bloqueio de tensão. Com isso, objetiva-se apresentar a configuração completa do relé proposto e a modelagem das cargas. As contribuições desta proposta referem-se a identificação do ilhamento por meio do relé proposto, juntamente com a alteração dos modos de controle da GD, para o atendimento de energia elétrica das cargas prioritárias. Conforme é apresentado na Figura 5, as técnicas utilizadas nos Capítulos 6 e 7 são referentes a função de atuação de nível baixo, mais próximo a GD.

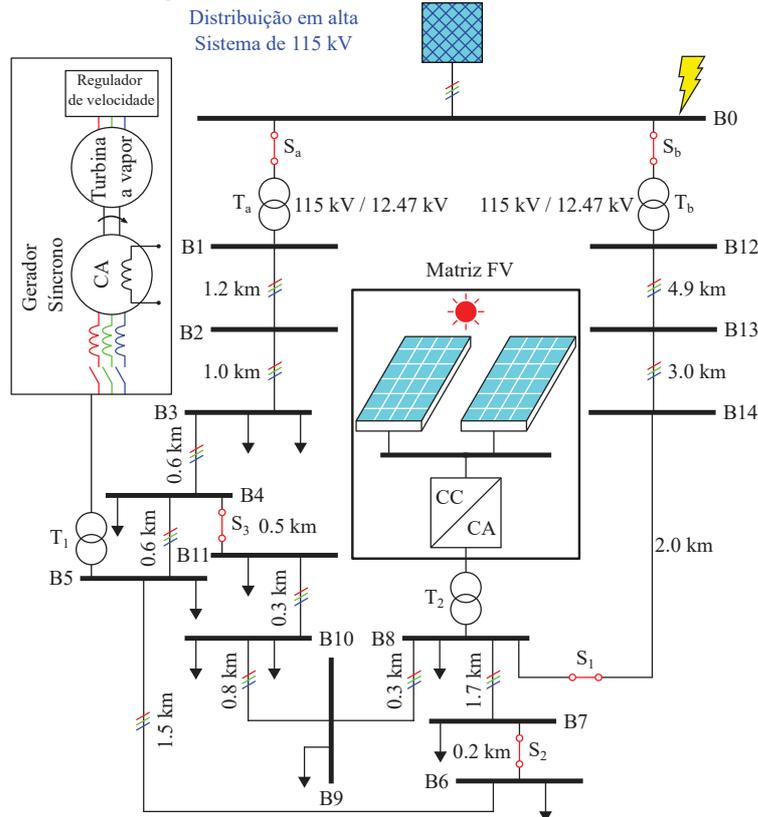
6.2 As GDs adotadas e o modelo de 14 barras para o ilhamento intencional

As simulações realizadas nesta etapa utilizam o modelo de referência CIGRÈ para média tensão de 14 barras, o qual foi descrito por (Hassan Farhangi and Geza Joos, 2019). A Figura 29 apresenta o modelo utilizado, o qual possui flexibilidade operacional para permitir a modelagem da estrutura com o fechamento dos disjuntores S_1 , S_2 e S_3 .

Já os disjuntores S_a e S_b , interconectam o alimentador da distribuidora de energia elétrica, em 115 kV, com as cargas a jusante, sendo rebaixada para média tensão em 12,47 kV por dois transformadores T_a e T_b de 15 MVA, de conexões D1/Yg (delta/estrela aterrado) instalados nas barras 1 e 12, sendo fornecida a demanda de energia elétrica necessária as demais cargas instaladas no sistema.

Na barra 5 é instalada uma central geradora a biomassa, definida pela ANEEL como Minigeração Distribuída (MD), constituída por um Gerador Síncrono (GS) de 6600 V com potência instalada de 5 MVA (MOURA, 2011). Já na barra 8, é instalado outra MD constituída por uma fazenda solar, composta de cinco arranjos com 88 módulos FV cada, com tensão de operação de cada arranjo em 249,85 V, e contabilizando ao todo uma potência instalada de 1,25 MW (SOUZA et al., 2020). Para a conexão das MDs na rede de média tensão de 12,47 kV, são utilizados dois transformadores T_1 e T_2 respectivamente.

Figura 29 – Modelo de 14 barras utilizado.



Fonte: adaptado de Hassan Farhangi and Geza Joos (2019).

6.2.1 A modelagem das cargas

Estudos têm evidenciado a importância de representar cargas com precisão para avaliar a estabilidade de tensão no planejamento e controle do sistema de potência. No entanto, a modelagem de carga é complexa devido aos seus diversos componentes, dependência do clima e informações específicas. O objetivo é desenvolver modelos matemáticos simples que possam aproximar o comportamento da carga (ARIF et al., 2018). De acordo com (ARIF et al., 2018), as cargas em nível de distribuição podem ser modeladas como impedância constante. Além disso, o sistema analisado apresenta problemas de subtensão quando ilhado, tornando as cargas importantes para garantir a estabilidade ao exigir menor potência.

As cargas foram modeladas como impedância constante, pois representam as grandes parcelas em um sistema real (P2781, 2021) (ELGERD, 1982).

$$P + jQ = \frac{RV^2}{R^2 + X^2} + j \frac{XV^2}{R^2 + X^2} \quad (6.1)$$

Substituindo $R/(R^2 + X^2)$ e $X/(R^2 + X^2)$ por K_1 e K_2 , respectivamente, e isolando os termos reais e imaginários, define-se as seguintes equações (ELGERD, 1982):

$$P = K_1 V^2 \quad (6.2)$$

$$Q = K_2 V^2 \quad (6.3)$$

6.3 Detecção do ilhamento

A detecção do ilhamento requer equipamentos e controles adequados para as tomadas de decisões autônomas, como desligamento de algumas cargas em casos de ilhamento não intencional e mudança na estratégia de controle das fontes geradoras para abastecer o maior número de unidades consumidoras em eventos intencionais (ALVES et al., 2023) (MAHAT; CHEN; BAK-JENSEN, 2008). O padrão IEEE 1547 (2018) (IEEE... , 2018) define a detecção do ilhamento, que por sua vez tem o papel importante para garantir a segurança e confiabilidade do sistema elétrico. A detecção pode ser realizada por meio de técnicas passivas (ANUDEEP; VERMA; NAYAK, 2019) ou ativas (GUPTA; BHATIA; JAIN, 2015), ambas importantes e devem ser avaliadas cuidadosamente (NALE; BISWAL, 2017), como mostrado a seguir.

6.3.1 Técnica de detecção ativa

Para esta técnica, uma pequena perturbação é aplicada no terminal do sistema da GD, e a reação resultante é observada. No entanto, essas técnicas podem levar à instabilidade da MR, o que é considerado uma de suas desvantagens (DABBAGHJAMANESH et al., 2020). Como tal, as técnicas ativas são comparativamente mais rápidas, mas podem afetar a qualidade da energia (GUPTA; BHATIA; JAIN, 2015).

6.3.2 Técnica de detecção passiva

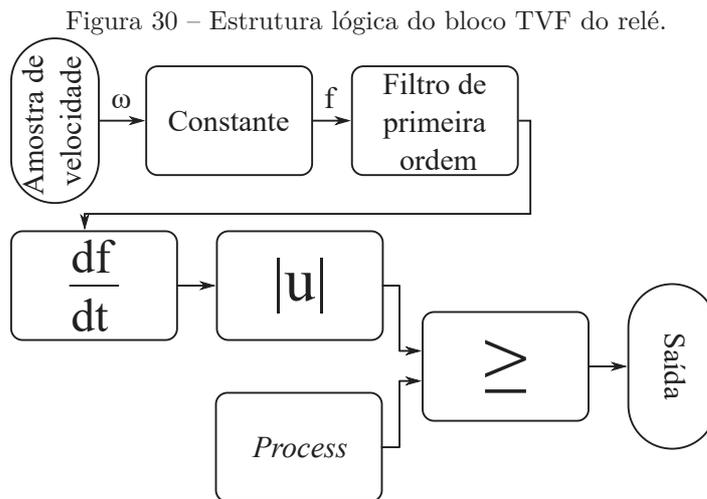
Este método de detecção de ilhamento é baseado em variáveis elétricas, como frequência, corrente e tensão elétrica. O uso combinado de técnicas passivas, como sub/sobrefrequência, sub/sobretensão e relés TVFs, pode ser efetivo na proteção do sistema (KULKARNI; KHEDKAR, 2021). Antes do ilhamento ocorrer, a energia elétrica consumida pela carga da MR é suprida pela GD e alimentador principal, mas no instante do ilhamento, ocorre um desbalanço entre a potência gerada e consumida, devido à perda do alimentador principal, gerando uma mudança na frequência (ANUDEEP; VERMA; NAYAK, 2019). O método de TVF usa uma variação de frequência (df/dt) para identificar um possível ilhamento. O relé TVF monitora a tendência de alteração da mudança de frequência e, caso ultrapasse o pré-ajuste, é realizado a detecção do ilhamento.

6.4 Implementação do relé TVF proposto

O relé utilizado neste trabalho tem como objetivo identificar a TVF em situações de sub e sobrefrequência, bem como atuar para um limite mínimo de tensão de bloqueio. A modelagem do relé foi realizada na plataforma computacional integrada *Simulink* e *Matlab*. O processo de modelagem adotado foi adaptado a partir de (PIARDI et al., 2019) e (MOTTER; MOURINHO; VIEIRA, 2015), e será descrito nas seções a seguir.

6.4.1 Relé de taxa de variação de frequência (TVF)

A Figura 30 mostra a estrutura lógica do relé TVF, que recebe uma amostra em rad/s e converte para Hz usando um bloco de conversão. O sinal é então filtrado com um filtro passa-baixa e diferenciado para obter a taxa de frequência ao longo do tempo, que indica a tendência de mudança da frequência. Obtém-se o módulo com o bloco de valor absoluto. Se o sinal resultante exceder os valores pré-definidos no bloco *Process* para uma ação *pick-up*, o relé envia um sinal de *trip* para detectar o ilhamento.



Fonte: o autor.

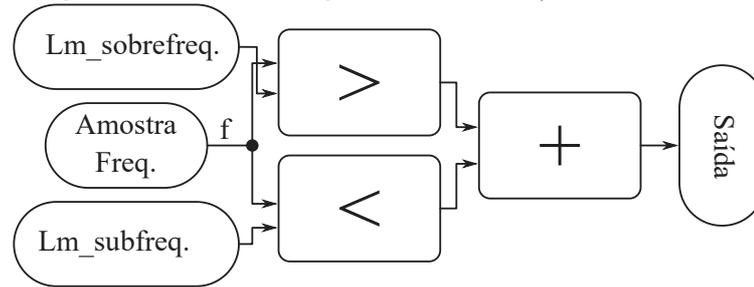
6.4.2 Relé sub/sobre frequência

Este relé verifica a amostra do nível de frequência no barramento e envia um sinal para a estrutura lógica apresentada na Figura 31, que utiliza limites de sub/sobrefrequência para uma possível identificação de ilhamento no sistema.

6.4.3 Tensão de bloqueio

É relevante destacar que apenas uma fase do sistema trifásico é amostrada para a comparação com um valor mínimo pré-ajustado, conforme ilustrado na Figura 32. Em casos em que o nível de tensão amostrado é igual ou superior ao valor de tensão pré-ajustado, o

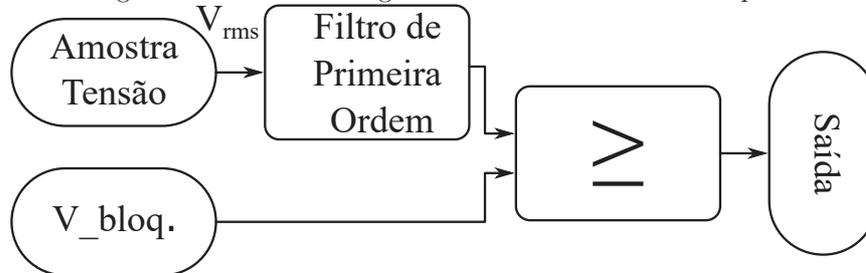
Figura 31 – Estrutura lógica do relé de sub/sobre frequência.



Fonte: o autor.

relé envia um sinal de bloqueio, evitando a ocorrência de detecções de falsos ilhamentos, que podem ser causadas por grandes cargas indutivas aplicadas ao sistema.

Figura 32 – Estrutura lógica do bloco da tensão de bloqueio.



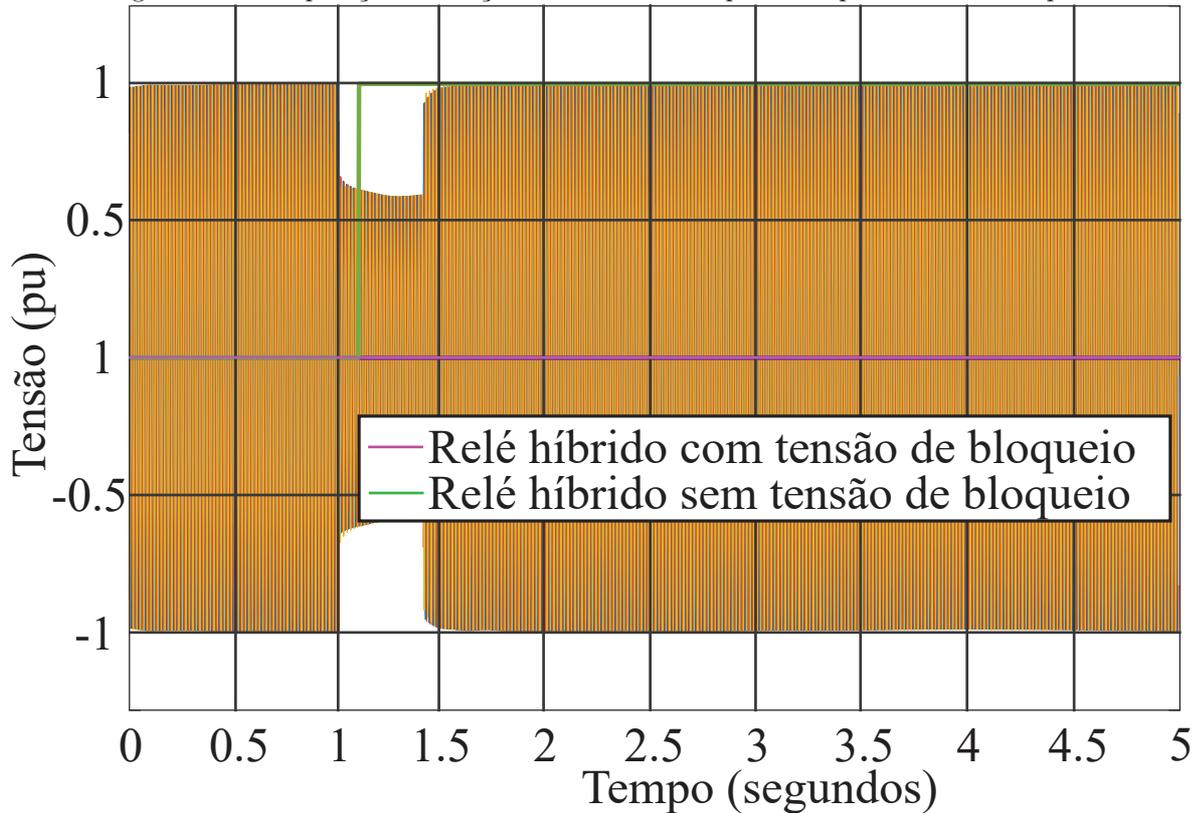
Fonte: o autor.

Na Figura 33, ocorre uma queda de tensão de 0,4 pu no instante de 1 s no GS; o sinal rosa mostra a tensão de bloqueio, não enviando nenhum sinal para alterar o método de controle. Enquanto isso, o sinal verde não tem a função da tensão de bloqueio no relé, e um sinal é enviado; neste caso o falso ilhamento sendo executado. É importante destacar que essa estratégia de controle está de acordo com as variações de tensão de curto prazo (MODULO8, 2016).

6.4.4 Parâmetros pré-ajustados no relé proposto

Adaptado de (MOTTER; VIEIRA, 2019), o relé proposto é sintonizado usando o método de ajuste do ganho. Na Tabela 5 é apresentada as variáveis definidas para as características do relé proposto. Os limites de sub/sobre frequência estabelecidos foram definidos pelo Documento Online Módulo 8 (2021) (MODULO8, 2016), visto que afirma que após uma perturbação na rede de distribuição, a geração deve garantir uma recuperação de frequência de 59,5 a 60,5 Hz em 30 s. Qualquer variação dentro deste intervalo, o relé proposto não altera o modo de controle. Para o sensor de bloqueio de tensão, conforme recomendado pelo Documento Online Módulo 8 (2021) (MODULO8, 2016), o limite é de 0,9 pu, garantindo que o controle não seja afetado em caso de falso ilhamento ou queda de tensão (BOLLEN, 2000). É fundamental esclarecer que as normas brasileiras

Figura 33 – Comparação da função de tensão de bloqueio em queda de tensão típica.



Fonte: o autor.

também atendem a convenções internacionais como EN50160(MASETTI, 2010), IEEE Std. 1159(1159, 2009), IEEE Std. 1250(1250-2018, 2018) e (SIMÕES; FARRET, 2016).

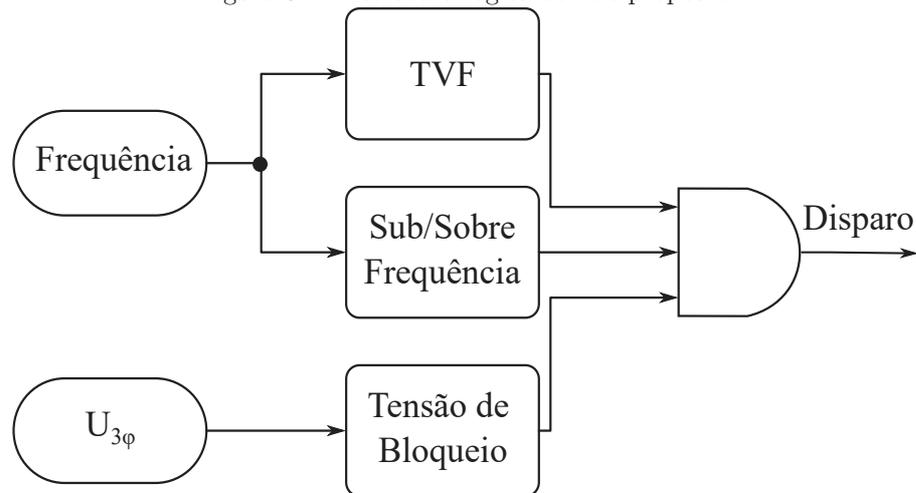
Além disso, caso facilite algum ilhamento, o nível da tensão para as cargas prioritárias também estará de acordo com a norma IEC 60038 (2009) (IEC, 2009). O disparo para o relé proposto será realizado apenas para a condição de nível alto em todos os outros relés, ou seja, saída igual a 1, simultaneamente nas três saídas ilustradas pelas Figuras 30-31-32, combinados e mostrados na Figura 34.

Tabela 5 – Parâmetros Utilizados no relé TVF.

Dados no Relé TVF	
Parâmetros	Ajuste realizado
Taxa de variação da frequência no tempo (Hz/s)	0.55
Limite sobrefrequência (Hz)	60,5
Limite subfrequência (Hz)	59,5
Valor base da tensão de fase (V)	6600
Mínimo valor de tensão de bloqueio (pu)	0,9

Fonte: o autor.

Figura 34 – Estrutura lógica do relé proposto.



Fonte: o autor.

6.5 Modos de controle para a GD

O modelo de controle adotado nesta rede é diferente do padrão convencional, apresentando duas arquiteturas distintas: uma para operação conectada ao alimentador principal e outra para quando ocorre o ilhamento. De acordo com (D. W. Gao, 2015), o comportamento dos GDs em um ambiente ilhado pode ser operado como um controle mestre-escravo. Nesse contexto, a MR deve manter níveis adequados de parâmetros elétricos, garantindo uma operação confiável e com qualidade de energia aceitável.

A Tabela 6 apresenta limites operacionais para a tensão e frequência em regime permanente. Vale ressaltar que a faixa apresentada refere-se a pontos de conexão em que a tensão é entendida como estando entre $1 \text{ kV} < V < 69 \text{ kV}$ (MODULO8, 2016).

Tabela 6 – Limites de Operação dos PRODIST - Módulo 8

Informações da Norma	
Indicador	Limite
Faixa de frequência (Hz)	$59,5 \leq f \leq 60,5$
Tempo máx. fora da faixa de frequência (s)	30
Faixa de tensão adequada (pu)	$0,93 \leq V \leq 1,05$

Caso ocorra o ilhamento, a MD (Minigeração Distribuída) formado por meio do GS é configurado como mestre, e seus controladores de excitação e velocidade são modificados, determinando assim o método de controle como V/f (ALVES et al., 2023). A outra MD formada pela usina FV, interligada por conversores, é definida como escravo. A figura 35 mostra esta estrutura de controle mestre-escravo (D. W. Gao, 2015).

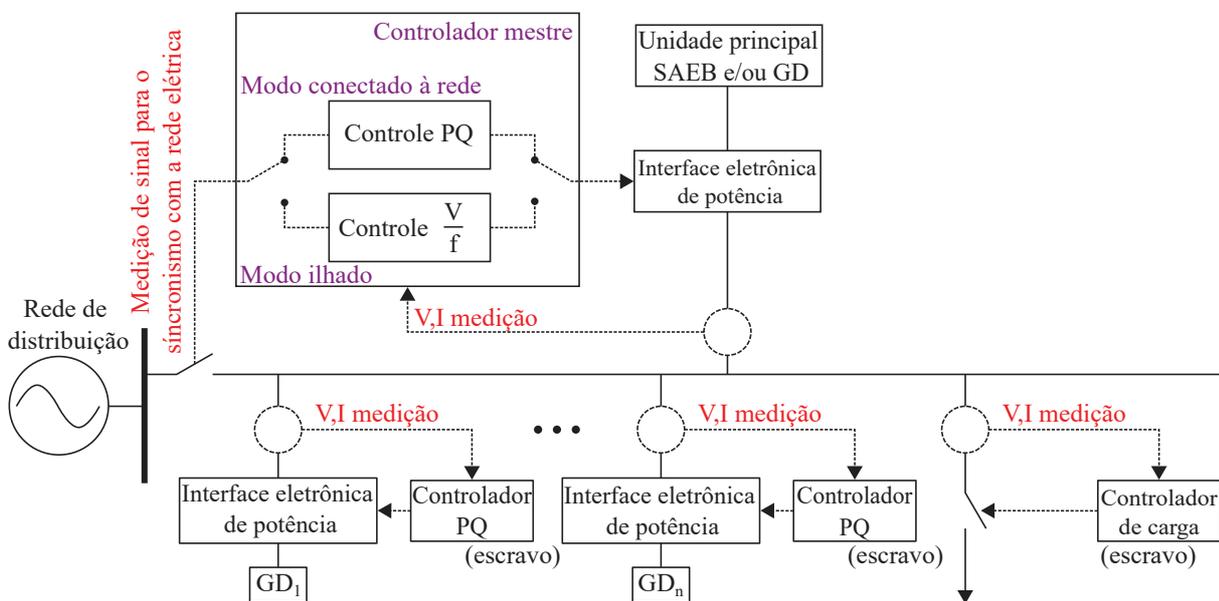
No modo ilhado, a MD construída com o GS passa a ser configurada como mestre e a FV como escravo. O controle do GS é modificado para o controle V/f e passa a fornecer a referência para aos outros geradores, neste caso para o arranjo FV. O regulador de velocidade do GS deve operar de duas maneiras possíveis: *droop* ou isócrono.

6.6 Regulador de velocidade - modo *droop*

O regulador de velocidade do GS permanece no modo *droop* se conectado à rede. A relação entre a potência ativa e a frequência (Figura 36) é descrita (D. W. Gao, 2015):

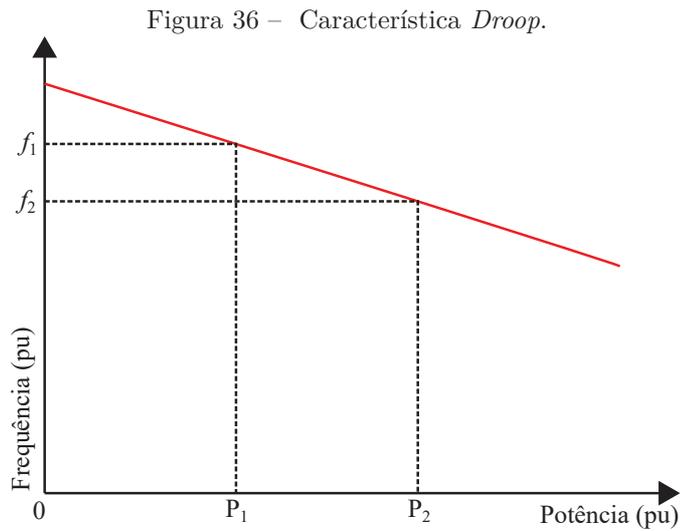
$$\Delta P = P_2 - P_1 = \alpha_p(f_1 - f_2) \quad (6.4)$$

Figura 35 – Modelo típico de uma estrutura de controle mestre-escravo.



Fonte: D. W. Gao (2015).

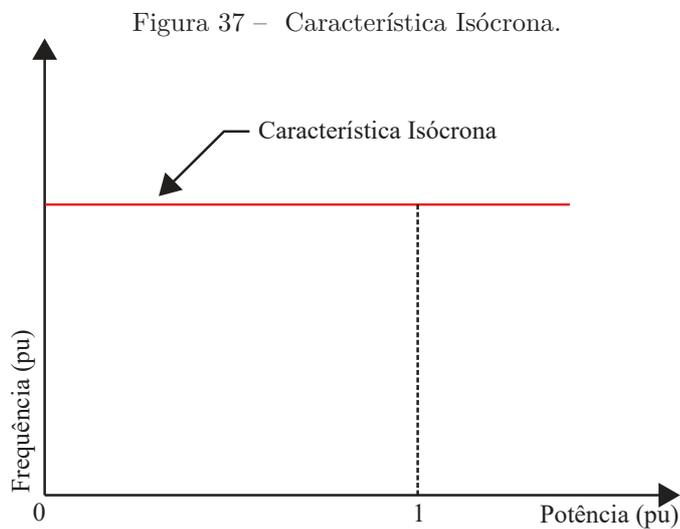
Onde P_1 é a potência ativa do momento 1, P_2 é a potência ativa do momento 2, f_1 é a frequência nos terminais GS do momento 1 e f_2 é a frequência nos terminais GS do momento 2. A grandeza α_p representa a inclinação da reta do *droop* que no Brasil é de 5%.



Fonte: (D. W. Gao, 2015).

6.7 Regulador de velocidade - modo isócrono

Sem o alimentador principal, o modo de controle de velocidade do GS é ajustado para isócrono para atender a demanda em frequência, conforme Figura 37.

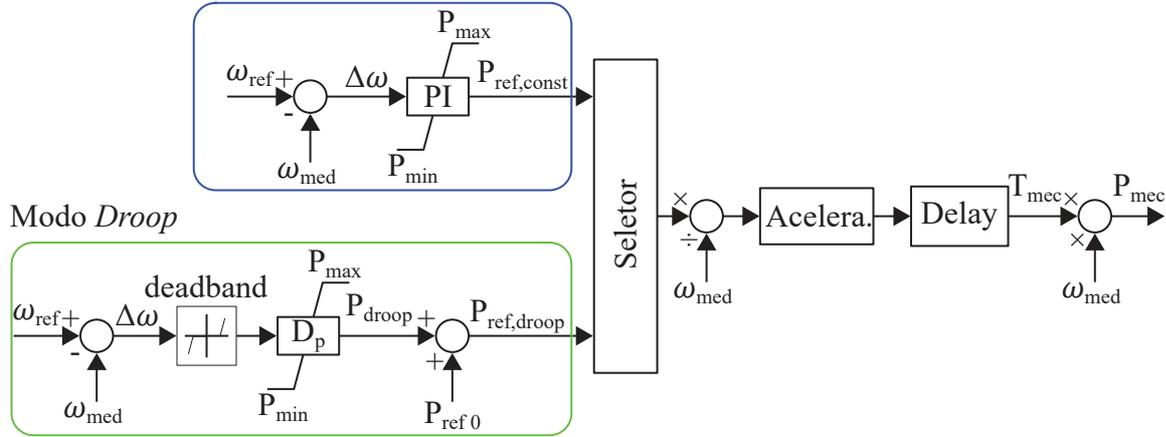


Fonte: D. W. Gao (2015).

O regulador de velocidade com suas duas malhas de controle é apresentado na Figura 38. A malha superior é referente ao modo isócrono que define a frequência, enquanto a malha inferior apresenta o modo *droop*. Depois que o modo apropriado do regulador é selecionado, a potência mecânica é controlada (FARHANGI; JOÓS, 2019).

O controle de excitação também possui modos específicos para cada cenário; Regulador de Fator de Potência/Reativo e o Regulador de Tensão, que será discutido na próxima seção (SILVA et al., 2016).

Figura 38 – Malha de controle do regulador de velocidade usada para o GS.



Fonte: Hassan Farhangi and Geza Joos (2019).

6.8 Regulador de fator de potência/reactivo

O regulador de fator de potência/reactivo tem origem nos motores e GSs, normalmente instalados no barramento de distribuição. A máquina, porém, não pode interferir no nível de tensão do barramento e deve atuar apenas para manter o fator de potência do barramento ao qual está conectada. O controle de tensão aplicado ao campo do enrolamento utiliza um valor de referência ajustável associado ao fator de potência da barra (SILVA et al., 2016) (R. C. Dugan and M. F. McGranaghan and S. Santese and H. W. Beaty, 2002).

Se a potência ativa fornecida pelo alimentador principal mudar, a excitação é ajustada. Conseqüentemente, a potência reativa fornecida é corrigida para manter a relação constante entre as potências no barramento. Como a MD e a rede compartilham as cargas, as potências ativa e reativa podem ser obtidas a partir da diferença entre o consumo da carga e o fornecimento da rede a cada instante ou conforme apresentado pelas equações (SILVA et al., 2016):

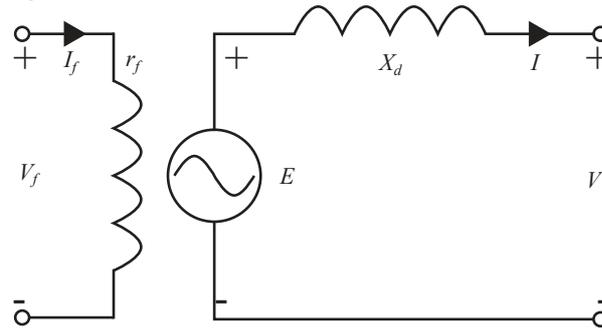
$$P_{MD} = P_{carga} - P_{rede} \quad (6.5)$$

$$Q_{MD} = Q_{carga} - Q_{rede} \quad (6.6)$$

A referência de tensão é obtida considerando o modelo clássico de máquina síncrona. Constitui uma fonte de tensão efetiva E posicionada antes da reatância de eixo direto X_d . A tensão nos terminais da máquina síncrona apresenta a tensão efetiva V e a corrente I . O modelo clássico da síncrona é ilustrado na Figura 39.

O sinal de tensão contínua V_f proveniente da excitatriz alimenta este enrolamento, controlado por uma referência variável. Ou seja, o valor da tensão de referência aplicado ao sistema de controle do campo muda continuamente. Assim, as expressões que modelam

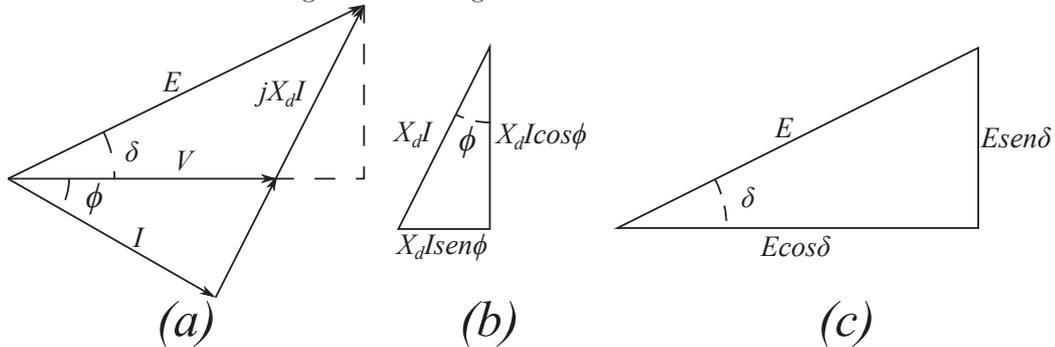
Figura 39 – Modelo Clássico para Máquina Síncrona.



Fonte: Silva et al. (2016).

a tensão de referência foram deduzidas com o auxílio dos diagramas fasoriais mostrados na Figura 40.

Figura 40 – Diagramas derivados dos fasores.



Fonte: Silva et al. (2016).

A partir dos diagramas da Figura 40, as potências (P ativa e Q reativa) fornecidas pelo GS podem ser determinadas por:

$$P = VI \cos(\phi) \quad (6.7)$$

$$Q = VI \sin(\phi) \quad (6.8)$$

onde ϕ é o ângulo de defasagem entre a tensão V e a corrente I e δ é o ângulo de carga ou potência (SILVA et al., 2016). Esta pesquisa tem como referência a máquina de pólos lisos. Assim, as seguintes equações de potência ativa e reativa são adequadas para representar a máquina do tipo turbogerador, onde X_d representa a reatância de eixo direto.

$$P = \frac{EV}{X_d} \sin(\delta) \quad (6.9)$$

$$Q = \frac{EV}{X_d} \cos(\delta) - \frac{V^2}{X_d} \quad (6.10)$$

Isolando os termos $\text{sen}(\delta)$ e $\text{cos}(\delta)$, obtém-se o seguinte:

$$\text{sen}(\delta) = \frac{PX_d}{EV} \quad (6.11)$$

$$\text{cos}(\delta) = \frac{QX_d + V^2}{EV} \quad (6.12)$$

Dividindo a equação 6.11 por 6.12:

$$\text{tg}(\delta) = \frac{\text{sen}(\delta)}{\text{cos}(\delta)} = \frac{PX_d}{QX_d + V^2} \quad (6.13)$$

Além disso, a tangente do ângulo de carga é vista como:

$$\text{tg}(\delta) = \frac{P}{Q + \frac{V^2}{X_d}} \quad (6.14)$$

Finalmente, ao realizar operações algébricas pode-se escrever (SILVA et al., 2016):

$$V = \sqrt{\frac{PX_d - QX_d \text{tg}(\delta)}{\text{tg}(\delta)}} \quad (6.15)$$

Observe que V é o valor de referência do controle de tensão aplicado ao campo do enrolamento, P é a potência ativa fornecida às cargas, Q é a potência reativa fornecida às cargas, X_d é a reatância direta do eixo, δ é o ângulo de carga ou ângulo de potência do GS.

6.9 Regulador de tensão

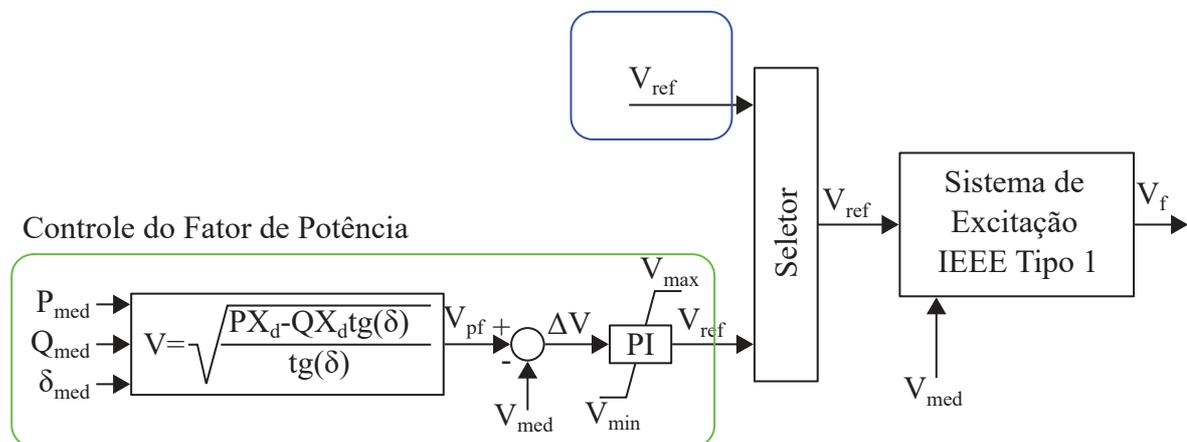
Ao operar no modo regulador de tensão, o controle de excitação ajusta a tensão de saída EFD do campo GS. Esta operação diminui o valor do erro entre a tensão do barramento conectado ao GS e a referência, que é pré-ajustada no *setpoint* do regulador. O sistema de excitação empregado no GS é baseado no IEEE tipo AC1A. A Figura 41 apresenta o *loop* de controle adotado para o SG com dois modos de controle (SILVA et al., 2016). O bloco seletor é usado para definir qual modo de operação é selecionado. Os parâmetros de entrada e saída são apresentados na Tabela 7.

Tabela 7 – Descrição Utilizadas para Entrada e Saída, das Malhas de Controle do GS

Legenda dos termos	Descrição
RPM_1 (modo Volt-VAr)	Regulador de tensão (modo isócrono)
RPM_2 (modo Volt-VAr)	Regulador de Fator de Potência Fixado
V_{ref}	Tensão de Referência para RPM_1 e RPM_2
V_{pf}	Resultado relativo ao fp de RPM_2 , calculado a partir das entradas de P , Q e δ
RPM_1 (modo Volt-Watt)	Regulador de Velocidade modo isócrono
RPM_2 (modo Volt-Watt))	Regulador de Velocidade modo <i>droop</i>

Fonte: Hassan Farhangi and Geza Joos (2019).

Figura 41 – Malha de controle da excitação usada para o GS.
Controle de Tensão



Fonte: Hassan Farhangi and Geza Joos (2019).

6.10 Resumo

Este capítulo abordou em detalhes as modificações realizadas no modelo de 14 barras CIGRÈ para ser simulado em estudos de casos contendo as GDs e cargas em condições do ilhamento intencional. As cargas são modeladas com base em impedância constante, enquanto que as técnicas de detecção de ilhamento e o relé proposto, que engloba TVF, sub/sobrefrequência e bloqueio de tensão, são apresentadas com seus respectivos

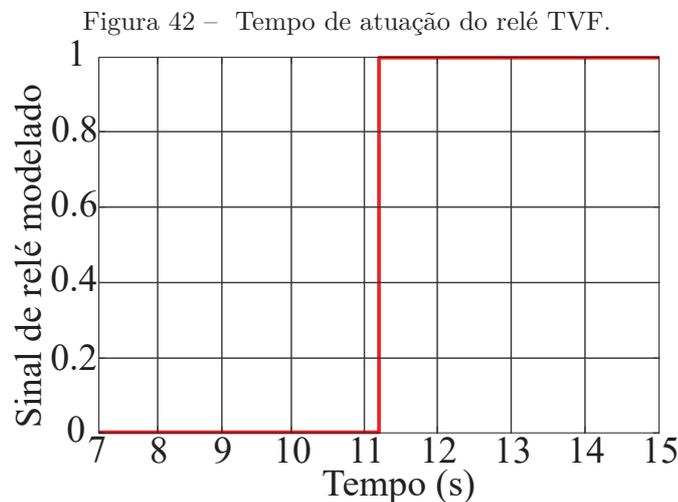
parâmetros. Além disso, os modos de controle aplicados às GDs conectadas na MR da proposta também são apresentados.

7 Resultados e discussões para o ilhamento intencional

Neste capítulo, foram realizados dois estudos de caso com o objetivo de apresentar a contribuição da proposta. No primeiro estudo de caso, foi executado um ilhamento intencional através do acionamento do relé proposto, alterando o modo de controle do grupo gerador. É importante mencionar que os reguladores do GS, antes das alterações nos modos de controle estão ajustados em *droop* e fator de potência. Já no segundo estudo de caso, foi inserido uma grande carga no sistema ilhado para avaliar a eficácia da MR formada. As simulações foram executadas em tempo discreto através do *software Simulink MATLAB R2019b*, utilizando um tempo de amostragem de $50 \mu s$. Além disso, para a criação das imagens vetorizadas, foi utilizado o *CorelDRAW Graphics Suite X8*.

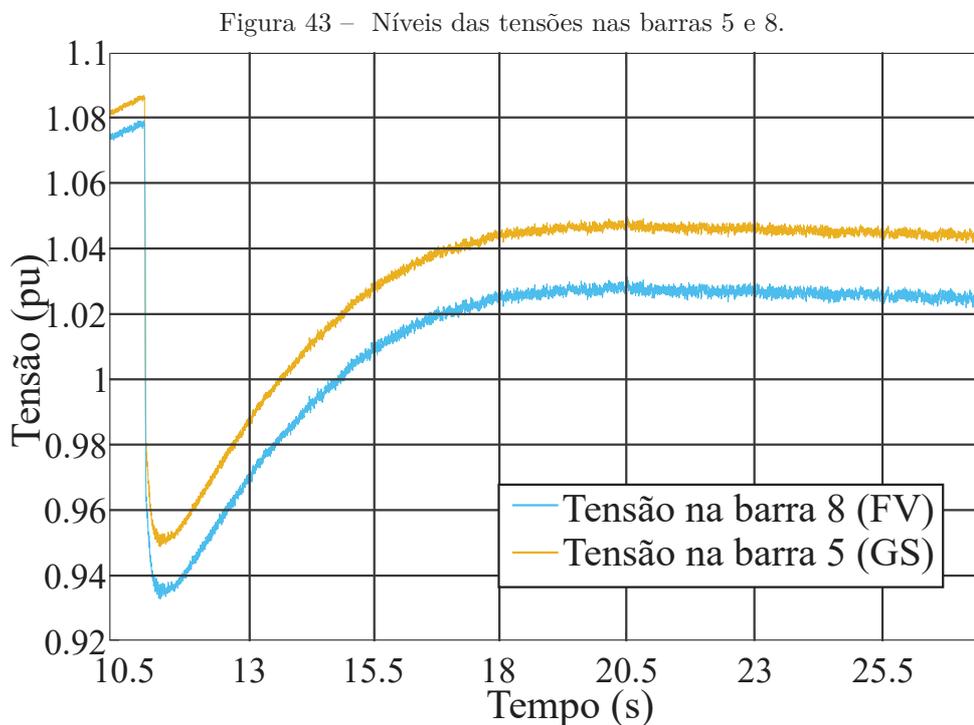
7.1 Estudo de caso 1: Sem o alimentador principal com o ilhamento intencional

O primeiro estudo de caso apresenta a simulação de uma falta na barra 0, causando uma queda de tensão instantânea (R. C. Dugan and M. F. McGranaghan and S. Santese and H. W. Beaty, 2002) por $50,1 ms$ (cerca de três ciclos). Os interruptores S_a e S_b são acionados, desconectando o sistema de alimentação principal de $115 kV$ da rede em $10,5 s$, resultando em uma MR ilhada. O relé híbrido identifica o ilhamento após $0,7 s$ e gera o sinal mostrado na Figura 42, modificando os modos de controle nos reguladores de excitação e velocidade do GS na barra 5.



Fonte: o autor.

Na Figura 43, é apresentado os níveis de tensão nas barras 5 e 8 que se referem ao GS e à usina FV, respectivamente, em 10,5 a 25 s. A recuperação e estabilização da tensão nas barras 5 e 8 atingiram valores de 1,047 e 1,027 pu com duração de 8,5 s e estabilizaram em 19 s. A Tabela 8 apresenta as cargas prioritárias de potência pelo MD quando o MR foi formado por ilhamento intencional.



Fonte: o autor.

A Tabela 9 mostra os níveis de tensões em ambos estudos de caso. O GS e o arranjo FV são suficientes para garantir a tensão nominal para as cargas prioritárias da MR formada. As tensões das cargas prioritárias estão na faixa adequada, conforme regulamento do Documento Online Módulo 8 (2021) (MODULO8, 2016). Enquanto isso, as barras 1, 2, 12, 13 e 14 permanecem abaixo do limite operacional. Estas, porém, não contém cargas prioritárias para serem atendidas em uma eventual aplicação prática de ilhamento intencional.

Tabela 8 – Nível de Potência dos Barramentos Contendo as Cargas Alimentadas no Ilhamento

Dados das Cargas				
Carga Trifásica	Nº da Barra	Potência Ativa (kW)	Potência Reativa (kVAr)	
Conjunto A	3	276,45	69,29	
Conjunto B	3	225,25	139,60	
Conjunto C	4	431,70	108,18	
Conjunto D	5	727,5	182,33	
Conjunto E	6	548,05	137,35	
Conjunto F	7	76,5	47,41	
Conjunto G	8	586,85	147,08	
Conjunto H	9	573,75	355,58	
Conjunto I	10	475,30	119,12	
Conjunto J	10	68,00	42,14	
Conjunto K	11	329,80	82,66	
		4319,15	1430,74	

Fonte: o autor.

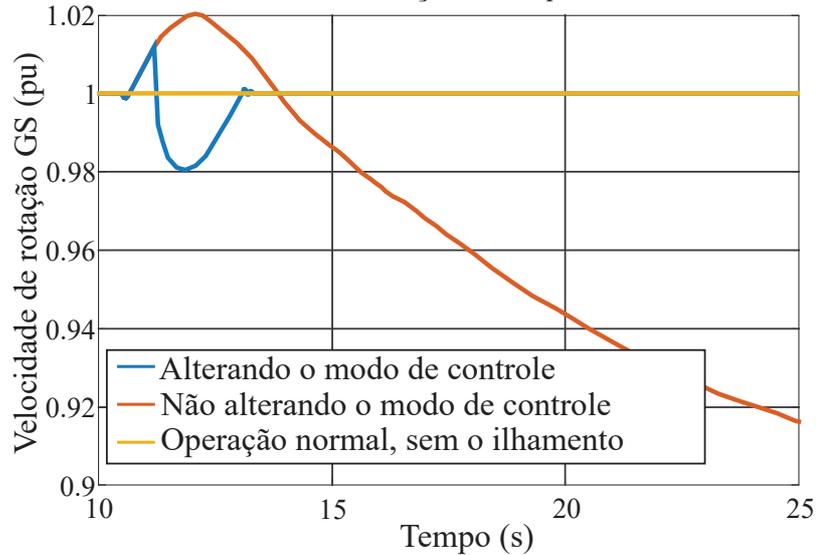
Tabela 9 – Resultados para os níveis de tensão nos estudos realizados após o ilhamento

	Estudo de caso 1 (pu)	Estudo de caso 2 (pu)
Barra 1	0,9	0,8988
Barra 2	0,9247	0,9235
Barra 3	0,9453	0,9441
Barra 4	0,9585	0,9573
Barra 5	0,9784	0,9775
Barra 6	0,963	0,9621
Barra 7	0,9607	0,9599
Barra 8	0,9456	0,9448
Barra 9	0,9482	0,9472
Barra 10	0,9552	0,9541
Barra 11	0,9585	0,9573
Barra 12	0,7747	0,7739
Barra 13	0,8587	0,8579
Barra 14	0,9106	0,9098

Fonte: o autor.

A velocidade de rotação ω_m do GS é mostrada na Figura 44 em três eventos; operação normal sem a falta, e ilhamento com e sem alterações do modo de controle. Após a interrupção da velocidade devido aos disjuntores S_a e S_b , a frequência medida retorna para 60,09 Hz em 3 s (curva azul), completando a mudança de *droop* para isócrono no regulador de velocidade. A curva vermelha mostra o que ocorre sem nenhuma alteração no controlador de velocidade, não atingindo os níveis aceitáveis pelo Documento Online Módulo 8 (2021)(MODULO8, 2016). Por fim, a curva amarela corresponde à operação normal sem ilhamento.

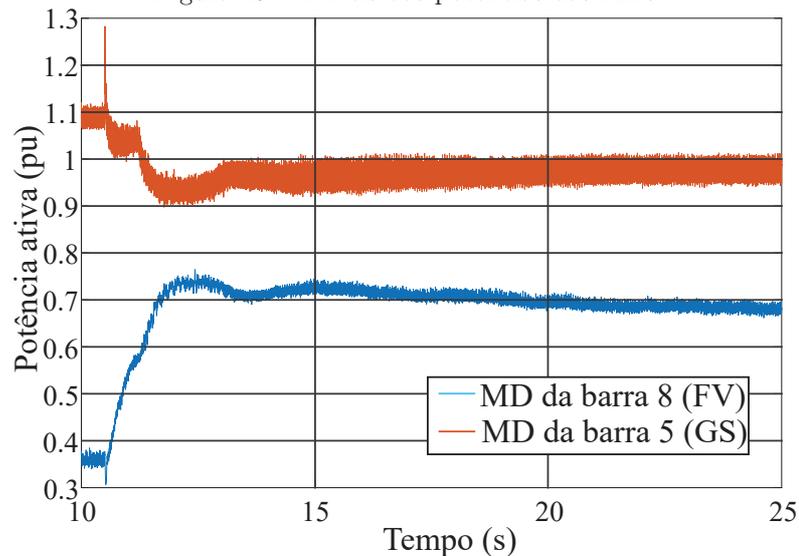
Figura 44 – Valores da velocidade de rotação do GS para os três modos de controle.



Fonte: o autor.

A Figura 45 apresenta os resultados da potência ativa em pu fornecidos pelo GS e o gerador FV durante o período de ilhamento. Após uma pequena perturbação causada pela abertura dos disjuntores S_a e S_b , o GS se estabiliza devido a alteração da configuração de seus controladores como mestre, fornecendo assim uma potência ativa da ordem de 0,97 pu no instante de 15 s com o ilhamento intencional. O gerador FV, configurado como escravo se estabiliza com 0,69 pu de potência ativa no instante de 23 s de ilhamento.

Figura 45 – Níveis das potências das MDs.

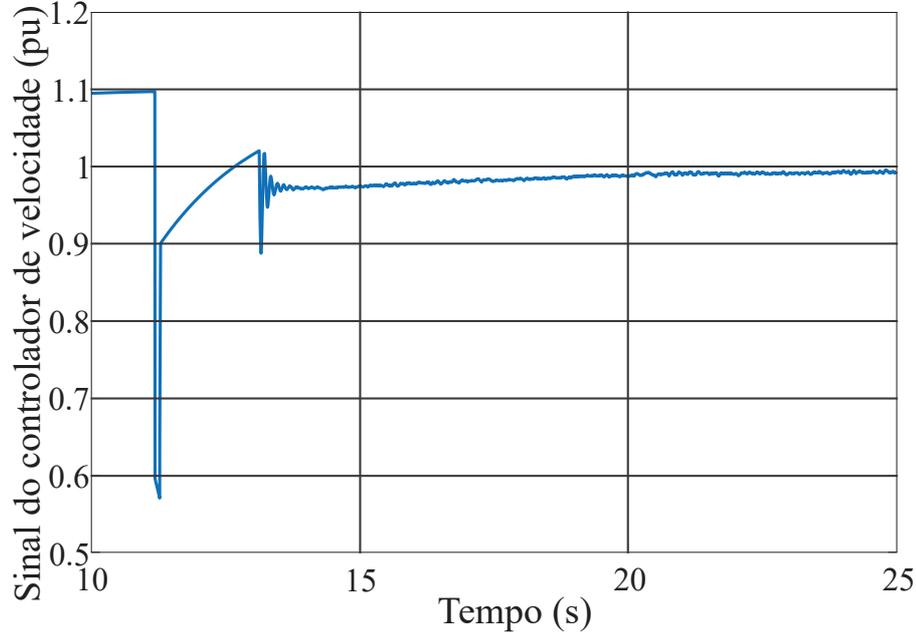


Fonte: o autor.

A Figura 46 apresenta o sinal do regulador de velocidade do GS, para manter o fornecimento da demanda de carga. Este regulador de velocidade manteve-se estável até

11,25 s, instante que o sinal de controle é perdido por um curto período de tempo causado pela alteração do modo de controle. A recuperação e estabilização da frequência leva 3,0 s.

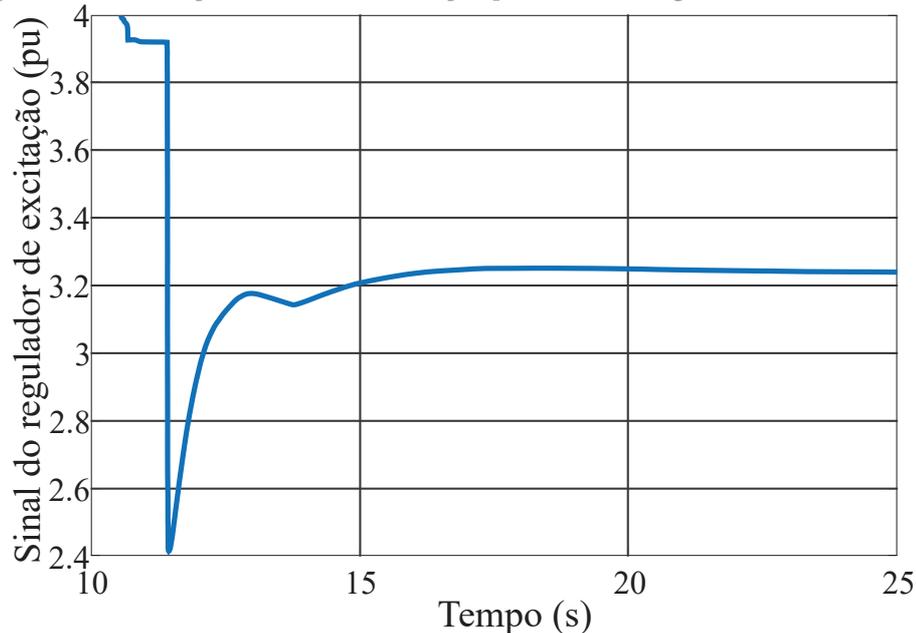
Figura 46 – Alteração do sinal do regulador de velocidade para o modo isócrono do GS.



Fonte: o autor.

A Figura 47 mostra o sinal da excitação com a alteração para o modo de regulador de tensão do GS, para mantê-lo dentro dos limites operacionais estabelecidos pelo Documento Online Módulo 8 (2021) (MODULO8, 2016). Logo após a falta, o sinal da excitação é estabilizado ao longo de 8,5 s no instante de 19 s.

Figura 47 – Alteração do sinal de excitação para o modo regulador de tensão do GS.

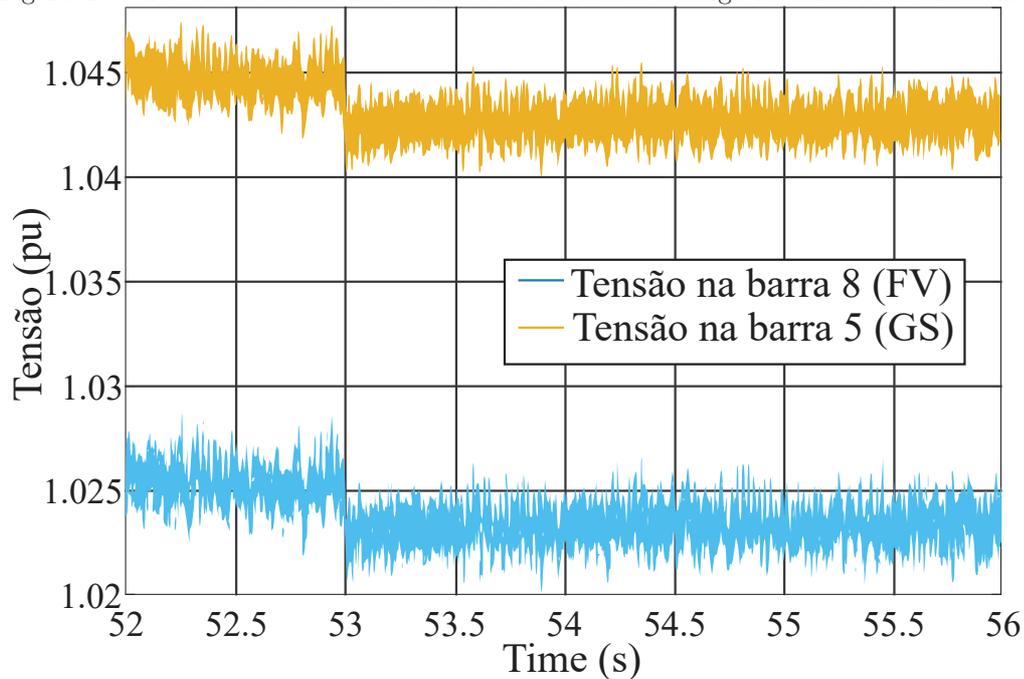


Fonte: o autor.

7.2 Estudo de caso 2: Operação em modo ilhado da MR

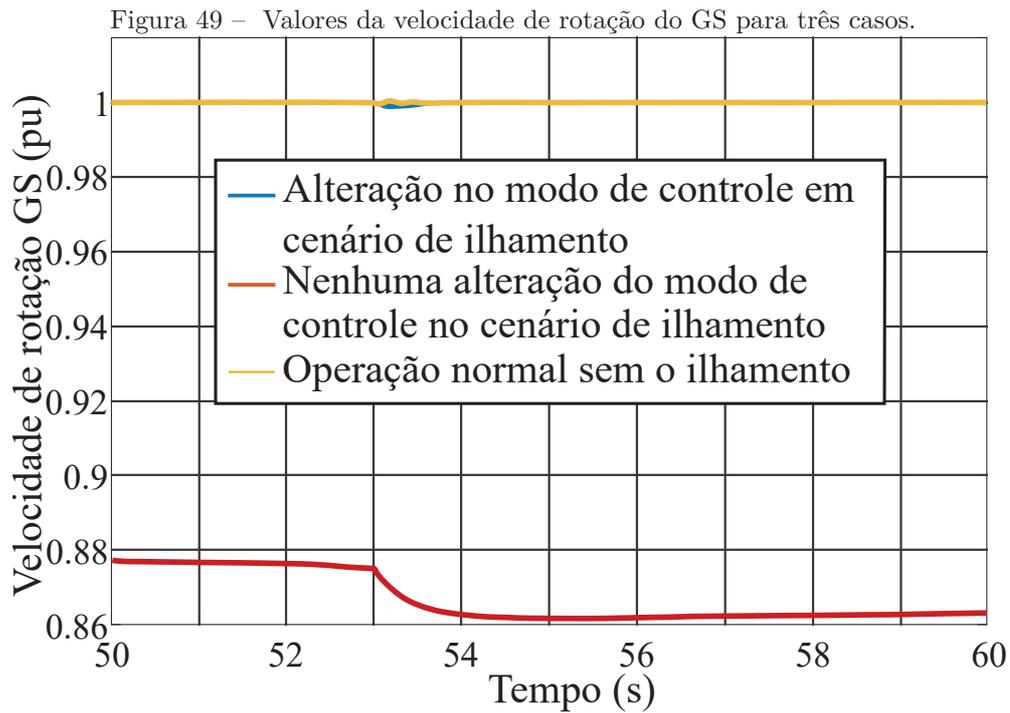
Com o propósito de verificar a eficácia dos ajustes realizados no sistema para operação em modo ilhado da MR, foi seguido um segundo estudo de caso. Neste cenário, uma grande carga com impedância constante aterrada em estrela de 432 kW e 110 kVAr foi adicionada na barra 4 após o ilhamento, em um tempo de 53 s. O objetivo deste teste foi validar a capacidade dos MDs em fornecer a demanda de carga da ilha formada, manter altos níveis de continuidade de serviço, e garantir o atendimento das cargas prioritárias. A tensão se estabiliza em torno de 1,043 pu e 1,023 pu nas barras 5 e 8 respectivamente, como mostra a Figura 48.

Figura 48 – Níveis de tensão nas barras 5 e 8 ao inserir a carga no cenário de ilhamento.



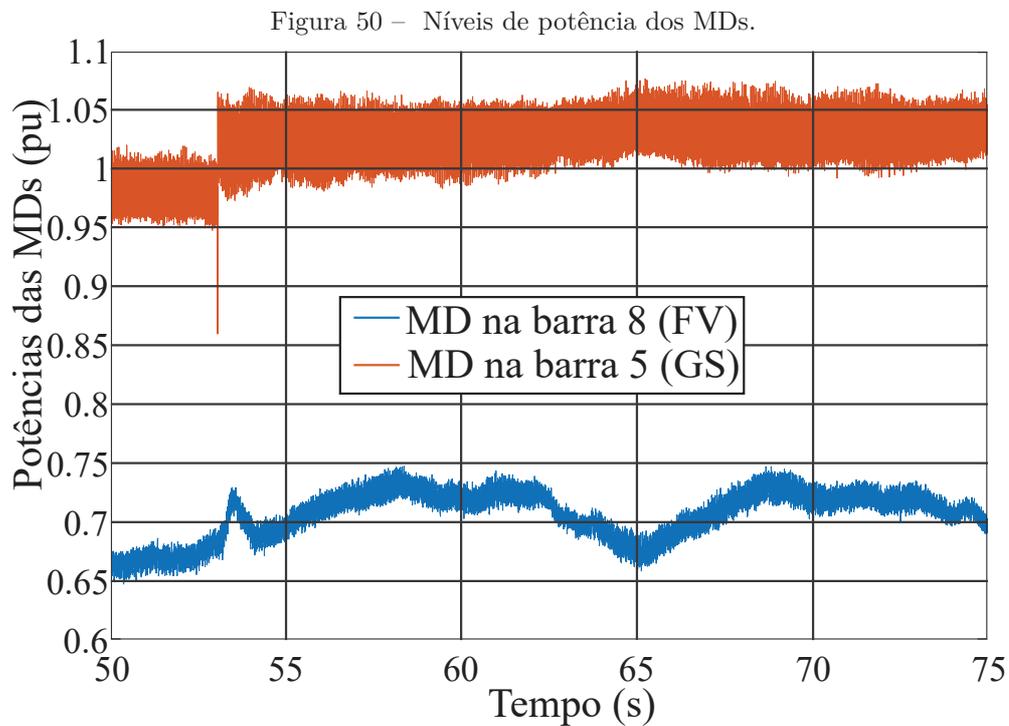
Fonte: o autor.

Os resultados foram apresentados na Tabela 9, na segunda coluna, intitulado como **estudo de caso 2**. Confirma-se que os resultados dos níveis de tensão adequados estão dentro dos limites estabelecidos em (MODULO8, 2016). A demanda total atendida pelos MDs, notadamente, é de 4.751,15 kW e 1.540,74 kVAr. A Figura 49 mostra a mesma analogia feita no primeiro estudo de caso; para as três situações, com uma velocidade do rotor ω_m , a entrada da carga, em 53 s, ocorre uma pequena oscilação e estabilização, e a frequência MR é 59,99 Hz.



Fonte: o autor.

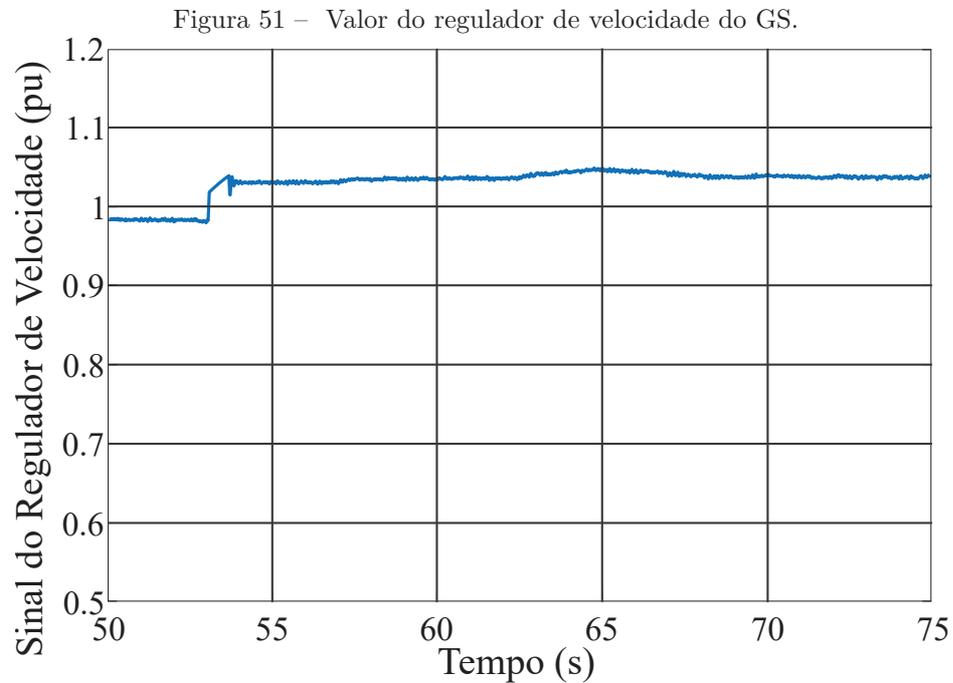
Na Figura 50, os níveis de potência ativa são mostrados para as MDs. Ao inserir as cargas aos 53 s, há um viés de aumentar a demanda de potência ativa pelo GS para reabastecer o sistema.



Fonte: o autor.

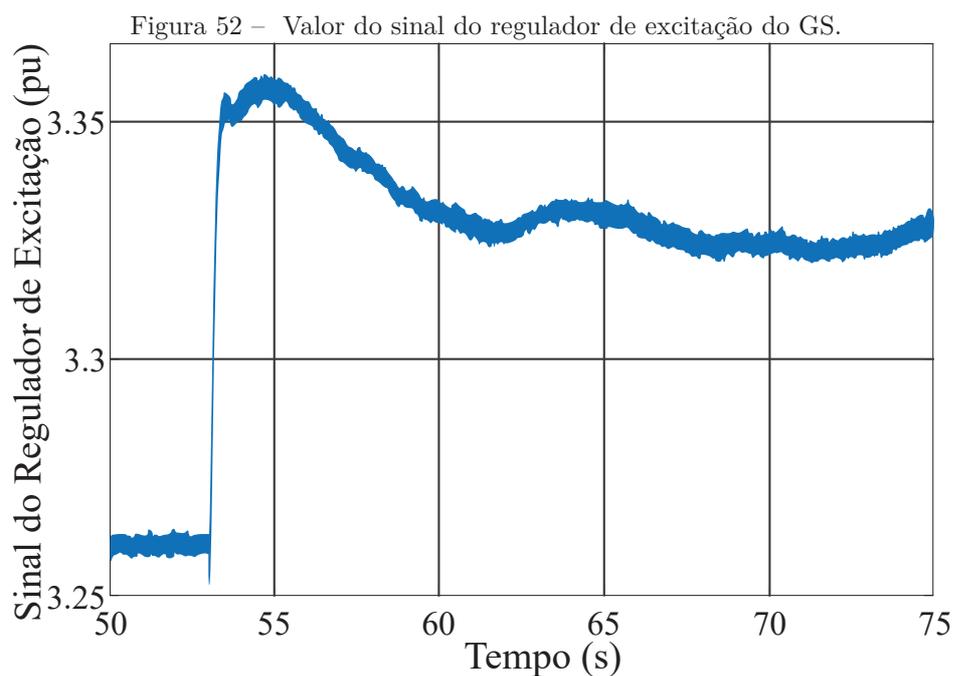
A Figura 51 apresenta o valor do sinal do regulador de velocidade do GS. Ao inserir

as cargas aos 53 s, ocorre um aumento no sinal do regulador de velocidade, para manter o fornecimento de carga e a frequência da rede, conforme apresentado no Documento (MODULO8, 2016).



Fonte: o autor.

Outro resultado relevante é visto na Figura 52; o regulador de excitação aumenta seu sinal, que tende ao equilíbrio na marca de 73 segundos.



Fonte: o autor.

7.3 Resumo

Neste capítulo, foram tratados dois estudos de caso com o objetivo de demonstrar a contribuição da proposta. O primeiro estudo de caso envolveu a realização de um ilhamento intencional através do acionamento do relé desenvolvido, em uma operação ilhada. O relé detectou o ilhamento e modificou os modos de controle dos geradores, garantindo a estabilidade do sistema. No segundo estudo de caso, foi inserida uma grande carga no sistema ilhado para avaliar a eficácia da ilha formada. A simulação foi realizada utilizando o *software Simulink MATLAB R2019b* em tempo discreto, com um tempo de $50 \mu s$. Os resultados indicaram que os sistemas de geração distribuídos foram capazes de atender as demandas das cargas no ilhamento formado e mantendo a estabilidade operacional, garantindo a qualidade no fornecimento de energia para as cargas prioritárias no ilhamento. As simulações apreciaram que os controladores ajustados de acordo com a proposta foram eficientes na gestão do ilhamento formado.

8 Conclusões

O objetivo principal da pesquisa foi desenvolver uma metodologia de SGE para MR conectada à rede principal, que combinasse uma rede neural autorregressiva não linear para previsões das variáveis e com algoritmos de LN para tomar decisões de compra ou venda de energia elétrica do alimentador principal. Esses algoritmos foram escolhidos devido à dinâmica das variáveis envolvidas na MR, sendo necessário atualizar o modelo a cada passo de integração para uma nova tomada de decisão.

Com base na investigação realizada, concluiu-se que o SGE dentro de uma estrutura da MR com a utilização de IA é uma abordagem adequada para a diminuição de custos. A revisão da literatura gerou diretrizes e sugestões para o desenvolvimento da metodologia do SGE.

Nesta Tese foi criada uma modelagem computacional de MR desenvolvida para testar estratégias de gerenciamento de energia implementada em *MATLAB/Simulink*. Para o SGE a plataforma foi adaptada para construir uma MR conectada à rede, composta por um sistema FV, cargas estáticas/variáveis e uma bateria sem incluir o modelo de degradação. Além disso, foi simulado por meio do método de resolução fasorial, para aumentar a velocidade de simulação e incluir um nível de detalhamento suficiente para uma melhor análise. Essa configuração no modelo suporta apenas o modo de operação conectado à rede. Na outra etapa da pesquisa considerou algumas modificações nas GDs para também suportar o modo ilhado.

Foi desenvolvido na plataforma de simulação de MR duas estratégias de gerenciamento de energia, que consistem em algoritmos combinando o modelo autorregressivo não linear com a LN para tomar decisões sobre a compra ou venda de energia elétrica, além de uma estratégia heurística para fins de comparação. O algoritmo desenvolvido propôs as variáveis do sistema, como potência gerada FV, demanda de cargas e preços de eletricidade, para decidir a operação da MR através da LN. Vale ressaltar que a degradação da bateria foge do escopo desta pesquisa e não foi considerada. Esses algoritmos podem ser adaptados e aprimorados para serem utilizados em outras MRs.

Foram realizados estudos de caso extensivos para avaliar o desempenho da proposta durante um período de simulação de 24 horas, utilizando dados FV e cargas do *software Mathworks* e perfis de preços de eletricidade da *Nordpool*. Em todos os cenários, os algoritmos propostos com IA conseguiram reduzir o custo diário de energia da rede principal, melhorando a sustentabilidade da MR em comparação com a utilização do algoritmo heurístico.

Vale ressaltar que, diferentemente do algoritmo proposto, o heurístico finalizou o seu período de simulação com o EDC no seu valor máximo 80% (em comparação ao

proposto, em torno de 37%). Sendo assim, para trabalhos futuros é interessante aumentar o período de simulação em um mês completo, para verificar os resultados de um prazo maior.

A outra etapa da pesquisa se refere ao objetivo secundário, que analisa um método de controle V/f para situações de ilhamento intencional, utilizando outras GDs e uma técnica de detecção passiva de ilhamento. O relé proposto foi ajustado de acordo com as diretrizes da norma IEEE 1547 e superou todas as expectativas durante os testes de detecção de ilhamento. Quando o relé é acionado, os reguladores de excitação e velocidade do GS são ajustados para manter a tensão e a frequência em níveis adequados à MR, seguindo os requisitos dos Módulos 3 e 8 dos PRODIST. Além disso, as funções mestre-escravo das GDs asseguram o fornecimento de energia elétrica com qualidade para as cargas prioritárias.

Com o objetivo de validar a confiabilidade, continuidade e flexibilidade da proposta em face de possíveis problemas de fornecimento de energia elétrica pela distribuidora local, foi realizada a conexão de uma grande carga durante o período de estabilização da tensão e frequência do ilhamento. O estudo de caso comprovou que, mesmo com o aumento do consumo, as GDs foram capazes de manter os níveis de tensão e frequência dentro dos valores aceitáveis para atender às demandas.

A partir do que foi exposto nos parágrafos anteriores, é possível concluir que esta Tese alcançou tanto seu objetivo principal quanto o secundário, isto é, a concepção de um SGE eficaz para uma MR conectada à rede principal, abordando desafios de cenários com dias ensolarados e nublados por meio de um modelo estrutural de previsões, bem como uma sugestão para a implementação de MRs em caso de ilhamentos intencionais.

8.1 Orientações e recomendações para o desenvolvimento de aplicações práticas futuras

Analisando os resultados implementados ao longo deste Tese, bem como as estratégias de controle utilizadas para o SGE e o ilhamento intencional, podem-se destacar recomendações e sugestões das pesquisas futuras para aplicações práticas:

- Adotar os dados para o treinamento das redes, conforme as variações sazonais;
- Para o treinamento da RNA de previsão FV de céu claro, sempre utilizar outra curva referente aos dias anteriores de céu claro;
- Para o treinamento da RNA de previsão FV de céu nublado, sempre utilizar outra curva referente aos dias anteriores de céu nublado;

- Para o treinamento da RNA de previsão de carga, considerar uma curva de carga de um dia de semana anterior para uma aplicação prática de um dia de semana, e uma curva anterior de carga referente aos finais de semana/feriados para aplicação prática de um dia de finais de semana/feriados.
- Realizar uma simulação considerando um mês inteiro, para verificar os resultados do Custo Acumulado da Rede e do Uso Acumulado da Rede, referente a um maior prazo de avaliação, para aproximar de uma conclusão mais precisa nos resultados, pelo fato da diferença nos níveis finais de EDC da bateria entre os métodos proposto e o heurístico;
- Para um prazo de simulação maior, deve ser considerado a degradação das baterias;
- Realizar uma avaliação das tensões mais detalhada para a proposta do SGE;
- Verificar a implantação da proposta de identificação e operação no ilhamento intencional para cenários de MRs diferentes e/ou para baixos níveis de carregamentos após perder o alimentador principal.

Referências

1159, I. S. *Recommended Practice for Monitoring Electric Power Quality*. [S.l.]: IEEE Std New York, 2009. Citado na página 77.

1250-2018, I. S. *IEEE Guide for Identifying and Improving Voltage Quality in Power Systems*. [S.l.]: IEEE New York, NY, USA, 2018. Citado na página 77.

AHMED, A.; KHALID, M. A nonlinear autoregressive neural network model for short-term wind forecasting. In: *2017 9th IEEE-GCC Conference and Exhibition (GCCCE)*. [S.l.: s.n.], 2017. p. 1–9. Doi: 10.1109/IEEEGCC.2017.8447983. Citado 2 vezes nas páginas 33 e 40.

ALIBERTI, A. et al. A multi-patient data-driven approach to blood glucose prediction. *IEEE Access*, v. 7, p. 69311–69325, 2019. Doi: 10.1109/ACCESS.2019.2919184. Citado na página 33.

ALVES, G. H. et al. Proposal of a master–slave control for an isolated microgrid after an intentional islanding. *Journal of Control, Automation and Electrical Systems*, Springer, p. 1–12, 2023. Citado 6 vezes nas páginas 29, 34, 38, 46, 75 e 79.

ALVES, G. H. et al. Avaliação operacional de microrrede mediante ilhamento intencional. In: *2021 XIV Conferência Brasileira sobre Qualidade da Energia Elétrica (CBQEE)*. [S.l.: s.n.], 2021. Doi: 10.17648/cbqee-2021-130597. Citado na página 39.

ALVES, G. H. et al. Battery storage systems control strategies with intelligent algorithms in microgrids with dynamic pricing. *Energies, MDPI*, 2023. Citado na página 31.

ALVES, G. H. et al. Análise e avaliação operacional da metodologia de controle v/f aplicada em situações de ilhamento intencional. In: *2021 14th IEEE International Conference on Industry Applications (INDUSCON)*. [S.l.: s.n.], 2021. p. 567–574. Doi: 10.1109/INDUSCON51756.2021.9529376. Citado 3 vezes nas páginas 33, 34 e 39.

ALWAKEEL, M.; SHAABAN, Z. Face recognition based on haar wavelet transform and principal component analysis via levenberg-marquardt backpropagation neural network. *European Journal of Scientific Research*, v. 42, n. 1, p. 25–31, 2010. Citado na página 55.

ANSEÁN, D. et al. Lithium-ion battery degradation indicators via incremental capacity analysis. *IEEE Transactions on Industry Applications*, v. 55, n. 3, p. 2992–3002, 2019. Doi: 10.1109/TIA.2019.2891213. Citado na página 32.

ANUDEEP, B.; VERMA, A.; NAYAK, P. K. Comparative assessment of passive islanding detection techniques for distributed generations. In: NATH, V.; MANDAL, J. K. (Ed.). *Proceedings of the Third International Conference on Microelectronics, Computing and Communication Systems*. Singapore: Springer Singapore, 2019. p. 35–49. ISBN 978-981-13-7091-5. Doi: 10.1007/978-981-13-7091-5₄. Citado na página 75.

ARCOS-AVILES, D. et al. An energy management system design using fuzzy logic control: Smoothing the grid power profile of a residential electro-thermal microgrid. *IEEE Access*, v. 9, p. 25172–25188, 2021. Doi: 10.1109/ACCESS.2021.3056454. Citado na página 33.

ARIF, A. et al. Load modeling—a review. *IEEE Transactions on Smart Grid*, v. 9, n. 6, p. 5986–5999, 2018. Doi: 10.1109/TSG.2017.2700436. Citado na página 74.

BATTERYUNIVERSITY.COM. *How to prolong lithium-based batteries*. www.batteryuniversity.com, 2003. Disponível em: <http://batteryuniversity.com/learn/article/how_to_prolong_lithium_based_batteries>. Acesso em: 02 jun. 2021. Citado na página 61.

BEHERA, M. K.; SAIKIA, L. C. A novel spontaneous control for autonomous microgrid vsc system using bpf droop and improved hysteresis band control scheme. *Electric Power Systems Research*, v. 220, p. 109262, 2023. ISSN 0378-7796. Doi: 10.1016/j.epsr.2023.109262. Citado na página 43.

BENRHMACH, G. et al. Nonlinear autoregressive neural network and extended kalman filters for prediction of financial time series. *Journal of Applied Mathematics*, Hindawi Limited, v. 2020, p. 1–6, 2020. Doi: 10.1155/2020/5057801. Citado na página 55.

BIDRAM, A.; DAVOUDI, A. Hierarchical structure of microgrids control system. *IEEE Transactions on Smart Grid*, v. 3, n. 4, p. 1963–1976, 2012. Doi: 10.1109/TSG.2012.2197425. Citado 2 vezes nas páginas 40 e 41.

BOLLEN, M. H. Understanding power quality problems. In: *Voltage sags and Interruptions*. [S.l.]: IEEE press Piscataway, NJ, USA, 2000. Citado na página 77.

BORALESSA, M. A. K. S. et al. Effect of renewable energy forecasting error on model predictive control based microgrid energy management system. In: *2022 IEEE IAS Global Conference on Emerging Technologies (GlobConET)*. [S.l.: s.n.], 2022. p. 959–962. Doi: 10.1109/GlobConET53749.2022.9872520. Citado na página 31.

BORDONS, C.; GARCIA-TORRES, F.; RIDAO, M. A. *Model predictive control of microgrids*. [S.l.]: Springer, 2020. v. 358. Doi: 10.1007/978-3-030-24570-2. Citado 3 vezes nas páginas 32, 39 e 43.

BUCHMANN, R. *Harmonic sharing in microgrid applications. modeling, developing and evaluating a microgrid control system with harmonic sharing capability*. 53 p. Tese (Doutorado) — Norwegian University of Science and Technology, 2018. Citado na página 38.

CABRERA-TOBAR, A. et al. A review of the optimization and control techniques in the presence of uncertainties for the energy management of microgrids. *Energies*, Multidisciplinary Digital Publishing Institute, v. 15, n. 23, p. 9114, 2022. Citado na página 32.

CHALAH, S. et al. Microgrid energy management strategy based on mas. In: *2022 3rd International Conference on Human-Centric Smart Environments for Health and Well-being (IHSH)*. [S.l.: s.n.], 2022. p. 1–6. Doi: 10.1109/IHSH57076.2022.10092010. Citado na página 29.

D. W. Gao. *Energy Storage for Sustainable Microgrid*. 1. ed. [S.l.]: Universidade de Denver, 2015. v. 1. Citado 3 vezes nas páginas 79, 80 e 81.

- DABBAGHJAMANESH, M. et al. A novel two-stage multi-layer constrained spectral clustering strategy for intentional islanding of power grids. *IEEE Transactions on Power Delivery*, v. 35, n. 2, p. 560–570, 2020. Doi: 10.1109/TPWRD.2019.2915342. Citado na página 75.
- ELGERD, O. I. Electric energy systems theory: an introduction. McGraw-Hill Book Company, New York, NY, 1982. Citado na página 74.
- FARHANGI, H.; JOÓS, G. *Microgrid planning and design: a concise guide*. [S.l.]: John Wiley & Sons, 2019. Doi: 10.1002/9781119453550. Citado 2 vezes nas páginas 46 e 81.
- GIORGI, M. G. D.; CONGEDO, P. M.; MALVONI, M. Photovoltaic power forecasting using statistical methods: impact of weather data. *IET Science, Measurement & Technology*, Wiley Online Library, v. 8, n. 3, p. 90–97, 2014. Doi: 10.1049/iet-smt.2013.0135. Citado na página 44.
- GIRALDO, J. S. et al. Microgrids energy management using robust convex programming. *IEEE Transactions on Smart Grid*, v. 10, n. 4, p. 4520–4530, 2019. Doi: 10.1109/TSG.2018.2863049. Citado na página 33.
- GUERRERO, J. M. et al. Hierarchical control of droop-controlled ac and dc microgrids—a general approach toward standardization. *IEEE Transactions on Industrial Electronics*, v. 58, n. 1, p. 158–172, 2011. Doi: 10.1109/TIE.2010.2066534. Citado na página 41.
- GUPTA, P.; BHATIA, R. S.; JAIN, D. K. Average absolute frequency deviation value based active islanding detection technique. *IEEE Transactions on Smart Grid*, v. 6, n. 1, p. 26–35, 2015. Doi: 10.1109/TSG.2014.2337751. Citado na página 75.
- HAGAN, M.; MENHAJ, M. Training feedforward networks with the marquardt algorithm. *IEEE Transactions on Neural Networks*, v. 5, n. 6, p. 989–993, 1994. Doi: 10.1109/72.329697. Citado 2 vezes nas páginas 55 e 56.
- Hassan Farhangi and Geza Joos. *Microgrid Planning and Design – A Concise Guide*. 1. ed. [S.l.]: Wiley - IEEE Press, 2019. Doi: 10.3390/batteries2020014. Citado 5 vezes nas páginas 73, 74, 82, 85 e 111.
- HIRSCH, A.; PARAG, Y.; GUERRERO, J. Microgrids: A review of technologies, key drivers, and outstanding issues. *Renewable and Sustainable Energy Reviews*, v. 90, p. 402–411, 2018. ISSN 1364-0321. Doi: 10.1016/j.rser.2018.03.040. Citado 4 vezes nas páginas 37, 38, 39 e 40.
- HOVDEN, S. *An optimal model predictive control-based energy management system for microgrids*. Dissertação (Mestrado) — NTNU, 2021. Citado 4 vezes nas páginas 29, 42, 49 e 54.
- HU, J. et al. Model predictive control of microgrids – an overview. *Renewable and Sustainable Energy Reviews*, v. 136, p. 110422, 2021. ISSN 1364-0321. Doi: 10.1016/j.rser.2020.110422. Citado na página 43.
- HUANG, C.-M. et al. One-day-ahead hourly forecasting for photovoltaic power generation using an intelligent method with weather-based forecasting models. *IET Generation, Transmission & Distribution*, Wiley Online Library, v. 9, n. 14, p. 1874–1882, 2015. Doi: 10.1049/iet-gtd.2015.0175. Citado na página 44.

IBRAHIM, M. et al. Nonlinear autoregressive neural network in an energy management strategy for battery/ultra-capacitor hybrid electrical vehicles. *Electric Power Systems Research*, v. 136, p. 262–269, 2016. ISSN 0378-7796. Doi: 10.1016/j.epsr.2016.03.005. Citado na página 55.

IEC, I. 60038: Iec standard voltages. *International Electrotechnical Commission (IEC): Geneva, Switzerland*, 2009. Citado na página 77.

IEEE Standard for Interconnection and Interoperability of Distributed Energy Resources with Associated Electric Power Systems Interfaces. *IEEE Std 1547 (Revision of IEEE Std 1547-2003)*, p. 1–138, 2018. Citado na página 75.

ILYUSHIN, P. et al. State-of-the-art literature review of power flow control methods for low-voltage ac and ac-dc microgrids. *Energies*, v. 16, n. 7, 2023. ISSN 1996-1073. Doi: 10.3390/en16073153. Disponível em: <<https://www.mdpi.com/1996-1073/16/7/3153>>. Citado na página 29.

JAFARI, M. et al. A novel predictive fuzzy logic-based energy management system for grid-connected and off-grid operation of residential smart microgrids. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, v. 8, n. 2, p. 1391–1404, 2020. Doi: 10.1109/JESTPE.2018.2882509. Citado na página 33.

Jan Machowski, Zbigniew Lubosny, Janusz W. Bialek, James R. Bumby. *Power System Dynamics: Stability and Control*. 3rd edition. ed. [S.l.]: Wiley, 2020. Citado na página 111.

KULKARNI, N. K.; KHEDKAR, M. Methods to detect the occurrence of an unintentional island with passive approach: A review. *Journal of The Institution of Engineers (India): Series B*, Springer, v. 102, n. 5, p. 1091–1111, 2021. Citado na página 75.

KUMAR, K. et al. Effect of hysteresis band control strategy on energy efficiency and durability of solar-hydrogen storage based microgrid in partial cloudy condition. *Journal of Energy Storage*, v. 32, p. 101936, 2020. ISSN 2352-152X. Doi: 10.1016/j.est.2020.101936. Citado na página 43.

KUMAR, N. M. et al. Distributed energy resources and the application of ai, iot, and blockchain in smart grids. *Energies*, v. 13, n. 21, 2020. ISSN 1996-1073. Doi: 10.3390/en13215739. Citado na página 29.

LESAGE, J. *Microgrid energy management system (ems) using optimization*. www.mathworks.com, 2020. Disponível em: <<https://www.mathworks.com/matlabcentral/fileexchange/73139-microgrid-energy-management-system-ems-using-optimization>>. Acesso em: 02 jun. 2021. Citado 9 vezes nas páginas 15, 32, 46, 47, 49, 51, 61, 63 e 64.

LUIZ, L. G. B. et al. An application of non-linear autoregressive neural networks to predict energy consumption in public buildings. *Energies*, v. 9, n. 9, 2016. ISSN 1996-1073. Doi: 10.3390/en9090684. Citado 2 vezes nas páginas 55 e 56.

MA, G.; LI, J.; ZHANG, X.-P. A review on optimal energy management of multimicrogrid system considering uncertainties. *IEEE Access*, v. 10, p. 77081–77098, 2022. Doi: 10.1109/ACCESS.2022.3192638. Citado na página 33.

- MAHAT, P.; CHEN, Z.; BAK-JENSEN, B. Review of islanding detection methods for distributed generation. In: *2008 Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*. [S.l.: s.n.], 2008. p. 2743–2748. Doi: 10.1109/DRPT.2008.4523877. Citado na página 75.
- MAMDANI. Application of fuzzy logic to approximate reasoning using linguistic synthesis. *IEEE Transactions on Computers*, C-26, n. 12, p. 1182–1191, 1977. Doi: 10.1109/TC.1977.1674779. Citado na página 58.
- MARNAY, C. et al. Microgrid evolution roadmap. In: *2015 International Symposium on Smart Electric Distribution Systems and Technologies (EDST)*. [S.l.: s.n.], 2015. p. 139–144. Doi: 10.1109/SEDST.2015.7315197. Citado 2 vezes nas páginas 37 e 40.
- MASETTI, C. Revision of european standard en 50160 on power quality: Reasons and solutions. In: IEEE. *Proceedings of 14th International Conference on Harmonics and Quality of Power-ICHQP 2010*. [S.l.], 2010. p. 1–7. Doi: 10.1109/ICHQP.2010.5625472. Citado na página 77.
- MASSIGNAN, J. A. D.; PEREIRA, B. R.; LONDON, J. B. A. Load flow calculation with voltage regulators bidirectional mode and distributed generation. *IEEE Transactions on Power Systems*, v. 32, n. 2, p. 1576–1577, 2017. Doi: 10.1109/PESGM.2017.8274286. Citado na página 29.
- MATHWORKS. *Choose a Solver*. www.mathworks.com, 2006. Disponível em: <<https://se.mathworks.com/help/simulink/ug/choose-a-solver.html>>. Acesso em: 09 jun. 2021. Citado na página 45.
- MATHWORKS. *powergui - environment block for Simscape Electrical Specialized Power Systems models*. www.mathworks.com, 2006. Disponível em: <<https://se.mathworks.com/help/sps/powersys/ref/powergui.html;jsessionid=e32f895e02f1ce68e22798d4c823>>. Acesso em: 09 jun. 2021. Citado na página 45.
- MATHWORKS. *Shallow Neural Network Time-Series Prediction and Modeling*. www.mathworks.com, 2022. Disponível em: <<https://www.mathworks.com/help/deeplearning/gs/neural-network-time-series-prediction-and-modeling.html>>. Acesso em: 26 jan. 2023. Citado na página 55.
- MATHWORKS. *Choose a Solver*. www.mathworks.com, 2023. Disponível em: <<https://se.mathworks.com/help/deeplearning/ref/neuralnettimeseries-app.html>>. Acesso em: 13 jun. 2023. Citado na página 55.
- MATHWORKS. *Shallow Neural Network Time-Series Prediction and Modeling*. www.mathworks.com, 2023. Disponível em: <<https://www.mathworks.com/help/fuzzy/simulation.html>>. Acesso em: 20 jan. 2023. Citado na página 65.
- MATHWORKSSIMSCAPE. *Simscape Electrical - Model and simulate electronic, mechatronic, and electrical power systems*. www.mathworks.com, 2020. Disponível em: <<https://www.mathworks.com/help/deeplearning/ref/narnet.html>>. Acesso em: 21 jun. 2021. Citado na página 46.
- MENG, L. et al. Microgrid supervisory controllers and energy management systems: A literature review. *Renewable and Sustainable Energy Reviews*, v. 60, p. 1263–1273, 2016. ISSN 1364-0321. Doi: 10.1016/j.rser.2016.03.003. Disponível em:

- <<https://www.sciencedirect.com/science/article/pii/S1364032116002380>>. Citado 3 vezes nas páginas 40, 41 e 42.
- MIGLIAVACCA, G. *Advanced technologies for future transmission grids*. [S.l.]: Springer Science & Business Media, 2012. Citado na página 29.
- MODULO8, A. R. N. n° 482. *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – Modulos 8 PRODIST*. Sancionado em 01 de janeiro de 2021. [S.l.], 2016. Disponível em: <<https://www.aneel.gov.br/modulo-8>>. Acesso em: 01 ago. 2021. Citado 9 vezes nas páginas 34, 46, 77, 79, 88, 90, 92, 93 e 95.
- MOTTER, D.; MOURINHO, F. A.; VIEIRA, J. C. M. Impact of load variation on the synchronous dg frequency-based anti-islanding protection. In: *2015 IEEE Power Energy Society General Meeting*. [S.l.: s.n.], 2015. p. 1–5. Doi: 10.1109/PESGM.2015.7286287. Citado na página 76.
- MOTTER, D.; VIEIRA, J. Influence of a step-voltage regulator on synchronous dg anti-islanding protection. *IEEE Latin America Transactions*, v. 17, n. 06, p. 897–906, 2019. Doi: 10.1109/TLA.2019.8896811. Citado na página 77.
- MOURA, F. A. M. *Geração distribuída - impactos e contribuições para a qualidade da energia elétrica e dinâmica dos sistemas elétricos - uma análise através do ATP-EMTP*. 240 p. Dissertação (Mestrado) — Universidade Federal de Uberlândia, Ago 2011. Citado na página 73.
- NAGY, G. I. et al. Gefcom2014: Probabilistic solar and wind power forecasting using a generalized additive tree ensemble approach. *International Journal of Forecasting*, Elsevier, v. 32, n. 3, p. 1087–1093, 2016. Doi: 10.1016/j.ijforecast.2015.11.013. Citado na página 44.
- NALE, R.; BISWAL, M. Comparative assessment of passive islanding detection techniques for microgrid. In: *2017 International Conference on Innovations in Information, Embedded and Communication Systems (ICIIECS)*. [S.l.: s.n.], 2017. p. 1–5. Doi: 10.1109/ICIIECS.2017.8275935. Citado na página 75.
- NORDPOOLAS. *Historical Market Data*. www.nordpoolgroup.com, 2020. Disponível em: <<https://www.nordpoolgroup.com/en/Market-data1/Dayahead/Area-Prices/ALL1/Hourly/?view=table>>. Acesso em: 22 jul. 2022. Citado 5 vezes nas páginas 15, 33, 61, 62 e 64.
- OLIVARES, D. E. et al. Trends in microgrid control. *IEEE Transactions on Smart Grid*, v. 5, n. 4, p. 1905–1919, 2014. Doi: 10.1109/TSG.2013.2295514. Citado 4 vezes nas páginas 37, 39, 40 e 41.
- P. Kundur. *Power Systems Stability and Control*. [S.l.]: Toronto, Universidade de Toronto, 1994. Citado na página 111.
- P2781, I. S. *IEEE draft guide for load modeling and simulations for power system (2021)*. [S.l.]: IEEE Std New York, 2021. Citado na página 74.
- PARHIZI, S. et al. State of the art in research on microgrids: A review. *IEEE Access*, v. 3, p. 890–925, 2015. Doi: 10.1109/ACCESS.2015.2443119. Citado 2 vezes nas páginas 37 e 38.

- PARISIO, A.; RIKOS, E.; GLIELMO, L. A model predictive control approach to microgrid operation optimization. *IEEE Transactions on Control Systems Technology*, v. 22, n. 5, p. 1813–1827, 2014. Doi: 10.1109/TCST.2013.2295737. Citado 3 vezes nas páginas 39, 40 e 43.
- PIARDI, A. B. et al. Impact of rocof-based islanding detection on the stand-alone operation of a distributed synchronous generator. In: *2019 IEEE Milan PowerTech*. [S.l.: s.n.], 2019. p. 1–6. Doi: 10.1109/PTC.2019.8810844. Citado na página 76.
- R. C. Dugan and M. F. McGranaghan and S. Santese and H. W. Beaty. *Electrical Power Systems Quality*. 3. ed. [S.l.]: McGraw-Hill Education, 2002. Citado 2 vezes nas páginas 82 e 87.
- SEYDENSCHWANZ, M. et al. Rule-based dispatching of microgrids with coupled electricity and heat power systems. In: *2020 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe)*. [S.l.: s.n.], 2020. p. 519–523. Doi: 10.1109/ISGT-Europe47291.2020.9248935. Citado na página 43.
- SII, H. S.; RUXTON, T.; WANG, J. A fuzzy-logic-based approach to qualitative safety modelling for marine systems. *Reliability Engineering and System Safety*, v. 73, n. 1, p. 19–34, 2001. ISSN 0951-8320. Doi: 10.1016/S0951-8320(01)00023-0. Citado 3 vezes nas páginas 15, 57 e 58.
- SILVA, A. M. B. et al. Behavior analysis of synchronous generator controllers in distributed generation systems. *J Control Autom Electr*, p. 702–717, Apr 2016. Doi: 10.1007/s40313-016-0273-z. Citado 4 vezes nas páginas 81, 82, 83 e 84.
- SIMÕES, M. G.; FARRET, F. A. *Modeling Power electronics and interfacing energy conversion systems*. [S.l.]: John Wiley & Sons, 2016. Doi: 10.1002/9781119058458. Citado na página 77.
- SOUZA, A. C. et al. Avaliação crítica das correntes certificadas propostas pelo submódulo 2.8 do procedimento de rede do ons. *CBA2018*, v. 1, n. 1, Out 2020. Citado na página 73.
- STOKER, L. *Smart, flexible power system could save consumers billions, government told*. www.solarpowerportal.co.uk, 2016. Disponível em: <https://www.solarpowerportal.co.uk/news/smart_flexible_power_system_could_save_consumers_billions_government_3502>. Acesso em: 25 jun. 2022. Citado na página 30.
- THIRUNAVUKKARASU, G. S. et al. Role of optimization techniques in microgrid energy management systems—a review. *Energy Strategy Reviews*, v. 43, p. 100899, 2022. ISSN 2211-467X. Doi: 10.1016/j.esr.2022.100899. Citado na página 42.
- TRUONG, C. N. et al. Economics of residential photovoltaic battery systems in germany: The case of tesla’s powerwall. *Batteries*, MDPI, v. 2, n. 2, p. 14, 2016. Doi: 10.3390/batteries2020014. Citado na página 48.
- ULLAH, Z. et al. Implementation of various control methods for the efficient energy management in hybrid microgrid system. *Ain Shams Engineering Journal*, v. 14, n. 5, p. 101961, 2023. ISSN 2090-4479. Doi: 10.1016/j.asej.2022.101961. Citado na página 41.
- YAO, R. et al. A novel category-specific pricing strategy for demand response in microgrids. *IEEE Transactions on Sustainable Energy*, v. 13, n. 1, p. 182–195, 2022. Doi: 10.1109/TSTE.2021.3106329. Citado na página 30.

ZHANG, L. et al. Improved cycle aging cost model for battery energy storage systems considering more accurate battery life degradation. *IEEE Access*, v. 10, p. 297–307, 2022. Doi: 10.1109/ACCESS.2021.3139075. Citado na página 32.

ZHANG, Y.; GATSIIS, N.; GIANNAKIS, G. B. Robust energy management for microgrids with high-penetration renewables. *IEEE Transactions on Sustainable Energy*, v. 4, n. 4, p. 944–953, 2013. Doi: 10.1109/TSTE.2013.2255135. Citado na página 40.

ZIA, M. F.; ELBOUCHIKHI, E.; BENBOUZID, M. Microgrids energy management systems: A critical review on methods, solutions, and prospects. *Applied Energy*, v. 222, p. 1033–1055, 2018. ISSN 0306-2619. Doi: 10.1016/j.apenergy.2018.04.103. Citado na página 42.

Apêndices

APÊNDICE A – Dados e parâmetros das simulações

Segue abaixo os parâmetros configurados no bloco *Simple Solar Inverter*, simplificado para o SGE:

Tabela 10 – Bloco *Simple Solar Inverter*

Parâmetros	
Tensão primária nominal F-F	249.8480 Vrms
Frequência nominal	60 Hz
Potência ativa inicial	1.25 MW
Potência reativa inicial	0 MW
Tensão de seqüência positiva inicial	0.999844 pu
Defasagem	-0.0038635 °

Fonte: o autor.

Segue abaixo os parâmetros configurados no bloco *table:ThreePhaseSource*:

Tabela 11 – Bloco *Three-Phase Source*

Parâmetros	
Tensão nominal F-F	115000 Vrms
Frequência nominal	60 Hz
Ângulo de defasamento	0.071468 °
Potência de curto-circuito	250 MVA
Tensão base F-F	115000 Vrms
X/R	7

Fonte: o autor.

Os parâmetros das tabelas abaixo foram obtidas de (P. Kundur, 1994), (Jan Machowski, Zbigniew Lubosny, Janusz W. Bialek, James R. Bumby, 2020), e (Hassan Farhangi and Geza Joos, 2019) conforme os símbolos apresentados. Os ajustes dos parâmetros dos inversores da fazenda solar (FV), foram definidos após os devidos ensaios, conforme o conhecimento adquirido após leituras de artigos científicos relacionados e simulações realizadas.

Tabela 12 – Dados Utilizados nos Transformadores Trifásicos

	T_a	T_b	T_1	T_2
S_n (MVA)	15,0	15,0	6,0	2,0
F (Hz)	60	60	60	60
$V_1 F-F$ (kVrms)	115	115	6,6	0,24985
R_1 (Ω)	26,45	26,45	4,32	3,0
L_1 (mH)	833,898	833,898	229,18	198,94
$V_2 F-F$ kVrms	12,47	12,47	12,47	12,47
R_2 (Ω)	0,104	0,104	0,038875	0,0089892
L_2 (mH)	3,28912	3,28912	2,0624	0,59612
R_m (Ω)	11426,4	11426,4	5183,4	50000
L_m	30,3095	30,3095	13,749	13,263

Fonte: o autor.

Tabela 13 – Parâmetros Utilizados para a Máquina Síncrona

Dados Utilizados	
S_n	5,0 MVA
V_n	6.600 Vrms
F	60 Hz
X_d	1,5 pu
X'_d	0,398 pu
X''_d	0,254 pu
X_q	1,47 pu
X'_q	0,3 pu
X''_q	0,254 pu
X_l	0,10 pu
X'_d	8,0 pu
X''_d	0,03 pu
T'_{qo}	0,3371
T''_{qo}	0,0295
H	1,07
P	2

Fonte: o autor.

Tabela 14 – Parâmetros Utilizados no Regulador de Fator de Potência

Dados Utilizados	
K_a	20,0
T_a	0,02
K_f	0,03
T_f	1,0
K_e	1,0
T_e	0,3

Fonte: o autor.

Tabela 15 – Parâmetros Utilizados no Regulador de Tensão

Dados Utilizados	
K_a	600
T_a	0,01
K_f	0,01
T_f	0,1
K_e	1,0
T_e	0,8

Fonte: o autor.

Tabela 16 – Parâmetros Utilizados no Regulador de Velocidade *Droop*

Dados Utilizados	
R_1	0,05
Constante de Amortecimento Mecânico da Turbina	0,0
$Limitação_{min}$	0,0
$Limitação_{max}$	1,1
T_1	0,05
T_2	0,6
T_3	2
P_{m0}	1 pu

Fonte: o autor.

Tabela 17 – Parâmetros Utilizados no Regulador de Velocidade Isócrono

Dados Utilizados	
R_2	0,001
Constante de Amortecimento Mecânico da Turbina	0,0
$Limitação_{min}$	0,0
$Limitação_{max}$	1,1
T_1	0,05
T_2	0,6
T_3	2
P_{m0}	1 pu

Fonte: o autor.

A Tabela 18, apresenta os dados das linhas de distribuição utilizadas.

Tabela 18 – Dados Utilizados				
Dados das Linhas de Distribuição				
Segmento de Linhas	Nó de	Nó para	$R(\Omega)$	$L(H)$
1	1	2	$3,38.10^{-1}$	$2,24.10^{-3}$
2	2	3	$2,82.10^{-1}$	$1,86.10^{-3}$
3	3	4	$1,72.10^{-1}$	$1,14.10^{-3}$
4	4	5	$1,72.10^{-1}$	$1,14.10^{-3}$
5	5	6	$4,34.10^{-1}$	$2,87.10^{-3}$
6	6	7	$6,77.10^{-2}$	$4,48.10^{-4}$
7	7	8	$4,71.10^{-1}$	$3,11.10^{-3}$
8	8	9	$9,02.10^{-2}$	$5,97.10^{-4}$
9	9	10	$2,17.10^{-1}$	$1,44.10^{-3}$
10	10	11	$9,31.10^{-2}$	$6,15.10^{-4}$
11	11	4	$1,3818.10^{-1}$	$0,9114.10^{-3}$
12	12	13	$1,38.10^0$	$9,12.10^{-3}$
13	13	14	$8,43.10^{-1}$	$5,58.10^{-3}$
14	14	8	$5,64.10^{-1}$	$3,73.10^{-3}$

Fonte: o autor.

Tabela 19 – Valores Nominais de cada Inversor da Fazenda FV - Valores Nominais - Estudo de caso para o ilhamento intencional

Dados Utilizados	
Potência nominal (S_n)	250 kVA
Tensão Primária	12470 Vrms - FF
Tensão Secundária	249.8480 Vrms - FF
Frequência	60 Hz
Voltagem de CC	480 V

Fonte: o autor.

Tabela 20 – Parâmetros Utilizados no Controlador MPPT

Dados Utilizados	
Valores do <i>Output – increment</i>	0.0100 V
Limites de saída [Superior–Inferior]	583 - 357
Valor inicial de saída	480 V

Fonte: o autor.

Tabela 21 – Regulador de tensão DC

Dados Utilizados	
Ganho proporcional	2
Ganho integral	400

Fonte: o autor.

Tabela 22 – Dados importantes do regulador

Dados Utilizados	
Ganho proporcional	0.3000
Ganho integral	20
Valores de <i>feedforward</i> [Rff Lff]	0.0039 0.2100

Fonte: o autor.

APÊNDICE B – Códigos do bloco *MATLAB* *Function*

Arquivo *MATLAB Function* do algoritmo heurístico.

```
function P_com = fcn(P_carga, P_FV, SOC)

P_rede = P_FV - P_carga
P_desc_max = 400;
P_carr_max = 400;
SOC_min = 20;
SOC_max = 80;

if P_rede < 0

if SOC <= SOC_min
P_bat = 0;
else
if abs(P_rede) >= abs(P_desc_max)
P_bat = P_desc_max;
else
P_bat = P_rede
end
end
else
if SOC >= SOC_max
P_bat = 0;
else
if P_rede >= P_carr_max
P_bat = P_carr_max;
else
P_bat = P_rede;
end
end
end

P_com = P_bat*1000;
```

Segue a função para aplicação de treinamento da RNA com a técnica autorregressiva

não linear do *Neural Network Time Series* do MATLAB função *Nonlinear Autoregressive* (NAR) para previsão de preços de energia elétrica no mercado.

```

function [y1,xf1] = myNeuralNetworkFunction(x1,xi1)
%MYNEURALNETWORKFUNCTION neural network simulation function.
%
% Auto-generated by MATLAB, 10-Nov-2022 09:51:32.
%
% [y1,xf1] = myNeuralNetworkFunction(x1,xi1) takes these arguments:
% x1 = 1xTS matrix, input #1
% xi1 = 1x3 matrix, initial 3 delay states for input #1.
% and returns:
% y1 = 1xTS matrix, output #1
% xf1 = 1x3 matrix, final 3 delay states for input #1.
% where TS is the number of timesteps.

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = 0.5513886;
x1_step1.gain = 3.55089677898153;
x1_step1.ymin = -1;

% Layer 1
b1 =
[4.2491736500681547284;-3.0438863609766118046;-2.66089896458477293;-1.757565275403
IW1_1 = [-1.2246355486315396721 -1.0793557920485832291
-1.8175997495713482888;-0.16333163872501663128
-3.4747575864970006165
0.82193011726612585921;1.7926649809124963753 1.2322805165289525409
2.7567665918172368222;2.5027845424639005856
0.044491007979152633056 2.520121352702493045;2.6205190261493576109
-0.82599726970013598315
-2.1355669157067587172;0.79332652026001182488
3.5844174633374863426
0.79520255681883367238;-1.2853546741499617401
-0.34711823276736541999
0.46935758313966330357;-2.1787113691968658102
0.058869204650244325028
-2.2017090387512374683;-1.2279790189609085527
3.0002023284097507627 -1.0449636848470191808;1.7763947730863236529
-1.7593522894901598708

```

```
-2.3113617262890513437;-1.8220229312650775277
2.1302627252969159599 2.6796629808129472927;2.3057362223652693167
1.5378072496611481235
-1.1823392608232730083;-2.4561919836476207024
-0.94918546604409337331
-0.16334483131310517656;2.6197313910466215603
0.44758460920074072398
-2.0843218472424451804;-1.159877346769163875
-2.6842105101039144266 0.31870977019045448886];

% Layer 2
b2 = 0.16547218808090990994;
LW2_1 = [-0.11939170253482417339 0.55847431977329908825
0.10320746445395945212 -0.031481438769952914403
-0.012322057225268565062 -0.027426346854908235234
-0.67290203663044245719 -0.15283546344046769483
-0.095961311761957282518 0.22000515075612228633
0.1953347268491247013 0.13255344754585934863
-0.19402460776618957183 0.098793504358874906224
-0.52883391250186950749];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 3.55089677898153;
y1_step1.xoffset = 0.5513886;

% ===== SIMULATION =====

% Dimensions
TS = size(x1,2); % timesteps

% Input 1 Delay States
xd1 = mapminmax_apply(xi1,x1_step1);
xd1 = [xd1 zeros(1,1)];

% Allocate Outputs
y1 = zeros(1,TS);

% Time loop
for ts=1:TS

% Rotating delay state position
```

```

xdts = mod(ts+2,4)+1;

% Input 1
xd1(:,xdts) = mapminmax_apply(x1(:,ts),x1_step1);

% Layer 1
tapdelay1 = reshape(xd1(:,mod(xdts-[1 2 3]-1,4)+1),3,1);
a1 = tansig_apply(b1 + IW1_1*tapdelay1);

% Layer 2
a2 = b2 + LW2_1*a1;

% Output 1
y1(:,ts) = mapminmax_reverse(a2,y1_step1);
end

% Final delay states
finalxts = TS+(1: 3);
xits = finalxts(finalxts<=3);
xts = finalxts(finalxts>3)-3;
xf1 = [xi1(:,xits) x1(:,xts)];
end

% ===== MODULE FUNCTIONS =====

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
y = bsxfun(@minus,x,settings.xoffset);
y = bsxfun(@times,y,settings.gain);
y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
x = bsxfun(@minus,y,settings.ymin);
x = bsxfun(@rdivide,x,settings.gain);
x = bsxfun(@plus,x,settings.xoffset);

```

end

Segue a função para aplicação de treinamento da RNA com a técnica autorregressiva não linear do *Neural Network Time Series* do *MATLAB* função *Nonlinear Autoregressive (NAR)* para previsão da potência de energia FV.

```
function [Y,Xf,Af] = myNeuralNetworkFunction(X,Xi,~)
%MYNEURALNETWORKFUNCTION neural network simulation function.
%
% Auto-generated by MATLAB, 19-Mar-2023 20:53:22.
%
% [Y,Xf,Af] = myNeuralNetworkFunction(X,Xi,~) takes these arguments:
%
% X = 1xTS cell, 1 inputs over TS timesteps
% Each X{1,ts} = 1xQ matrix, input #1 at timestep ts.
%
% Xi = 1x3 cell 1, initial 3 input delay states.
% Each Xi{1,ts} = 1xQ matrix, initial states for input #1.
%
% Ai = 2x0 cell 2, initial 3 layer delay states.
% Each Ai{1,ts} = 15xQ matrix, initial states for layer #1.
% Each Ai{2,ts} = 1xQ matrix, initial states for layer #2.
%
% and returns:
% Y = 1xTS cell of 1 outputs over TS timesteps.
% Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% Xf = 1x3 cell 1, final 3 input delay states.
% Each Xf{1,ts} = 1xQ matrix, final states for input #1.
%
% Af = 2x0 cell 2, final 0 layer delay states.
% Each Af{1ts} = 15xQ matrix, final states for layer #1.
% Each Af{2ts} = 1xQ matrix, final states for layer #2.
%
% where Q is number of samples (or series) and TS is the number of
    timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====
```

```
% Input 1
x1_step1.xoffset = 0;
x1_step1.gain = 0.00219155866391626;
x1_step1.ymin = -1;

% Layer 1
b1 =
    [-3.9913415168753290097;-3.5974826258146239688;2.4598629321714788887;-1.0369346978;
IW1_1 = [2.0891492634761066327 -1.1972963655327708565
    -2.577738269037208596;2.0733746109733064422 -1.8528417686999643088
    -1.7740923464134554788;-1.9278897311132086045
    -1.7973234864141471867
    -2.0427952097735011527;2.4872539852888047029
    -0.66029247063160334541
    1.4352003353367011051;2.4236244948145428957 0.93424974647752956347
    -0.25897143579303366634;-0.68401867225532553274
    -1.3148282613943285124
    -2.283272134776357376;-0.61282414543202057278
    -3.1281670993843144757
    -1.9469612853879003644;-2.7228377028290049466
    1.8668140117759051133
    -0.34028229023529521502;-0.50372784640077383767
    1.0248257510539648951 3.1837159981761122829;1.7755989588068130658
    0.93429632982060617508
    -1.2699644193467964914;1.2763047855715126122
    -0.14691068063500825613
    -0.075929214544320791647;-1.3360711299441854205
    2.0733691390574446878
    0.67739904262168360027;-2.2050259806116359051
    -2.5873906339555166056
    -0.25451265799111366661;2.6209361617618989193
    -2.2832884567256166441
    0.94430888177153360363;-1.9381933250175462646
    -2.0219863521095247094 -1.6808884996650319543];

% Layer 2
b2 = 0.041031818340683881563;
LW2_1 = [0.42940013646473934594 0.084899156058622596288
    -0.0065629189085198965173 -0.21335621585126662847
    0.10857552455176845696 -0.063471189143675027511
    -0.0032340228630438599272 -0.60621072931196862132
    0.0066960031376567877293 0.36288267707455262867
```

```
    0.92081794279084150379 -0.10447575780457274419
    -0.0039036248745674372029 0.90108918069180965471
    -0.0023474484352812114915];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.00219155866391626;
y1_step1.xoffset = 0;

% ===== SIMULATION =====

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
X = {X};
end
if (nargin < 2), error('Initial input states Xi argument needed.');
```

```
end

% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
Q = size(X{1},2); % samples/series
elseif ~isempty(Xi)
Q = size(Xi{1},2);
else
Q = 0;
end

% Input 1 Delay States
Xd1 = cell(1,4);
for ts=1:3
Xd1{ts} = mapminmax_apply(Xi{1,ts},x1_step1);
end

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS

% Rotating delay state position
xdts = mod(ts+2,4)+1;
```

```

% Input 1
Xd1{xdts} = mapminmax_apply(X{1,ts},x1_step1);

% Layer 1
tapdelay1 = cat(1,Xd1{mod(xdts-[1 2 3]-1,4)+1});
a1 = tansig_apply repmat(b1,1,Q) + IW1_1*tapdelay1);

% Layer 2
a2 = repmat(b2,1,Q) + LW2_1*a1;

% Output 1
Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
finalxts = TS+(1: 3);
xits = finalxts(finalxts<=3);
xts = finalxts(finalxts>3)-3;
Xf = [Xi(:,xits) X(:,xts)];
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS =====

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
y = bsxfun(@minus,x,settings.xoffset);
y = bsxfun(@times,y,settings.gain);
y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
a = 2 ./ (1 + exp(-2*n)) - 1;
end

```

```

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
x = bsxfun(@minus,y,settings.ymin);
x = bsxfun(@rdivide,x,settings.gain);
x = bsxfun(@plus,x,settings.xoffset);
end

```

Segue a função para aplicação de treinamento da RNA com a técnica autorregressiva não linear do *Neural Network Time Series* do *MATLAB* função *Nonlinear Autoregressive (NAR)* para previsão do consumo de cargas.

```

function [Y,Xf,Af] = myNeuralNetworkFunction(X,Xi,~)
%MYNEURALNETWORKFUNCTION neural network simulation function.
%
% Auto-generated by MATLAB, 19-Mar-2023 20:40:01.
%
% [Y,Xf,Af] = myNeuralNetworkFunction(X,Xi,~) takes these arguments:
%
% X = 1xTS cell, 1 inputs over TS timesteps
% Each X{1,ts} = 1xQ matrix, input #1 at timestep ts.
%
% Xi = 1x3 cell 1, initial 3 input delay states.
% Each Xi{1,ts} = 1xQ matrix, initial states for input #1.
%
% Ai = 2x0 cell 2, initial 3 layer delay states.
% Each Ai{1,ts} = 15xQ matrix, initial states for layer #1.
% Each Ai{2,ts} = 1xQ matrix, initial states for layer #2.
%
% and returns:
% Y = 1xTS cell of 1 outputs over TS timesteps.
% Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% Xf = 1x3 cell 1, final 3 input delay states.
% Each Xf{1,ts} = 1xQ matrix, final states for input #1.
%
% Af = 2x0 cell 2, final 0 layer delay states.
% Each Af{1ts} = 15xQ matrix, final states for layer #1.
% Each Af{2ts} = 1xQ matrix, final states for layer #2.
%
% where Q is number of samples (or series) and TS is the number of
timesteps.

```

```
%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = 120.548779852823;
x1_step1.gain = 0.00296123501084055;
x1_step1.ymin = -1;

% Layer 1
b1 =
    [3.404339684529522625;-2.9788011690628546368;-2.4812755779829145375;-2.02221907084
IW1_1 = [-1.5657584654357843412 -1.8745790303895977225
    -2.6737175410633899908;0.17653299429711596935
    -3.2879280613810548672
    0.61448886155060378211;1.8836648129683759567 1.0864010791967695368
    2.636392580192532975;2.1147014643377204379 -0.35740450187489547496
    2.357625288015182452;2.7478813114157909503 -0.71101610012992422227
    -2.0200383965671826481;0.47495535198244120956
    3.2607519896689969308
    0.57652665144421366694;-2.5065545808326366028
    1.0834701944975793086
    0.0031739842082013692594;-2.2447973959475779893
    0.27498440691893383248
    -2.7479311717895225087;-2.2059950099985612404
    2.0602662536045213137 -1.6613441071746797295;2.1389186659528376389
    -1.5421321003924435278
    -2.5054260729022708176;-1.9998119850720172952
    1.5715414528167472863 1.5892965410032111606;2.0668480260653430136
    1.5872603147160266879
    -1.9929263591604939876;-3.0569675228910395681
    -1.4029966111171403575
    0.42548668121936250586;2.7172126997003052118
    0.43389378142532009086
    -2.1004801181357763973;-0.83340295624900262439
    -2.9672860180902018712 0.88520005145401325919];

% Layer 2
b2 = 0.83985812939231518914;
LW2_1 = [-0.0047604789573495566793 0.37297841455639701991
    0.0080664575985789840895 -0.030804868213987712106
```

```
    0.24476783148031922011 -0.0011840825519376704106
    -0.70592765311228622416 0.0014267539072270508677
    -0.18581638453119778132 0.20415690631840627267
    0.60922080915579090998 0.50107999922288859462
    0.0084223845264670294669 -0.22829392976738255294
    -0.43833546247522314765];

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.00296123501084055;
y1_step1.xoffset = 120.548779852823;

% ===== SIMULATION =====

% Format Input Arguments
isCellX = iscell(X);
if ~isCellX
X = {X};
end
if (nargin < 2), error('Initial input states Xi argument needed.');
```

```
end

% Dimensions
TS = size(X,2); % timesteps
if ~isempty(X)
Q = size(X{1},2); % samples/series
elseif ~isempty(Xi)
Q = size(Xi{1},2);
else
Q = 0;
end

% Input 1 Delay States
Xd1 = cell(1,4);
for ts=1:3
Xd1{ts} = mapminmax_apply(Xi{1,ts},x1_step1);
end

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS
```

```

% Rotating delay state position
xdts = mod(ts+2,4)+1;

% Input 1
Xd1{xdts} = mapminmax_apply(X{1,ts},x1_step1);

% Layer 1
tapdelay1 = cat(1,Xd1{mod(xdts-[1 2 3]-1,4)+1});
a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*tapdelay1);

% Layer 2
a2 = repmat(b2,1,Q) + LW2_1*a1;

% Output 1
Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
finalxts = TS+(1: 3);
xits = finalxts(finalxts<=3);
xts = finalxts(finalxts>3)-3;
Xf = [Xi(:,xits) X(:,xts)];
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS =====

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
y = bsxfun(@minus,x,settings.xoffset);
y = bsxfun(@times,y,settings.gain);
y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)

```

```
a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
x = bsxfun(@minus,y,settings.ymin);
x = bsxfun(@divide,x,settings.gain);
x = bsxfun(@plus,x,settings.xoffset);
end
```

Arquivo *MATLAB Function* do relé para identificação deilhamento que foi modelado.

```
function TP_ROCOF = myROCOF(deltaF,LF,LV,PCC)

if (PCC == 1)

if (LV == 1) && (LF == 1) && (deltaF == 1)

TP_ROCOF = 1;
PCC = 0;

else

TP_ROCOF = 0;

end
else

TP_ROCOF = 1;

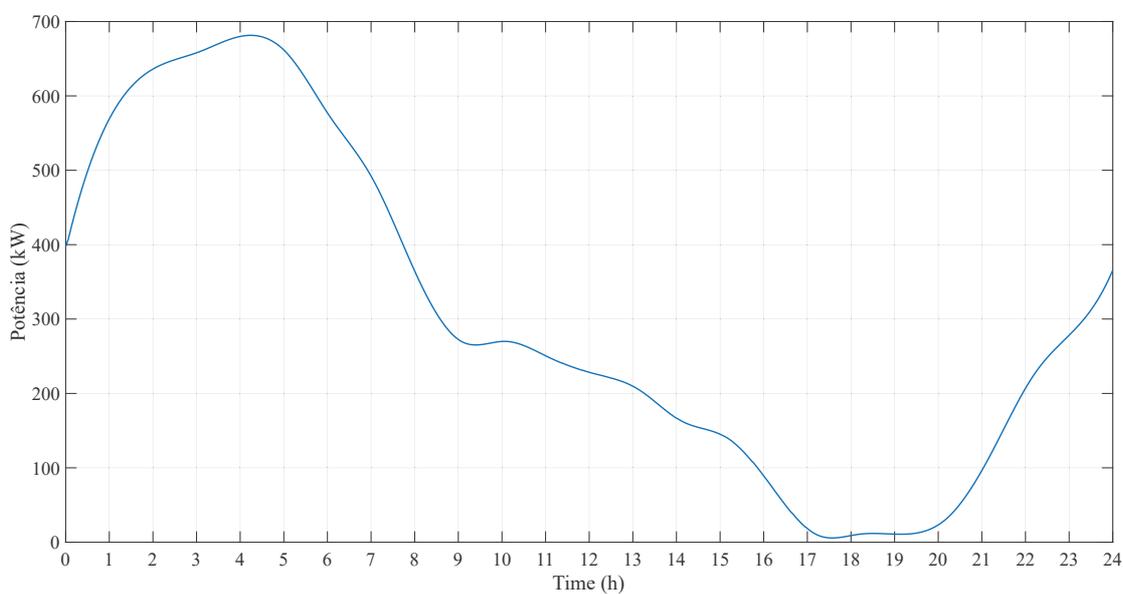
end
```

APÊNDICE C – Dados utilizados para o treinamento da RNA e previsões obtidas

C.0.1 Dados utilizados para o treinamento das RNA de previsões

A Figura 53, apresenta a curva referente aos dados utilizados para o treinamento da RNA previsões da demanda de carga da MR.

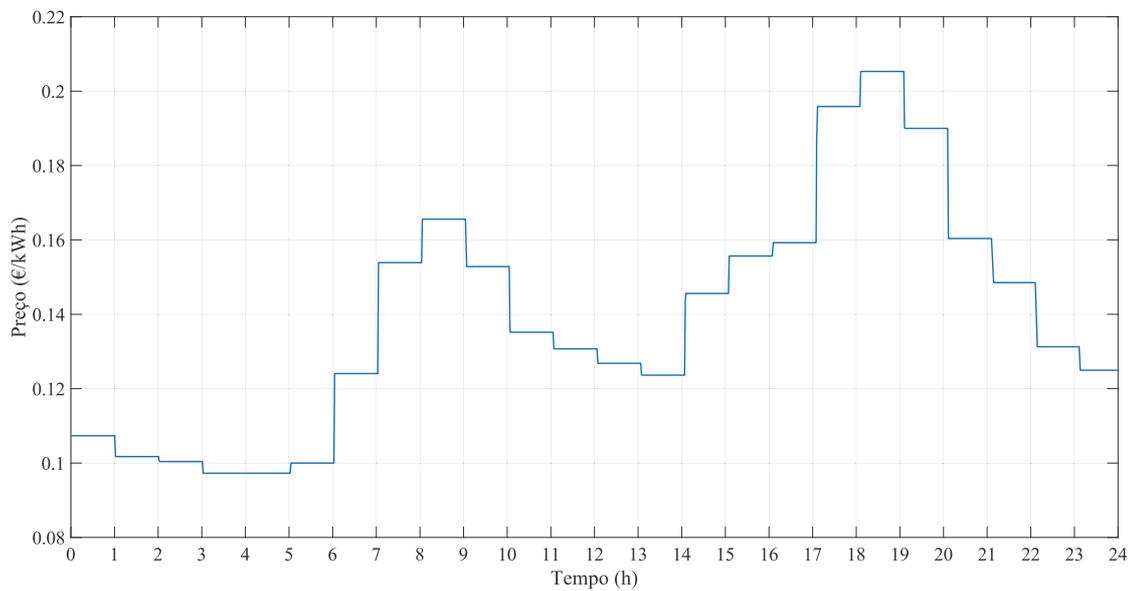
Figura 53 – Curva utilizada no treinamento da RNA previsões da carga.



Fonte: o autor.

A Figura 54, apresenta a curva referente aos dados utilizados no treinamento da RNA previsões da preços da energia elétrica, do dia 09 de Novembro de 2022.

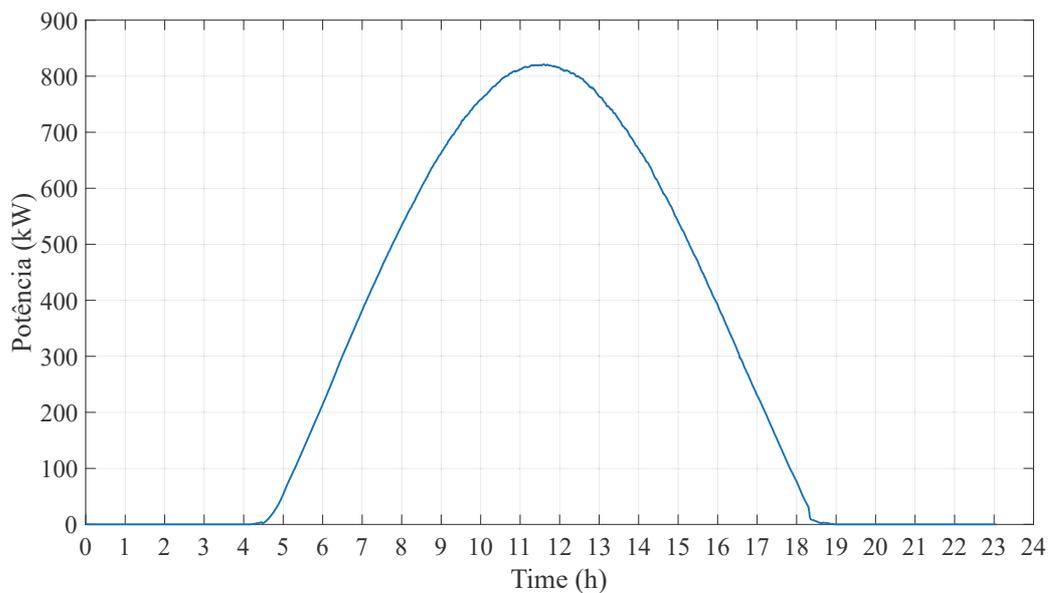
Figura 54 – Curva utilizada no treinamento da RNA previsões da preços dinâmicos.



Fonte: o autor.

A Figura 55, apresenta a curva referente aos dados utilizados no treinamento da RNA previsões do dia de céu claro para geração de energia elétrica FV.

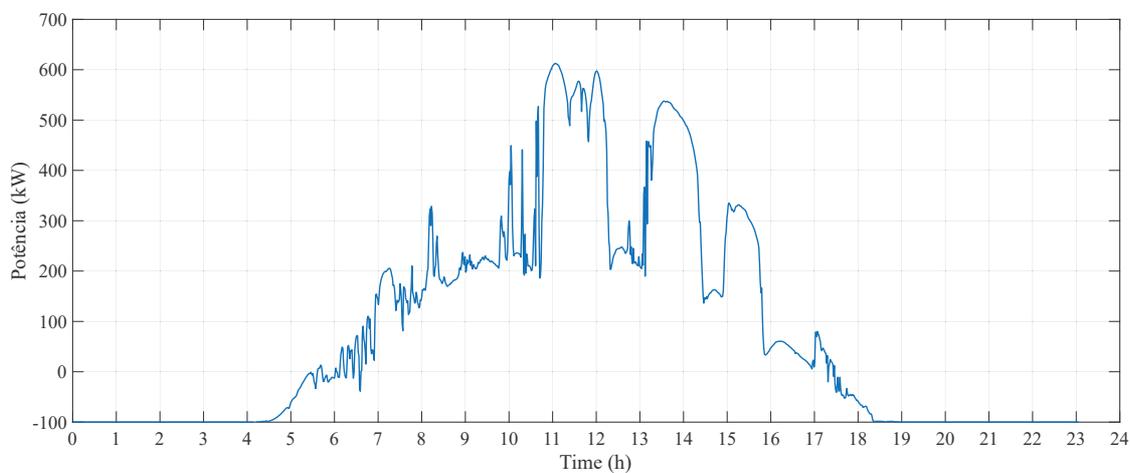
Figura 55 – Curva utilizada no treinamento da RNA previsões da geração de energia FV para o céu claro.



Fonte: o autor.

A Figura 56, apresenta a curva referente aos dados utilizados no treinamento da RNA previsões do dia de céu nublado para geração de energia elétrica FV.

Figura 56 – Curva utilizada no treinamento da RNA previsões da geração de energia FV para o céu nublado.

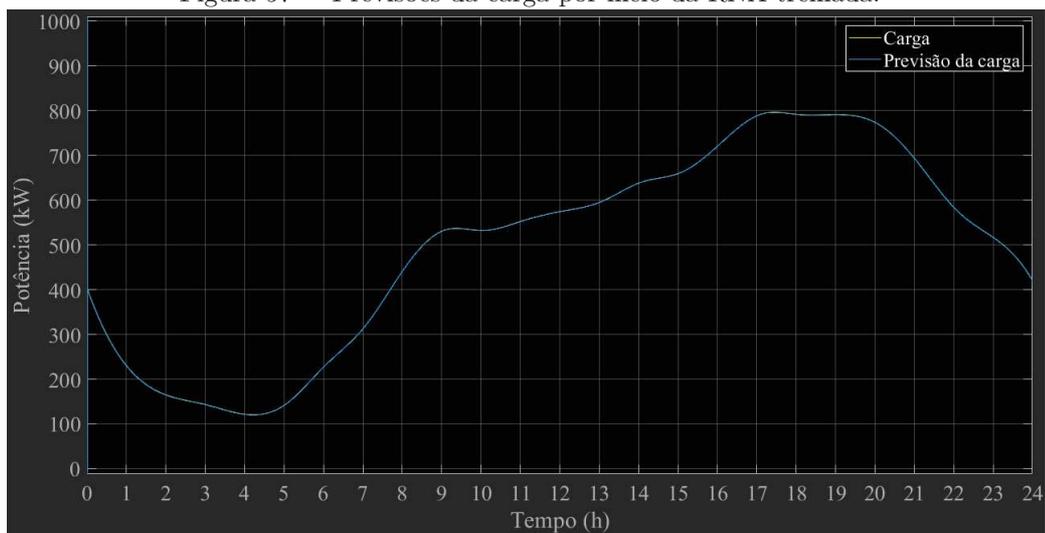


Fonte: o autor.

C.0.2 As previsões realizadas

A Figura 57, apresenta as previsões realizadas para a demanda de cargas.

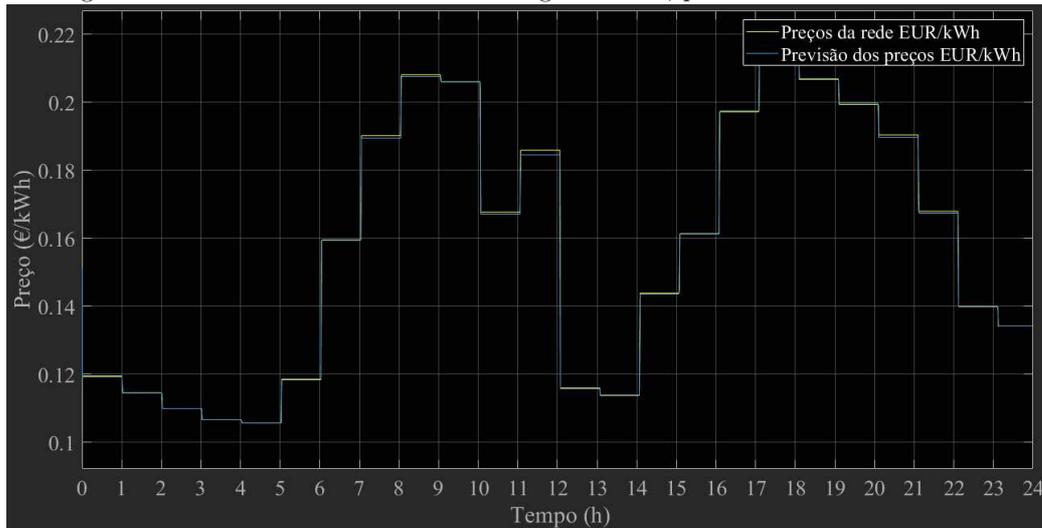
Figura 57 – Previsões da carga por meio da RNA treinada.



Fonte: o autor.

A Figura 58, apresenta as previsões realizadas para as preços de energia elétrica.

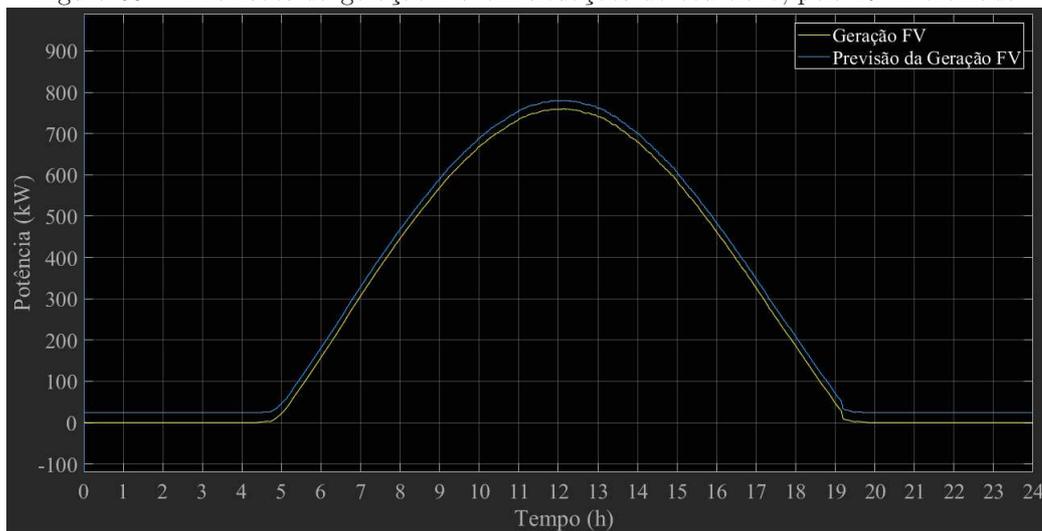
Figura 58 – Previsões dos custos de energia elétrica, por meio da RNA treinada.



Fonte: o autor.

A Figura 59, apresenta as previsões realizadas para a geração de energia elétrica FV no dia de céu claro.

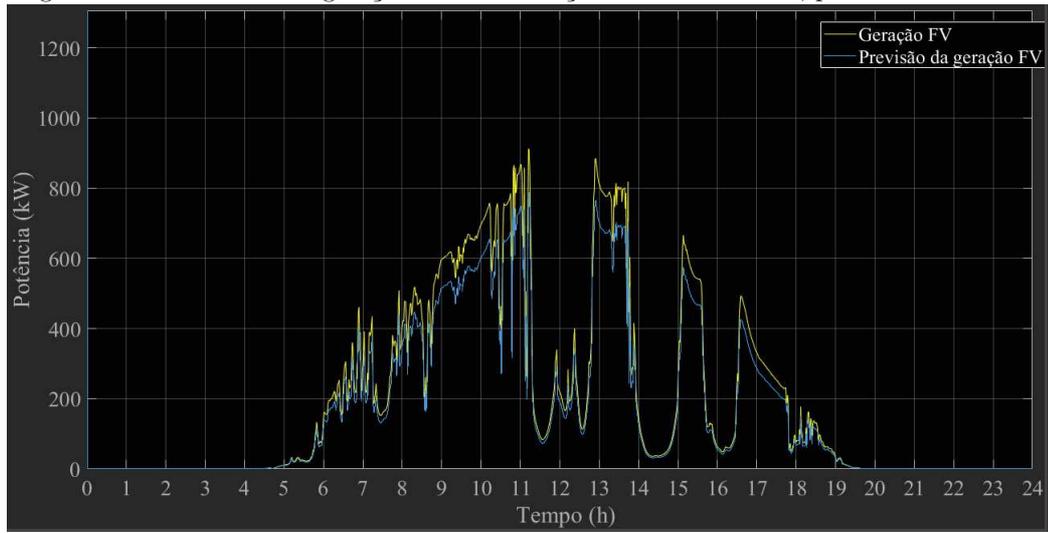
Figura 59 – Previsões da geração FV em situações do céu claro, pela RNA treinada.



Fonte: o autor.

A Figura 60, apresenta as previsões realizadas para a geração de energia elétrica FV no dia de céu nublado.

Figura 60 – Previsões da geração FV em situações do céu nublado, pela RNA treinada.



Fonte: o autor.

APÊNDICE D – Publicações

D.1 Apresentações em conferências

Título: **Análise e Avaliação Operacional da Metodologia de Controle V/f Aplicada em Situações de Ilhamento Intencional**

Conferência: **2021 14th IEEE International Conference on Industry Applications (INDUSCON)** *Electronic* ISBN: **978-1-6654-4118-6**

Nome: Guilherme Henrique Alves	Instituição: UFU
Nome: Geraldo Caixeta Guimarães	Instituição: UFU
Nome: Fabricio Augusto Matheus Moura	Instituição: UFTM
Nome: Arthur Costa De Souza	Instituição: UNIFEI - Campus Itabira
Nome: Antônio Manoel Batista da Silva	Instituição: UNIUBE

Título: **Avaliação Operacional de Microrrede Mediante Ilhamento Intencional**
 Conferência: **CBQEE 2021 - XIV Conferência Brasileira sobre Qualidade da Energia Elétrica** ISBN: **978-65-89463-06-1**

Nome: Guilherme Henrique Alves	Instituição: UFU
Nome: Geraldo Caixeta Guimarães	Instituição: UFU
Nome: Fabricio Augusto Matheus Moura	Instituição: UFTM
Nome: Arthur Costa de Souza	Instituição: UNIFEI - Campus Itabira

D.2 Publicações em periódicos

Título: *Proposal of a Master–Slave Control for an Isolated Microgrid after an Intentional Islanding*

Periódico: **2023 - Journal of Control, Automation and Electrical Systems**
Electronic ISSN: **2195-3899** Print ISSN: **2195-3880**

Nome: Guilherme Henrique Alves	Instituição: UFU
Nome: Geraldo Caixeta Guimarães	Instituição: UFU
Nome: Fabrício Augusto Matheus Moura	Instituição: UFTM
Nome: Arthur Costa de Souza	Instituição: UNIFEI - Campus Itabira
Nome: Lúcio Rogério Júnior	Instituição: UFU
Nome: Leonardo Rosenthal Caetano Silva	Instituição: IFG - Câmpus Itumbiara

Título: *Battery Storage Systems Control Strategies with Intelligent Algorithms in Microgrids with Dynamic Pricing*

Periódico: 2023 - *Energies, MDPI*

Electronic ISSN: 1996-1073

Nome: **Guilherme Henrique Alves**

Instituição: **UFU**

Nome: **Geraldo Caixeta Guimarães**

Instituição: **UFU**

Nome: **Fabício Augusto Matheus Moura**

Instituição: **UFTM**