

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA

Determinação das condições operativas de Microrredes baseada em Redes Neurais

Luiz Fernando Ribas Monteiro

Itajubá, dezembro 2020

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA

Luiz Fernando Ribas Monteiro

Determinação das condições operativas de Microrredes baseada em Redes Neurais

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica como parte dos requisitos para obtenção do Título de Mestre em Ciências em Engenharia Elétrica.

Área de Concentração: Microeletrônica.

Orientador: Professor Dr. Luís Henrique de Carvalho Ferreira.

Dezembro de 2020
Itajubá

As informações são fornecidas pela Biblioteca Mauá - BIM

MONTEIRO, Luiz Fernando Ribas

Determinação das condições operativas de Microrredes baseada em
Redes Neurais / Luiz Fernando Ribas Monteiro.

Itajubá: UNIFEI, 2020.

83 p.

Dissertação (mestrado) – Universidade Federal de Itajubá,
2020.

Orientador: Prof. Dr. Luís Henrique de Carvalho Ferreira.

1. ANN. 2. Geração Renovável. 3. Planejamento. 4. Operação
do sistema de potência. 5. Limites de Tensão. I. Ferreira, Luís
Henrique de Carvalho. II. Universidade Federal de Itajubá. III.
Título.

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA

Luiz Fernando Ribas Monteiro

Determinação das condições operativas de Microrredes baseada em Redes Neurais

Dissertação aprovada por banca examinadora em 18 de dezembro de 2020, conferindo ao autor o título de *Mestre em Ciências em Engenharia Elétrica*.

Banca Examinadora:

Prof. Dr. Luís Henrique de Carvalho Ferreira (Orientador)

Prof. Dr. Fernando Henrique Duarte Guaracy

Prof. Dr. Felipe Oliveira e Silva

Itajubá

2020

Aos meus pais, irmãs e minha querida
avó (*in memoriam*).

Agradecimentos

A Deus, pela força, proteção, pelas pessoas maravilhosas que passaram e as que estão presentes na minha vida e por tudo que conquistei. Peço sabedoria para continuar minha caminhada.

Aos meus pais Luiz Carlos e Maria Inês, pelo incentivo e apoio que sempre me deram.

À minha irmã Juliana, Máira e ao meu cunhado Yuri, por todo apoio que sempre deram.

Aos meus familiares e amigos, pela companhia mesmo que distante.

Um agradecimento especial ao Professor Luís Henrique, pela atenção, paciência na solução das dúvidas, pelo tempo dedicado e amizade.

Aos servidores técnico-administrativos e Professores da UNIFEI, pela atenção.

À banca examinadora, pelas sugestões construtivas.

Aos colegas do grupo da Micro.

À CAPES, pela bolsa de mestrado.

E a todos os meus Professores, que de certa forma contribuíram para a construção do meu conhecimento.

“A mente que se abre a uma nova
ideia jamais voltará ao seu tamanho
original”.

(Albert Einstein)

Resumo

O aumento da inserção de geração renovável, principalmente eólica e solar, traz novos desafios para o planejamento e operação de sistemas elétricos de potência devido à sua dependência de condições climáticas. Nesta perspectiva, esta dissertação tem o objetivo de propor uma metodologia com base em Redes Neurais Artificiais (ANN) de reconhecimento de padrão e mapa auto organizável para auxiliar no planejamento e operação do sistema de potência. Neste contexto, as condições operacionais que podem levar o sistema à violação dos limites de tensão podem ser identificadas possibilitando a realização de ações de controle corretivas. Além disso, a abordagem proposta é capaz de identificar a unidade específica responsável por conduzir o sistema a uma condição operativa insatisfatória. Para isso, a metodologia é testada em uma microrrede representada pelo sistema IEEE 34-barras trifásico desequilibrado modificado, considerando o emprego de geração eólica e solar. O conjunto de dados de condições operativas satisfatórias e insatisfatórias são obtidos empregando a simulação de Monte Carlo. Para este propósito, o fluxo de potência por varredura *backward-forward* é empregado. Em seguida esses dados são fornecidos às ANNs para treinamento, validação e teste. Os resultados obtidos indicam uma metodologia robusta capaz de auxiliar na tomada de decisão e determinar ações de controle durante a operação do sistema com alta inserção de renováveis evitando assim sobretensões.

Palavras-chave – ANN, geração renovável, planejamento, operação do sistema de potência, limites de tensão.

Abstract

The increased insertion of renewable generation, mainly wind and solar, brings new challenges for the planning and operation of electric power systems due to its dependence on climatic conditions. In this perspective, this dissertation aims to propose a methodology based on Artificial Neural Networks (ANN) for pattern recognition and a self-organizing map to assist in the planning and operation of the power system. In this context, the operational conditions that can lead the system to breach of voltage limits can be identified, enabling corrective control actions to be carried out. In addition, the proposed approach is able to identify the specific unit responsible for driving the system to an unsatisfactory operating condition. For this, the methodology is tested in a microgrid represented by the modified unbalanced three-phase IEEE 34-bus system, considering the use of wind and solar generation. The data set of satisfactory and unsatisfactory operating conditions are obtained using the Monte Carlo simulation. For this purpose, the backward-forward scan power flow is employed. These data are then provided to ANNs for training, validation and testing. The results obtained indicate a robust methodology capable of assisting in decision making and determining control actions during the operation of the system with high insertion of renewables, thus avoiding overvoltages.

Keywords - ANN, renewable generation, planning, power system operation, voltage limits.

Lista de Figuras

Figura 1.1 – Microrrede.....	17
Figura 1.2 - Operador Nacional do Sistema Elétrico (ONS).....	20
Figura 2.1 - Ilustração de um neurônio biológico [33].....	26
Figura 2.2 - Modelo não linear de um neurônio [31]	27
Figura 2.3 - Função de ativação sigmóide.....	28
Figura 2.4 - Rede alimentada diretamente com duas camadas ocultas [33].....	30
Figura 2.5 - MLP (<i>Multilayer Perceptron</i>) [31].....	31
Figura 2.6 - Fluxo de processamento do algoritmo <i>backpropagation</i> [33].....	32
Figura 2.7 - Arquitetura rede SOM [33].....	35
Figura 2.8 - Funcionamento da rede SOM	36
Figura 2.9 - Fluxograma para implementação da técnica de varredura <i>backward-forward</i>	39
Figura 2.10 - Ilustração simplificada do método de Monte Carlo.....	42
Figura 3.1 - Circuito equivalente do modelo exponencial simples [38].....	43
Figura 3.2 -Resposta da turbina [41]	49
Figura 3.3 - Fluxograma - Monte Carlo	52
Figura 3.4 - Fluxograma – ANN de reconhecimento de padrão	54
Figura 3.5 - Fluxograma - ANN mapa auto-organizável.....	55
Figura 3.6 - Fluxograma da abordagem proposta.....	56
Figura 4.1 - Sistema IEEE 34-barras modificada [42]	57
Figura 4.2 - Verificação do erro de validação: (a) ANN1, (b) ANN2, (c) ANN3.....	59
Figura 4.3 - Performance do treinamento das ANNs: (a) ANN1, (b) ANN2, (c) ANN3.....	60
Figura 4.4 - Matriz <i>Confusion</i> para o teste de 5900 amostras: (a) ANN1, (b) ANN2, (c) ANN3	62
Figura 4.5 - Hits: (a) ANN1, (b) ANN2, (c) ANN3	63
Figura 4.6 - Posições dos pesos da SOM: (a) ANN1, (b) ANN2, (c) ANN3.....	64
Figura 4.7 - Perfil de velocidade do vento.....	65
Figura 4.8 - Perfil de temperatura.....	66
Figura 4.9 - Perfil de radiação solar	66
Figura 4.10 - Perfil de geração eólica e solar	67
Figura 4.11 - Perfil de carga de potência ativa.....	67
Figura 4.12 - Perfil de carga de potência reativa.....	68

Figura 4.13 - Perfil de tensão na fase a.....	69
Figura 4.14 - Perfil de tensão na fase b	69
Figura 4.15 - Perfil de tensão na fase c.....	70
Figura 4.16 - Máxima tensão na fase a, b, c	70
Figura 4.17 - Identificação da sobretensão na MG e devido ao Gerador 1	71
Figura 4.18 - Identificação da sobretensão devido ao Gerador 2	72
Figura 4.19 - Perfil de tensão após a compensação na fase a.....	73
Figura 4.20 - Perfil de tensão após a compensação na fase b.....	73
Figura 4.21 - Perfil de tensão após a compensação na fase c.....	74

Lista de Tabelas

Tabela 4.1 - Descrição do conjunto de amostras para treinamento e teste.....	58
Tabela 4.2 - Resultados da etapa de testes das ANNs.....	62

Lista de Abreviaturas e Siglas

AI	<i>artificial intelligence</i>
ANEEL	Agência Nacional de Energia Elétrica
ANNs	<i>artificial neural networks</i>
BESS	<i>battery energy storage system</i>
CHP	<i>combined heat and power</i>
CPS	critério de porcentagem de sucesso
DERs	<i>distributed energy resources</i>
DGs	<i>distributed generations</i>
DWT	<i>discrete wavelet transform</i>
EMS	<i>energy management system</i>
ESSs	<i>energy storage systems</i>
Evs	<i>electric vehicle</i>
FC	<i>fuel cell</i>
GA	<i>genetic algorithms</i>
G2V	<i>grid-to-vehicle</i>
IEEE	Instituto de Engenheiros Eletricistas e Eletrônicos
MGs	<i>microgrids</i>
MILP	<i>mixed integer linear programming</i>
MLP	<i>multilayer perceptron</i>
MMC	Método de Monte Carlo
MMG	muti-microrredes
MSE	mean squared error
ONS	Operador Nacional do Sistema Elétrico
PCC	<i>point of common coupling</i>
PDF	<i>probability density functions</i>
PV	<i>photovoltaic</i>
RESs	<i>renewable energy resources</i>
SEP	sistema elétrico de potência
SG	<i>smart grid</i>
SOM	<i>self-organizing maps</i>
VPPs	<i>virtual power plants</i>

V2G *vehicle-to-grid*
ZIP impedância, corrente e potência

Sumário

1	Capítulo – Introdução.....	16
1.1	Considerações Iniciais do Trabalho.....	16
1.2	Contextualização do Problema	16
1.3	Revisão da Literatura	17
1.4	Motivação	19
1.5	Objetivos.....	20
1.6	Estrutura do Trabalho	21
2	Capítulo - Revisão de Conceitos.....	22
2.1	Redes Neurais Artificiais (ANNs).....	22
2.1.1	Definição.....	22
2.1.2	Propriedades das ANNs	23
2.1.2.1	Não Linearidade.....	23
2.1.2.2	Mapeamento de Entrada-Saída	23
2.1.2.3	Adaptabilidade	24
2.1.2.4	Resposta a Evidências.....	24
2.1.2.5	Informação Contextual.....	24
2.1.2.6	Tolerância a Falhas	24
2.1.2.7	Uniformidade de Análise e Projeto.....	24
2.1.2.8	Analogia Neurobiológica	25
2.1.3	Modelo de um Neurônio	25
2.1.3.1	Modelo de Neurônio Biológico.....	25
2.1.3.2	Modelo de Neurônio Artificial.....	26
2.1.4	Funções de Ativação	28
2.1.4.1	Função de ativação sigmóide	28
2.1.5	Arquitetura de Redes Neurais	29
2.1.5.1	Redes Neurais Alimentadas Diretamente com Múltiplas Camadas... 29	
2.1.6	Rede Neural Artificial <i>Multilayer Perceptron</i> (MLP).....	30
2.1.6.1	Algoritmo de Treinamento <i>Backpropagation</i>	31
2.1.7	Mapas Auto-organizáveis	35
2.1.7.1	Treinamento Rede SOM	37
2.2	Formulação do Fluxo de Potência	37

2.2.1	Fluxo de Potência Trifásico Desequilibrado	38
2.3	Método de Monte Carlo	42
3	Capítulo – Metodologia e Desenvolvimento	43
3.1	Microrrede (MG)	43
3.1.1	Recursos de Energia Distribuídos	43
3.1.1.1	Modelo do Sistema Fotovoltaico	43
3.1.1.2	Modelo do Sistema de Geração Eólica	48
3.1.2	Modelo de Carga	50
3.2	Formulação do Problema	50
4	Capítulo - Resultados e Análises	57
4.1	Treinamento, Validação e Teste das Redes Neurais	58
4.1.1	ANN de Reconhecimento de Padrão	58
4.1.2	ANN de Mapa Auto-Organizável	62
4.2	Aplicação da Metodologia Proposta	65
5	Capítulo - Conclusões	75
5.1	Considerações Finais	75
5.2	Principais Contribuições	75
5.3	Propostas de Trabalhos Futuros	76
	Referências	77
	Anexo A – Dados do Sistema IEEE de 34-Barras	81

1 Capítulo – Introdução

1.1 Considerações Iniciais do Trabalho

O sistema elétrico de potência (SEP) é definido como um conjunto de equipamentos e elementos de circuitos elétricos conectados que operam de forma coordenada, destinados à geração, transmissão e distribuição de energia elétrica. Ele tem a função principal de fornecer energia elétrica aos consumidores, com qualidade adequada, no momento em que for solicitada [1].

Alguns fatores estão impulsionando a evolução da rede elétrica tradicional para uma rede inteligente ou do inglês *smart grid* (SG). Dentre os principais fatores que podem ser destacados são: a crescente preocupação ambiental, o aumento da demanda de energia elétrica tanto pelo setor industrial quanto pela população, a necessidade de diversificação de geração de fontes de energia, a inserção de veículos elétricos (ou do inglês *electric vehicle*, EVs) e novas tecnologias e a confiabilidade da rede [2] – [4].

Esta nova configuração é mais complexa e integra fontes de energia tradicionais e sustentáveis, que podem ter gerações intermitentes, exigindo níveis mais altos de gerenciamento do lado da demanda. O fluxo de potência é bidirecional o que requer um controle distribuído [2] – [4].

Com o tempo, os SEPs passaram a atender demandas expressivas e cada vez maiores de energia elétrica, tornando-se sistemas predominantes de grande porte. A evolução completa para uma SG torna-se mais complexa quando se observa o tamanho do sistema elétrico. Desta forma, a evolução do sistema tradicional para uma SG não deve ocorrer de forma rápida, já que uma SG necessita de uma infraestrutura dependente de fatores financeiros, técnicos e regulatórios. Deste modo, a mudança está ocorrendo com a inserção de estruturas ou regiões chamadas microrredes ou do inglês *microgrids* (MGs).

1.2 Contextualização do Problema

Tradicionalmente, o sistema de distribuição é representado por cargas passivas fornecidas por meio de um fluxo de energia unidirecional entre a geração e os consumidores. No entanto, este cenário tem mudado devido ao surgimento de MGs, que fazem a energia fluir bidirecionalmente e possuem recursos distribuídos de energia (ou do inglês *distributed energy resources*, DERs) como recursos de energia renovável (ou do inglês *renewable energy*

resources, RESs), EVs, sistemas de armazenamento de energia (ou do inglês *energy storage systems*, ESSs) e cargas controláveis [5].

As MGs podem ser de vários tipos, possuir diversos tamanhos, funcionalidades e configurações. Podem ser sistemas extensos e complexos, com até dezenas de MW de tamanho ou podem ser redes pequenas e simples, na faixa de centenas de kW, atendendo alguns consumidores, e possuírem faixas de operação de baixa e média tensão (400 V a 69 kV) [6]. Elas são capazes de operar conectadas à rede e isoladas. Devido à sua capacidade de operar no modo ilha, elas melhoram consideravelmente a confiabilidade da rede elétrica [7]. As MGs possuem um ponto de acoplamento comum ou do inglês *point of common coupling* (PCC) com uma grande rede de energia. A figura 1.1 ilustra um exemplo de uma microrrede.

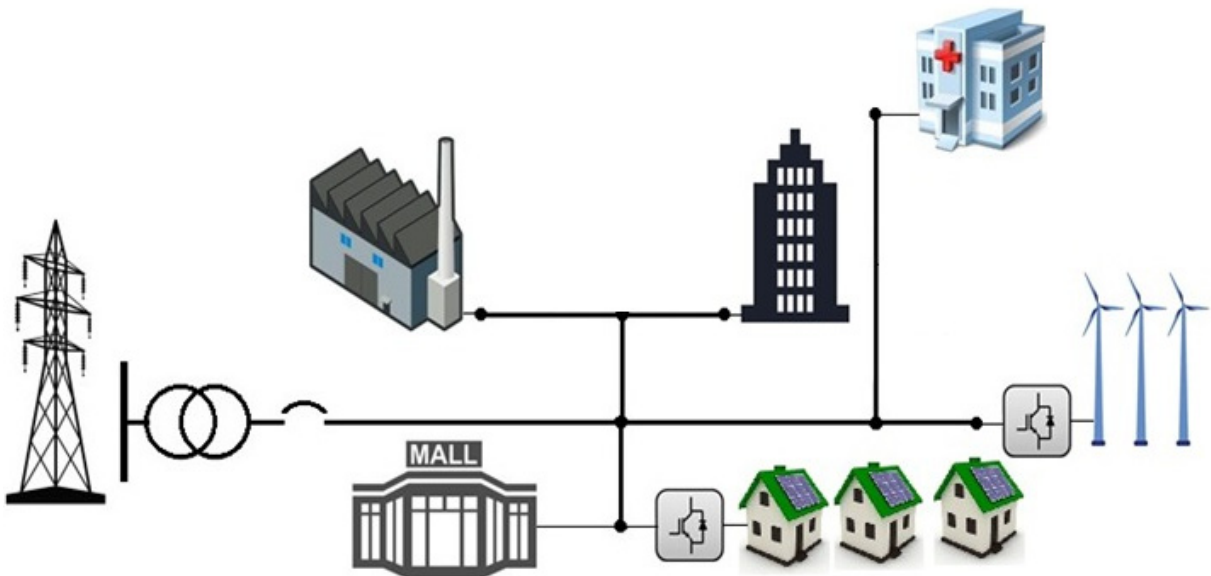


Figura 1.1 – Microrrede

1.3 Revisão da Literatura

Essas mudanças apresentam um impacto significativo na operação e planejamento dos sistemas de potência. São necessárias ferramentas para garantir uma operação confiável diante da intermitência dos RESs causada por variações nas condições climáticas.

Na literatura, vários trabalhos significativos foram propostos para melhorar a operação e o planejamento da MG. Em [8] é proposto um método de otimização robusto baseado em programação linear inteira mista (ou do inglês *mixed integer linear programming*, MILP) considerando os efeitos da incerteza do preço de mercado na operação de MGs híbridas. Um

método de operação distribuída para MGs conectadas à rede e ilhadas é proposto em [9] e pode determinar o comércio de energia bidirecional com a rede principal. Já em [10] é desenvolvida uma estratégia de operação de MG em dois estágios na qual a reserva de controle de frequência é utilizada para garantir uma operação econômica, confiável e estável em um ambiente de mercado de energia conjunta e serviços auxiliares. Um sistema de armazenamento de energia por bateria (ou do inglês *battery energy storage system*, BESS) é aplicado como um recurso para resiliência em [11]. Já [12] incorpora modelos dinâmicos eletromecânicos de múltiplos estados de carga para avaliar as operações de MGs de baixa inércia, mostrando melhoria econômica e suporte a operações resilientes. Os autores de [13] propõem um modelo de despacho otimizado com limite de rampa de dois estágios para MG com presença de geração fotovoltaica (ou do inglês *photovoltaic*, PV). O trabalho [14] propõe uma métrica de flexibilidade operacional para quantificar a capacidade da MG combinada de calor e energia (ou do inglês *combined heat and power*, CHP) sob as incertezas de RESs.

Um planejamento é apresentado em [15] para alocar e dimensionar geradores distribuídos junto com estações de carregamento de VEs e assim equilibrar o fornecimento/demanda. Em um mercado de eletricidade, o autor [16] aborda um planejamento da expansão da MG, onde auxilia na tomada de decisões de empresas de MGs comunitárias. O trabalho [17] investiga se a receita da MG compensa o investimento e determina a combinação ideal de DERs a ser implantada. A pesquisa [18] aborda um planejamento para uma MG parcialmente autossuficiente com uma quantidade limitada de troca de eletricidade anual. Em [19] é proposto um modelo de otimização de dois níveis que fornece uma estrutura hierárquica de tomada de decisão para o planejador da MG e para o sistema de gerenciamento de energia (ou do inglês *energy management system*, EMS). O estudo [20] apresenta uma metodologia para determinar o dimensionamento e a localização ideais de capacitores *shunt* e uma mistura de gerações distribuídas (ou do inglês *distributed generations*, DGs) despacháveis e intermitentes.

A lógica difusa, ou do inglês *fuzzy logic*, é aplicada em um modelo de otimização multi-objetivo com restrições para minimizar o custo econômico total e a perda de energia da MG [21]. Em [22] é apresentada uma técnica de otimização de algoritmos genéticos (ou do inglês *genetic algorithms*, GA) para operação *on-line* de DGs, como um sistema híbrido de célula de combustível (ou do inglês *fuel cell*, FC) e PV para aplicações residenciais. O trabalho [23] aplica redes neurais artificiais, ou do inglês *artificial neural networks* (ANNs), para detectar ilhamento de geradores síncronos distribuídos, enquanto [24] propõe um método de detecção, classificação e localização de falhas baseado em transformada de *wavelet* discreta, ou do inglês

discrete wavelet transform (DWT), e uma ANN baseada em Taguchi. Os autores [25] utilizam ANNs para rastrear o ponto de potência máxima dos geradores de energia renovável e para controlar a troca de energia entre o conversor *front-end* e a rede elétrica e também propõem um EMS baseado em lógica *fuzzy* a fim de minimizar a energia comprada da rede elétrica. Para o gerenciamento de usinas de energia virtuais (ou do inglês *virtual power plants*, VPPs) é desenvolvido em [26] um método de predição descentralizada distribuída baseado em ANNs. Uma ferramenta para previsão de densidade de energia eólica de curto prazo por meio de ANNs para operação da MG é apresentada em [27]. Em [28] é abordada uma estratégia para o planejamento ideal e projeto de MGs com base na previsão de carga a longo prazo usando ANNs de multicamadas *perceptron* (ou do inglês *multilayer perceptron*, MLP). E em [29] é desenvolvida uma otimização de oferta e demanda operacional usando ANNs e GA.

O uso de técnicas de inteligência artificial (ou do inglês *artificial intelligence*, AI) em sistemas intermitentes, complexos, não-lineares, com parâmetros variantes no tempo e sem exatidões adequadas, são alternativas que apresentam ótimos resultados em aplicações práticas [30], como metodologias baseadas em ANNs.

Os modelos baseados em ANNs têm interpretações mais robustas no que diz respeito às incertezas do sistema, têm uma boa capacidade de mapear características não-lineares de operação e possuem uma característica adaptativa [31]. As ANNs têm ainda capacidades de adaptações aos contextos em que são utilizadas, apresentando resultados otimizados em relação aos algoritmos convencionais elaborados para as mesmas tarefas correspondentes [32].

1.4 Motivação

Buscando atender à necessidade de entrada de novas tecnologias na rede, preocupações globais com o meio ambiente e o crescente consumo de energia, o sistema elétrico está se transformando gradualmente em SGs.

As MGs são consideradas regiões ou estruturas propícias para se começar a transformação da rede tradicional em SGs. A possibilidade de integração de novas fontes de energia, a melhora da confiabilidade e a diversificação da matriz energética, têm encorajado o desenvolvimento das MGs.

Observando a problemática da intermitência dos recursos renováveis, principalmente a geração de energia solar e a eólica, são necessárias ferramentas para auxiliar a operação desses sistemas e ajudar no planejamento da expansão da rede.

1.5 Objetivos

Os objetivos deste trabalho estão descritos a seguir:

- Auxílio nas tomadas de decisões sobre o planejamento da operação de MGs com geradores renováveis distribuídos: A ferramenta proposta orienta a alocação de novas gerações distribuídas trazendo eficiência ao planejamento da MG.
- Determinação de ações de controle durante a operação de MGs com alta penetração de geração distribuída: a ação correta do operador do sistema traz uma operação confiável e precisa para retomar a normalidade, quando uma geração renovável provoca a violação de tensão.

A figura 1.2 ilustra uma aplicação da ferramenta desenvolvida neste trabalho.



Figura 1.2 - Operador Nacional do Sistema Elétrico (ONS)

1.6 Estrutura do Trabalho

A estrutura do trabalho está organizada conforme descrito a seguir. O Capítulo 2 revisa alguns conceitos aplicados durante o desenvolvimento da pesquisa. O Capítulo 3 descreve a modelagem matemática da MG adotada na proposta. Além disso, ele aborda a formulação do problema e os detalhes para descrever a metodologia sugerida. O Capítulo 4 apresenta os resultados obtidos por meio de simulações computacionais e a respectiva discussão. Ele também introduz as contribuições do trabalho. O Capítulo 5 realiza as considerações finais, apresenta as contribuições gerais e sugestões para trabalhos futuros.

2 Capítulo - Revisão de Conceitos

Este Capítulo apresenta os conceitos básicos e fundamentos necessários para o desenvolvimento desta dissertação, fornecendo os subsídios essenciais para a compreensão da metodologia a ser utilizada.

2.1 Redes Neurais Artificiais (ANNs)

A rede neural artificial é um modelo computacional formado por um conjunto de unidades de processamento individuais, os neurônios artificiais, interligados por pesos que podem ser modificados de acordo com os parâmetros de qualidade que avaliam a proximidade entre a resposta requerida e a obtida. Ela tem a capacidade de aprender à medida que os pesos das interconexões entre os neurônios são ajustados de acordo com a saída desejada [31] - [32].

Neste capítulo são abordados os conceitos teóricos importantes sobre redes neurais, explicitando as vantagens da rede neural, o modelo de um neurônio, os tipos de redes existentes, funções de ativação, arquiteturas e o algoritmo de treinamento utilizado.

2.1.1 Definição

As pesquisas em redes neurais artificiais têm sido instigadas pela percepção de que o cérebro humano efetua o processamento de informações de forma completamente diferente dos computadores. O cérebro humano é um “computador” com alta complexidade, não-linear e paralelo. Ele apresenta a aptidão de organizar seus componentes estruturais, conhecidos como neurônios, fazendo com que efetue alguns processamentos (como, por exemplo, reconhecimento de padrões, percepção e controle motor) com maior velocidade do que um computador [31] - [33].

De forma geral, a rede neural pode ser entendida como uma máquina que é construída para modelar a forma como o cérebro realiza uma determinada tarefa. Geralmente, ela é projetada utilizando simulação computacional ou componentes eletrônicos. Segundo [31], a rede neural pode ser definida como “um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que apresentam a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso”.

Fazendo analogia ao cérebro humano, há dois aspectos aos quais a rede neural se assemelha [31]:

- A rede obtém conhecimento com base no seu ambiente de trabalho por meio de um processo de aprendizagem,

- Os pesos sinápticos, forças de conexão entre neurônios, são usados para armazenar o conhecimento obtido [31].

O algoritmo de aprendizagem consiste no processo utilizado para realizar a aprendizagem da rede neural. Ele possui a função de alterar os pesos sinápticos da rede de maneira ordenada a fim de atingir o objetivo do projeto. Esse é o método tradicional para realizar o projeto de redes neurais [33].

Na literatura, as redes neurais também são conhecidas como *modelos conexionistas*, *neurocomputadores* e *processadores paralelamente distribuídos* [31] - [33].

2.1.2 Propriedades das ANNs

Para os autores [31] – [33], o uso da Rede Neural Artificial oferece diversas propriedades úteis e capacidades, tais como: não linearidade; mapeamento de entrada-saída; adaptabilidade; resposta a evidências; informação contextual; tolerância a falhas; uniformidade de análise e projeto; analogia neurobiológica. Tais características são descritas a seguir.

2.1.2.1 Não Linearidade

A não linearidade é distribuída de forma integral na rede sendo uma propriedade significativa, especialmente levando em consideração se a origem do sinal de entrada for intrinsecamente não linear (como por exemplo, o sinal de voz) [31].

2.1.2.2 Mapeamento de Entrada-Saída

A aprendizagem supervisionada engloba as alterações dos pesos sinápticos de uma ANN realizando a aplicação de um grupo de amostras de treinamento com rótulos ou exemplos da tarefa. Todo modelo apresenta um sinal de entrada único e uma correspondente resposta desejada. Escolhe-se um exemplo do conjunto de forma aleatória e apresenta-o para a rede. Para atenuar a possível diferença entre a resposta desejada e a resposta real da rede, criada pelo sinal de entrada, os pesos sinápticos são alterados de acordo com um critério estatístico adequado. Este treinamento da rede é realizado e repetido para diversas amostras do conjunto até que não ocorra mais alterações consideráveis nos pesos sinápticos e conseqüentemente a ANN atinja um estado de estabilidade [31] e [33].

As amostras de treinamento aplicadas primeiramente podem ser reaplicadas, mas em uma ordem diferente durante a sessão de treinamento. Dessa forma, a ANN aprende com as amostras ao criar um mapeamento de entrada e saída [32].

2.1.2.3 Adaptabilidade

De maneira natural, as ANNs possuem a habilidade de adaptar seus pesos sinápticos a mudanças do ambiente. Uma rede neural treinada para trabalhar numa situação particular pode ser retreinada com facilidade para enfrentar pequenas alterações no estado operativo do ambiente. Outrossim, a rede pode ser projetada para alterar os pesos sinápticos de maneira simultânea quando trabalha em uma situação não estacionária. Devido a sua capacidade de adaptação, a rede neural é uma ferramenta útil para aplicações em modelagem de sistemas, em controle de processos e em processamentos de sinais [31] e [33].

2.1.2.4 Resposta a Evidências

A rede neural utilizada na circunstância de classificação de padrões, pode fornecer não só a informação sobre qual padrão particular é selecionado, mas também informar qual é o nível de confiança do resultado apresentado. Portanto, essas informações podem ser utilizadas para rejeitar padrões ambíguos e, por consequência melhorar a performance de classificação da rede [31] – [33].

2.1.2.5 Informação Contextual

A estrutura e o estado de ativação de uma ANN representam o conhecimento. Na rede, todo neurônio pode ser afetado pela atividade de qualquer outro neurônio presente nela. Desse modo, a ANN trata a informação de forma natural [31].

2.1.2.6 Tolerância a Falhas

A implementação de uma rede neural em *hardware* pode ser intrinsicamente tolerante a falhas, ou graças a uma computação robusta, sua performance diminui de forma suave sob condições de trabalho adversas. Para que a resposta seja seriamente prejudicada, o dano no neurônio deve ser extenso devido à natureza distribuída da informação guardada na rede neural. No entanto, para garantir que uma rede neural seja verdadeiramente tolerante a falhas, pode haver a necessidade de criar medidas corretivas no projeto do algoritmo de treinamento da rede [31] – [33].

2.1.2.7 Uniformidade de Análise e Projeto

Segundo [31], “as redes neurais desfrutam de universalidade como processadores de informação”. Isto quer dizer que em todos os domínios envolvendo as aplicações de redes

neurais são utilizadas a mesma notação. Os neurônios são comuns a todas as redes neurais e a partir deles é possível compartilhar teorias e algoritmos [33].

2.1.2.8 Analogia Neurobiológica

A analogia com o cérebro humano é um dos motivadores para o projeto de uma rede neural. Segundo o autor [31] “é prova viva de que o processamento paralelo tolerante a falhas é possível fisicamente, mas também rápido e poderoso”. Há dois pontos de vista a respeito da neurobiologia: no primeiro, os neurobiólogos encaram as ANNs como mecanismo de pesquisa para compreensão dos fenômenos neurobiológicos. Já no segundo, os engenheiros buscam ideias para solução de problemas mais complexos do que aqueles cujo a solução tem base em técnicas convencionais de projetos por conexões fixas [32] e [33].

2.1.3 Modelo de um Neurônio

A unidade básica de processamento de uma ANN é o neurônio, também chamado de nó ou célula. Esta unidade de processamento é um modelo matemático e sua modelagem é inspirada no neurônio biológico. Inicialmente, nesta sessão, será descrito o modelo de um neurônio biológico e posteriormente o modelo de neurônio artificial [32].

2.1.3.1 Modelo de Neurônio Biológico

Na estrutura do sistema nervoso biológico, o neurônio é definido como uma célula nervosa muito especializada. Os neurônios interligam-se criando uma rede disposta em camadas. As informações referentes a uma determinada funcionalidade (como por exemplo, visão e audição) são processadas por estas redes [32]. Estima-se que o cérebro humano possui bilhões de neurônios [31] - [32].

Os neurônios podem ser divididos em três sessões básicas: o corpo da célula, os dendritos e o axônio, cada uma com funções específicas, porém complementares [31] - [33]. A representação de um neurônio biológico é ilustrada na Figura 2.1.

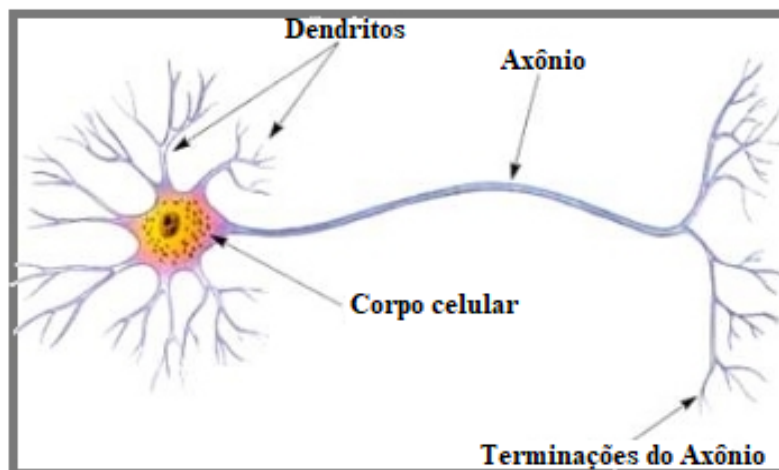


Figura 2.1 - Ilustração de um neurônio biológico [33]

Os dendritos são os elementos receptores, as entradas de um neurônio, os quais têm a função de receber as informações (impulsos nervosos) oriundos de outros neurônios e conduzi-las até o corpo celular. No corpo celular (núcleo), a informação é processada e novos impulsos são criados. Estes novos impulsos gerados são transmitidos a outros neurônios passando através do axônio até os dendritos do próximo neurônio. A região onde acontece o ponto de contato entre a terminação axônica de um neurônio e o dendrito de outro é conhecido como sinapse. As sinapses funcionam como válvulas, e são capazes de controlar a transmissão de impulsos, isto é, regulam a quantidade de informação que passam dos dendritos para a célula nervosa. Em outras palavras, as sinapses controlam o fluxo de informação. Além disso, as sinapses são importantes na memorização da rede, visto que as informações são armazenadas nelas. O axônio desempenha uma função de “linha de transmissão”, pois transporta o sinal de saída do neurônio. Já o corpo celular, é responsável pelo processamento dos sinais de entrada do neurônio.

2.1.3.2 Modelo de Neurônio Artificial

Para operação de uma rede neural, o neurônio é primordial, haja vista que ele consiste numa unidade de processamento de informações. Dessa forma, simular o comportamento de um neurônio biológico é de grande valia. Em 1943, McCullock e Pitts propuseram um modelo matemático, onde a representação básica de um neurônio está ilustrada na Figura 2.2 [31] - [33].

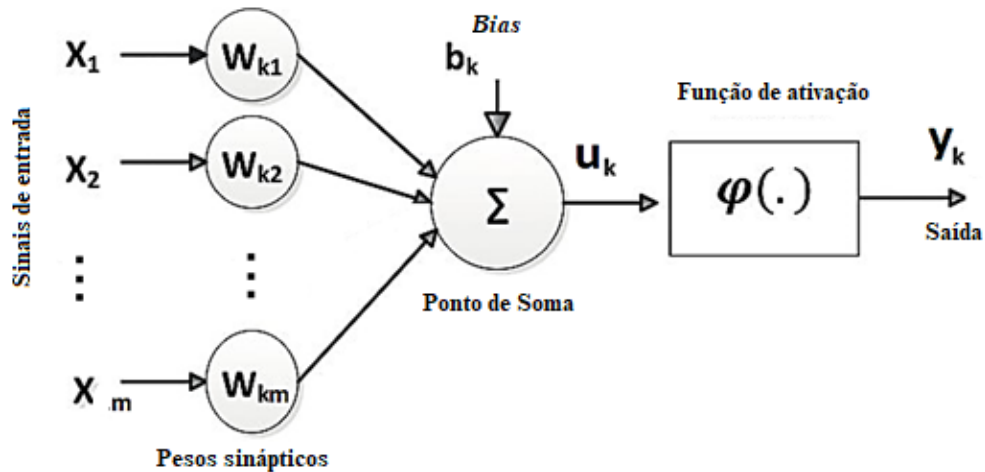


Figura 2.2 - Modelo não linear de um neurônio [31]

A operação do modelo ilustrado na Figura 2.2 pode ser resumida da seguinte forma [31] - [33]:

1. As informações de entrada são representadas pelo vetor $\mathcal{X} := [x_1, x_2, \dots, x_m]^T, m \in \mathbb{N} = [1, |\mathcal{X}|]$;
2. Os pesos sinápticos dos neurônios são descritos pelo vetor $W_k := [w_{k1}, \dots, w_{km}]^T, m \in \mathbb{N} = [1, |\mathcal{X}|]$;
3. u_k é a soma ponderada do produto dos sinais de entrada, vetor \mathcal{X} , com os pesos sinápticos, vetor W_k . Esta operação é uma combinação linear;
4. No modelo neural há também um *bias* que é um parâmetro externo ao neurônio, o qual é representado pelo b_k . Ele tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação;
5. $\varphi(\cdot)$ é a função de ativação (função restritiva) que tem a finalidade de restringir a amplitude da saída de um neurônio,
6. y_k é a resposta de saída do neurônio.

O modelo do neurônio artificial pode ser descrito pelo seguinte par de equações [31]:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2.1)$$

$$y_k = \varphi(u_k + b_k) \quad (2.2)$$

2.1.4 Funções de Ativação

A função de ativação representa a forma e a intensidade de alteração dos valores transmitidos de um neurônio a outro [31] - [32]. Segundo [31], “a função de ativação, representada por $\varphi(v)$, determina a saída de um neurônio em termos do campo local induzido v ”. Alguns tipos de funções de ativação são: limiar, linear por partes, e sigmóide [33]. Neste trabalho foi empregada a função de ativação sigmóide, a qual é descrita a seguir.

2.1.4.1 Função de ativação sigmóide

A função sigmóide é a forma mais utilizada na construção de redes neurais artificiais. O gráfico tem forma de “s” e é representado na Figura 2.3. Ela apresenta equilíbrio adequado entre comportamento linear e não linear e é uma função diferenciável. A função logística é um exemplo de função sigmóide [31]. A função sigmóide é expressa pela equação 2.3.




Figura 2.3 - Função de ativação sigmóide

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (2.3)$$

onde “ a ” é o parâmetro de inclinação.

Esta função de ativação é adotada para construir a rede neural de reconhecimento de padrões. Mais detalhes podem ser vistos no Capítulo 3, onde é detalhada a proposta.

2.1.5 Arquitetura de Redes Neurais

Os neurônios de uma rede neural podem estar agrupados por camadas com direcionamento ou não, i.e., com ligações num único sentido (para frente) ou em ambos (para frente e para trás [32]). A forma na qual eles estão estruturados está associada com o algoritmo de aprendizagem utilizado para o treinamento da rede. Segundo [31], há três tipos de topologias de rede diferentes, a saber: redes neurais alimentadas adiante com camada única, redes neurais alimentadas diretamente com múltiplas camadas e redes recorrentes. Neste trabalho foi empregado a arquitetura de rede neural alimentada diretamente com múltiplas camadas, a qual é descrita a seguir.

2.1.5.1 Redes Neurais Alimentadas Diretamente com Múltiplas Camadas

Esta classe de rede neural apresenta uma ou mais camadas ocultas, onde os nós computacionais são conhecidos como neurônios ocultos ou unidades ocultas [31]. Estes neurônios ocultos têm a função de intervir entre a entrada externa e a saída da rede de maneira adequada.

Ao adicionar uma ou mais camadas ocultas, torna-se esta rede capaz de extrair estatísticas de ordem elevada. Esta característica é de grande valia quando o tamanho da camada de entrada é elevado. A Figura 2.4 ilustra este tipo de arquitetura com duas camadas ocultas.

Devido às essas características apresentadas, esta arquitetura foi adotada para criação da rede neural de reconhecimento de padrões. Mais detalhes podem ser vistos no Capítulo 3, onde é detalhada a proposta.

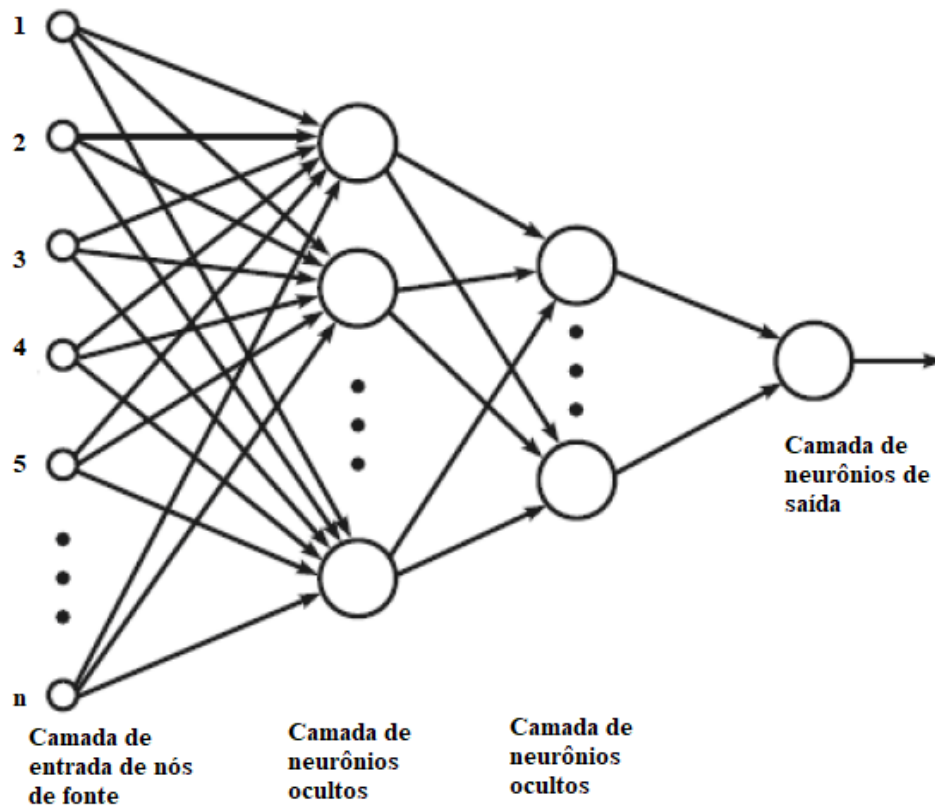


Figura 2.4 - Rede alimentada diretamente com duas camadas ocultas [33]

2.1.6 Rede Neural Artificial *Multilayer Perceptron* (MLP)

As redes neurais construídas com uma só camada resolvem apenas problemas linearmente separáveis (*Perceptron*). A solução de problemas não linearmente separáveis passa pelo uso de redes com uma ou mais camadas intermediárias ou ocultas [33]. Segundo [34], uma rede que apresenta uma camada intermediária pode implementar qualquer função contínua, e, com a utilização de duas camadas intermediárias é possível a aproximação de qualquer função matemática.

Neste contexto, foi criada a rede neural *Perceptrons de Múltiplas Camadas* ou do inglês *Multilayer Perceptron* (MLP). Esta rede consiste em um conjunto de unidades sensoriais que constituem a camada de entrada, uma ou mais camadas ocultas de nós computacionais e uma camada de saída de nós computacionais [31]. O sinal de entrada é propagado para frente, camada por camada através desta rede. Dessa forma, a rede passa a conter pelo menos três camadas: a de entrada, a camada intermediária ou oculta, e uma camada de saída. A Figura 2.5 ilustra uma rede MLP com duas camadas intermediárias (camadas ocultas).

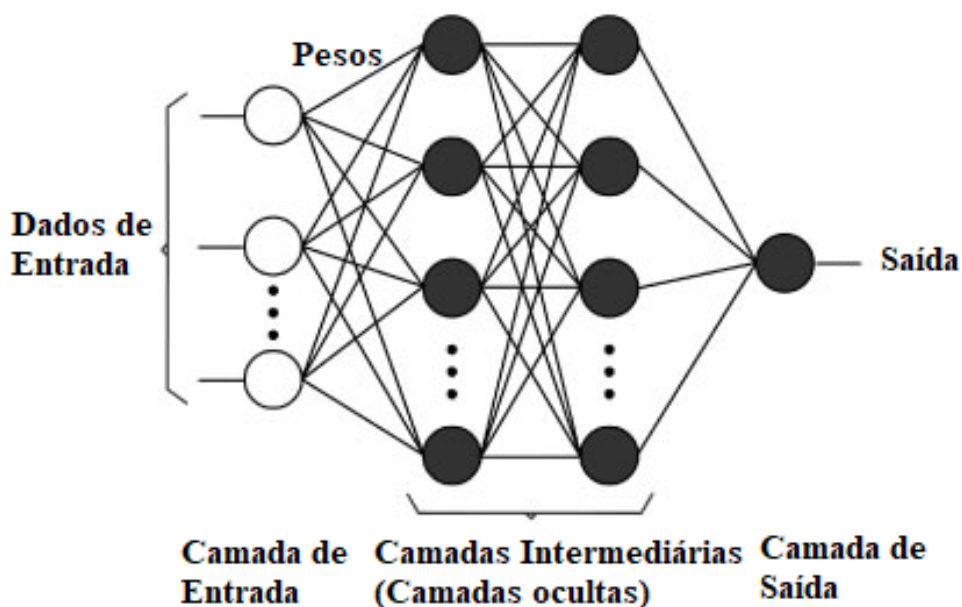


Figura 2.5 - MLP (*Multilayer Perceptron*) [31]

Uma rede MLP possui as seguintes características básicas [31]:

- A rede apresenta um alto grau de conectividade, onde a extensão é determinada pelos pesos sinápticos da rede;
- O modelo de cada neurônio na rede inclui uma função de ativação não linear e que é diferenciável, como por exemplo a função logística (sigmóide),
- A rede apresenta uma ou mais camadas de neurônios que estão ocultas dos nós de entrada e saída, não fazendo parte portanto, da entrada ou saída da rede.

Segundo [31], as redes neurais MLP têm sido empregadas com sucesso para solucionar problemas complexos. O treinamento desta rede é realizado de forma supervisionada através do algoritmo de *retropropagação de erro* ou do inglês *error backpropagation* [31] - [33]. Este algoritmo de treinamento é descrito com mais detalhes na seção 2.1.6.1.

Este tipo de rede neural é usado para construir a rede neural de reconhecimento de padrões. Mais detalhes podem ser vistos no Capítulo 3, onde é detalhada a proposta.

2.1.6.1 Algoritmo de Treinamento *Backpropagation*

A aprendizagem utilizando o algoritmo *backpropagation* utiliza pares (entrada e saída desejada) para ajustar os pesos da rede por meio de mecanismos de correção de erros. O

treinamento consiste em duas fases, onde cada fase percorre em um sentido as diferentes camadas da rede. As duas fases são chamadas de: fase *forward* (passo para frente) e fase *backward* (passo para trás) [33].

- Fase *forward*: os pesos sinápticos da rede são fixos e o sinal de entrada é propagado pela rede, camada por camada, até atingir a saída. Assim, nesta fase, as mudanças estão confinadas aos potenciais de ativação e saídas dos neurônios na rede [31],
- Fase *backward*: um sinal de erro é produzido comparando a saída da rede com uma resposta desejada. O sinal de erro resultante é propagado através da rede, novamente camada por camada, mas desta vez a propagação é realizada na direção reversa (contra a direção das conexões sinápticas). Nesta etapa, ajustes sucessivos são feitos nos pesos sinápticos da rede. O cálculo dos ajustes para a camada de saída é direto, mas é mais difícil para as camadas ocultas [31].

A Figura 2.6 ilustra estas duas etapas.




Figura 2.6 - Fluxo de processamento do algoritmo *backpropagation* [33]

Para correção dos valores sinápticos, o algoritmo *backpropagation* utiliza o método de gradiente descendente. Neste método, calcula-se o gradiente da função objetivo, erro quadrático médio, ou do inglês *mean squared error* (MSE), a ser minimizado e o valor das sinapses é atualizado pelo acréscimo do valor do gradiente com o sinal invertido. O gradiente, neste caso, é a derivada parcial da função de erro quadrático médio em relação à sinapse [31] e [32]. Segundo [31], a equação do algoritmo *backpropagation* pode ser expressa por:

$$\Delta w_{ji(n)} = \eta \delta_{j(n)} y_{i(n)} \quad (2.4)$$

Onde:

i e j : neurônios,

n : passo de iteração,

$\Delta w_{ji(n)}$ é a correção dos pesos sinápticos;

η : parâmetro da taxa de aprendizagem;

$\delta_{j(n)}$: gradiente local,

$y_{i(n)}$: sinal de entrada do neurônio j .

O MSE consiste no erro quadrático médio entre as saídas da rede “ a ” e as saídas alvo “ t ”, podendo ser definido conforme a equação 2.5 [35].

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (2.5)$$

onde:

N : número de amostras;

t_i : saída alvo na iteração i ;

a_i : saída da rede na iteração i ,

MSE : erro quadrático médio.

O gradiente local depende se o neurônio j é um nó de saída ou um nó oculto.

- Neurônio j sendo um nó de saída: O gradiente local é equivalente ao produto da derivada da função associada $\varphi'_j(v_{j(n)})$ e o sinal de erro $e_{j(n)}$, ambos associados ao neurônio j . A equação 2.6 expressa este caso [31].

$$\delta_{j(n)} = e_{j(n)} \varphi'_j(v_{j(n)}) \quad (2.6)$$

Onde:

i e j : neurônios;

n : passo de iteração;

$\delta_{j(n)}$: gradiente local para iteração n ;

$\varphi'_j(v_{j(n)})$: derivada da função de ativação do neurônio j , para iteração n ;

$v_{j(n)}$: sinal aplicado à função de ativação,

$e_{j(n)}$: sinal de erro na saída do neurônio j , para iteração n .

- Neurônio j sendo um nó oculto: O gradiente local é equivalente ao produto da derivada associada $\varphi'_j(v_{j(n)})$ pela soma ponderada dos δ s (gradientes) calculados para os neurônios na próxima camada oculta ou camada de saída que estão conectados ao neurônio j . A equação 2.7 expressa este caso [31].

$$\delta_{j(n)} = \varphi'_j(v_{j(n)}) \sum_k \delta_{k(n)} w_{kj(n)} \quad (2.7)$$

Onde:

i, j e k : neurônios,

n : passo de iteração,

$\delta_{j(n)}$: gradiente local para iteração n ,

$\varphi'_j(v_{j(n)})$: derivada da função de ativação do neurônio j , para iteração n ;

$v_{j(n)}$: sinal aplicado à função de ativação;

$\delta_{k(n)}$: gradiente na saída do neurônio k , para iteração n ,

$w_{kj(n)}$: peso sináptico.

O passo de treino é uma constante que controla a velocidade de convergência do algoritmo, isto é, a velocidade com que os valores sinápticos levam o MSE a um mínimo local ou global na superfície de erro do problema. [33].

Para este algoritmo, a função de ativação deve ser diferenciável em todo o seu domínio e deve ser não decrescente, de modo que sua derivada não mude o sinal, o que poderia comprometer a convergência do algoritmo [32].

A dedução matemática detalhada das equações (2.4), (2.6) e (2.7) encontram-se em [31].

2.1.7 Mapas Auto-organizáveis

As redes neurais do tipo mapas auto-organizáveis, ou do inglês *Self-organizing Maps* (SOM), também chamadas de redes Kohonen, foram propostas em 1984 por Teuvo Kohonen e utilizam um procedimento de aprendizagem não supervisionado [31]. Estas redes possuem inspiração no córtex cerebral humano. A estrutura da rede é composta de uma camada de nós, normalmente bidimensional, ligada aos nós de entrada conforme é ilustrado na Figura 2.7.

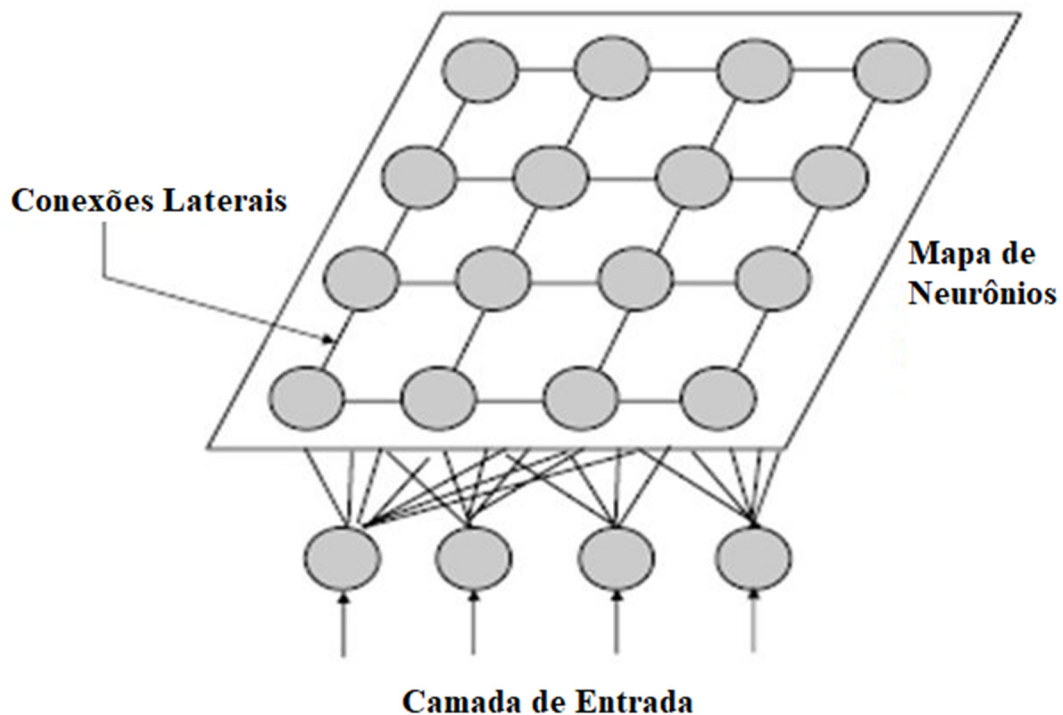


Figura 2.7 - Arquitetura rede SOM [33]

O funcionamento da rede SOM pode ser entendido da seguinte forma: Um padrão “Q” é aplicado à entrada, de forma que a rede busca uma unidade mais parecida com “Q”. No processo de treinamento, a rede aumenta a semelhança do neurônio escolhido e de seus vizinhos com o padrão aplicado. Isto posto, a rede neural cria um “mapa topológico” de forma que os neurônios que estão geograficamente próximos respondam de maneira similar a padrões de entrada parecidos [31].

A Figura 2.8 ilustra o funcionamento da rede SOM, onde o neurônio vencedor é o de cor “rosa” em destaque. Nota-se, que na camada de saída, os neurônios geograficamente próximos ao neurônio vencedor apresentam coloração similar.

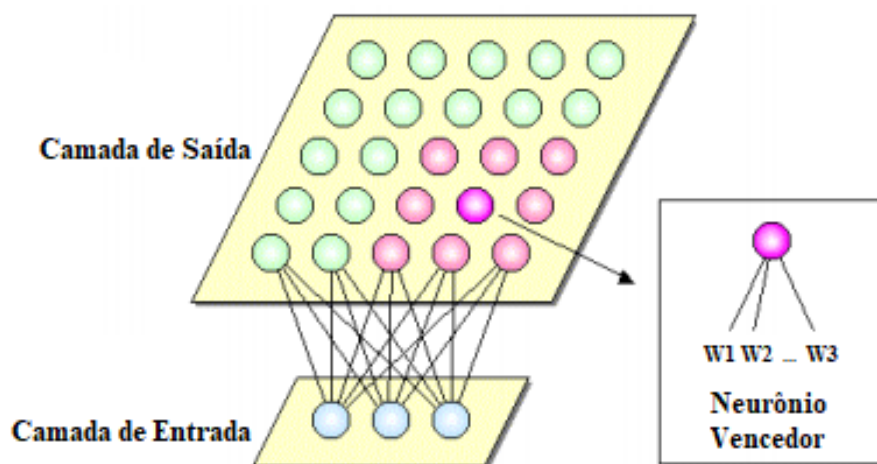


Figura 2.8 - Funcionamento da rede SOM

A aprendizagem da rede SOM é do tipo competitiva, haja vista que os neurônios de saída competem entre si para se tornarem ativos, isto é, para saber qual gera o maior valor de saída.

O algoritmo de aprendizagem competitiva divide uma série de dados de entrada em grupos, chamados de *clusters*, que são intrínsecos ao problema.

Apenas um neurônio de saída ou neurônio por grupo torna-se ativo. Esta competição entre os neurônios é chamada de “o vencedor leva tudo” ou do inglês “*winner-takes-all*”. Uma forma de estimular tal tipo de competição é fazer uso de conexões laterais inibitórias entre os nós de saídas [33]. Nesta rede, o comportamento de um determinado nó é diretamente influenciado pelo comportamento dos nós vizinhos (vizinhança local) [32]. Dessa forma, durante o processo de treinamento, quando um nó vence uma competição, produzindo a maior saída para uma determinada entrada, os pesos são alterados não somente no nó vencedor mas também nos nós localizados na vizinhança local [32]. É possível definir qual vizinhança será afetada pelo neurônio vencedor durante a etapa de treinamento através de duas formas: Distância Manhattan e de Grid [32].

Em resumo, a criação do mapa auto-organizável pode ser descrita de uma maneira simples [31] – [33]:

- 1) **Inicialização:** esta etapa geralmente é aleatória, podendo ainda ser estimada por análise da representação dos dados;
- 2) **Competição:** para cada padrão inserido na entrada, calcula-se a resposta dos neurônios de saída (grade/mapa). O neurônio que apresentar a maior resposta é o vencedor da competição;
- 3) **Cooperação:** o neurônio vencedor determina uma vizinhança de influência,

4) **Adaptação Sináptica:** aprendido em relação ao padrão de entrada. Os pesos do neurônio vencedor, e de sua vizinhança, ficam mais próximos do padrão apresentado na entrada.

2.1.7.1 Treinamento Rede SOM

A rede neural SOM possui o treinamento do tipo competitivo e não-supervisionado. Os neurônios são organizados em vizinhanças locais pelo algoritmo de treinamento. Toda vez que um padrão de treinamento é aplicado à rede, os neurônios competem entre si para determinar quem proporcionou a maior saída. Determinado o neurônio vencedor, inicia-se o processo de atualização dos pesos sinápticos do neurônio vencedor e de seus vizinhos dentro de uma área de vizinhança. No treinamento o raio de vizinhança e a taxa de aprendizagem são decrementados. Os neurônios são ajustados segundo a equação 2.8 [32] e [33].

$$w_{ji(t+1)} = \begin{cases} w_{ji(t)} + n_{(t)} [x_{i(t)} - w_{ji(t)}], & \text{se } j \in \Lambda_{(t)} \\ w_{ji(t)} & , \text{ caso contrário} \end{cases} \quad (2.8)$$

Onde:

t : instante de tempo t ;

$w_{ji(t)}$: peso da conexão entre o elemento de entrada $x_{i(t)}$ e o neurônio j ;

$n_{(t)}$: taxa de aprendizagem,

$\Lambda_{(t)}$: vizinhança do neurônio vencedor.

A aprendizagem padrão em um mapa auto-organizável ocorre no modo *batch* (lote) e a função de aprendizagem dos pesos é a *learnsomb* [35].

2.2 Formulação do Fluxo de Potência

O fluxo de potência, também conhecido como fluxo de carga ou do inglês *load flow*, consiste no estudo de sistemas de potência em condições de regime permanente. Neste estudo, é empregado um conjunto de equações não lineares que modelam e permitem determinar os estados de operação do sistema tais como, potência ativa, reativa, tensões, correntes, perdas nos barramentos de geração e carga, nas linhas de transmissão e diversas outras variáveis de interesse. Dessa forma, o fluxo de potência é visto com uma ferramenta primordial para a análise de segurança, estudo de planejamento da expansão e otimização de sistemas em operação em sistemas elétricos de potência.

2.2.1 Fluxo de Potência Trifásico Desequilibrado

Os algoritmos baseados em técnicas numéricas como Newton-Raphson e Gauss-Seidel são apropriados para análise de sistemas de transmissão uma vez que apresentam características intrínsecas como equilíbrio de carregamento entre fases e grandes susceptâncias capacitivas, baixa relação R/X (resistência/reatância), sistemas em sua maioria transposto.

O foco deste trabalho são os sistemas de distribuição que apresentam características tais como topologia radial, subdivisões monofásicas, bifásicas e trifásicas, fases desequilibradas, e alta razão R/X, as quais são características distintas do sistema de transmissão. Por isto, os métodos Newton-Raphson e Gauss-Seidel não são técnicas apropriadas para solução de problemas de fluxo de potência em sistemas de distribuição. No entanto, em 1967 foi proposta uma técnica chamada de varredura *backward-forward* (varredura inversa / varredura direta) aplicada a sistemas de potência que se tornou a base principal para solução deste tipo de problema. O algoritmo fundamenta-se em dois passos:

- *Backward* – varredura inversa: nesta etapa o processo tem início nas barras terminais e finaliza no nó de suprimento, realizando o somatório das correntes ou potências durante o percurso,
- *Forward* – varredura direta: esta etapa é efetuada, quando realizada a atualização das tensões nodais iniciando pela barra de suprimento até chegar às barras terminais.

O fluxograma detalhando os passos para implementação deste algoritmo é descrito na Figura 2.9.

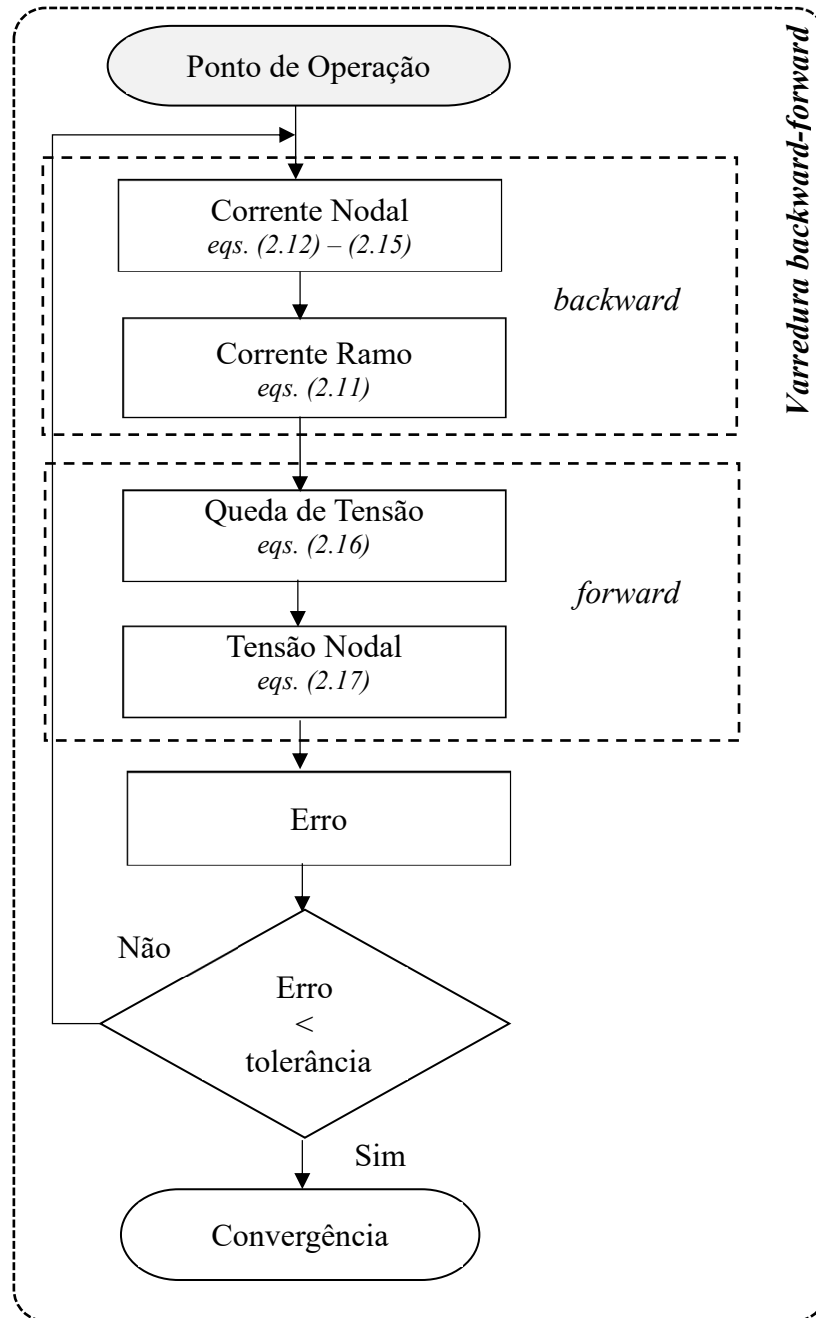


Figura 2.9 - Fluxograma para implementação da técnica de varredura *backward-forward*

A metodologia proposta em [36] proporciona a solução do problema de fluxo de potência em redes de distribuição trifásicas com arquitetura radial levando em conta a inserção de fontes de geração distribuída. O método proposto tem base na relação entre as correntes nodais e as correntes de ramo do sistema. Com a solução do fluxo de potência, os estados operacionais da MG são alcançados.

Levando em consideração um sistema com topografia radial de n nós, são possíveis $n - 1$ correntes de ramo. A subtração da corrente de entrada do ramo i e j pelas correntes dos nós conectados a barra i , $k(i)$ define a corrente nodal. Esta relação é expressa por

$$I_i = I_{ij} - \sum I_{ik(i)} \quad (2.9)$$

A matriz de incidência de elementos, chamada de $K = [k_{ij}]$, relaciona as correntes nodais e de ramo. Trata-se de uma matriz quadrada não-singular de ordem $n - 1$, onde os elementos da diagonal principal são definidos por $k_{ij} = 1$, e os elementos incidentes restantes, entre os nós i e j , são definidos por $k_{ij} = -1$. Os outros elementos são nulos. Esta relação descrita é representada pelas equações (2.10) e (2.11)

$$I_i = K \cdot I_{ij} \quad (2.10)$$

$$I_{ij} = K^{-1} \cdot I_i \quad (2.11)$$

Generalizando o equacionamento para uma rede de distribuição trifásica, são obtidas três matrizes de incidência, uma para cada fase, com dimensões $(n_A - 1 \times n_A - 1)$, $(n_B - 1 \times n_B - 1)$ e $(n_C - 1 \times n_C - 1)$, em que n_A , n_B e n_C são os números de nós existentes em cada fase. As correntes nodais de cada fase são obtidas aplicando a Equação 2.12

$$\begin{aligned} I_i^A &= I_L^A + I_{Sh}^A - I_G^A \\ I_i^B &= I_L^B + I_{Sh}^B - I_G^B \\ I_i^C &= I_L^C + I_{Sh}^C - I_G^C \end{aligned} \quad (2.12)$$

$$I_L^{A,B,C} = \frac{abs(V_i^{A,B,C})^n \times conj(S_{specified}^{A,B,C})}{conj(V_i^{A,B,C})} \quad (2.13)$$

$$\begin{bmatrix} I_{Sh}^A \\ I_{Sh}^B \\ I_{Sh}^C \end{bmatrix} = \frac{1}{2} \begin{bmatrix} Y_{AA} & Y_{AB} & Y_{AC} \\ Y_{BA} & Y_{BB} & Y_{BC} \\ Y_{CA} & Y_{CB} & Y_{CC} \end{bmatrix} \begin{bmatrix} V_i^A \\ V_i^B \\ V_i^C \end{bmatrix} \quad (2.14)$$

$$I_G^{A,B,C} = \frac{(P_{G,specified}^{A,B,C} - jQ_{G,specified}^{A,B,C})}{conj(V_i^{A,B,C})} \quad (2.15)$$

Em que:

$I_L^{A,B,C}$ é a corrente de carga de cada fase, calculada conforme (2.13), onde o índice n representa o modelo de carga empregado (0 para potência constante, 1 para corrente constante e 2 para impedância constante);

$I_{sh}^{A,B,C}$ é a corrente de *shunt* de cada fase, calculada de acordo com (2.14);

$I_G^{A,B,C}$ é a corrente de geração de cada fase, calculada de acordo com (2.15);

$V_i^{A,B,C}$ é a tensão nodal de cada fase;

$S_{specified}^{A,B,C}$ é a potência aparente especificada para cada fase;

Y_{ij} é a auto/mútua admitância;

$P_{G,specified}^{A,B,C}$ é a potência ativa especificada para cada fase,

$Q_{G,specified}^{A,B,C}$ é a potência reativa especificada para cada fase.

De posse das correntes nodais, as correntes de ramo de cada fase são calculadas conforme a Equação (2.11). Posteriormente, as quedas de tensão nos ramos são calculadas segundo a Equação (2.16) e as tensões nodais são calculadas usando a Equação (2.17) em cada fase.

Este método acontece de maneira iterativa até que se atinja o limite de tolerância adotado.

$$\begin{bmatrix} \Delta V_{ij}^A \\ \Delta V_{ij}^B \\ \Delta V_{ij}^C \end{bmatrix} = \begin{bmatrix} Z_{AA_{ij}} & Z_{AB_{ij}} & Z_{AC_{ij}} \\ Z_{BA_{ij}} & Z_{BB_{ij}} & Z_{BC_{ij}} \\ Z_{CA_{ij}} & Z_{CB_{ij}} & Z_{CC_{ij}} \end{bmatrix} \begin{bmatrix} I_{ij}^A \\ I_{ij}^B \\ I_{ij}^C \end{bmatrix} \quad (2.16)$$

$$\begin{bmatrix} V_j^A \\ V_j^B \\ V_j^C \end{bmatrix} = \begin{bmatrix} V_i^A \\ V_i^B \\ V_i^C \end{bmatrix} - \begin{bmatrix} \Delta V_{ij}^A \\ \Delta V_{ij}^B \\ \Delta V_{ij}^C \end{bmatrix} \quad (2.17)$$

Em que: Z é a matriz de impedância.

Esta abordagem foi adotada para a resolução do fluxo de potência da proposta desta dissertação.

2.3 Método de Monte Carlo

O Método de Monte Carlo (MMC) consiste em um método estatístico, onde utiliza-se um grande volume de amostras aleatórias a fim de realizar sucessivas simulações com o objetivo de obter um resultado numérico.

Uma característica essencial do método, e que difere dos métodos convencionais, é que não é necessário descrever o comportamento físico de sistemas complexos por meio de equações diferenciais parciais ou ordinárias. O único requisito é que o sistema possa ser modelado por funções de densidade de probabilidade ou do inglês *probability density functions* (PDF), que determinam o comportamento físico do sistema observado. Tendo determinada essas distribuições, a simulação do MMC pode continuar criando as amostras aleatórias a partir delas. O processo de simulação é repetido um elevado número de vezes e a solução almejada é alcançada através das técnicas de estatística (média, desvio padrão, etc) [37].

A técnica de Monte Carlo engloba alguns componentes necessários para simulação que são: geração de números aleatórios, funções de densidade de probabilidade e determinação da técnica de amostragem [37]. A Figura 2.10 ilustra de maneira simplificada o funcionamento do Método de Monte Carlo.

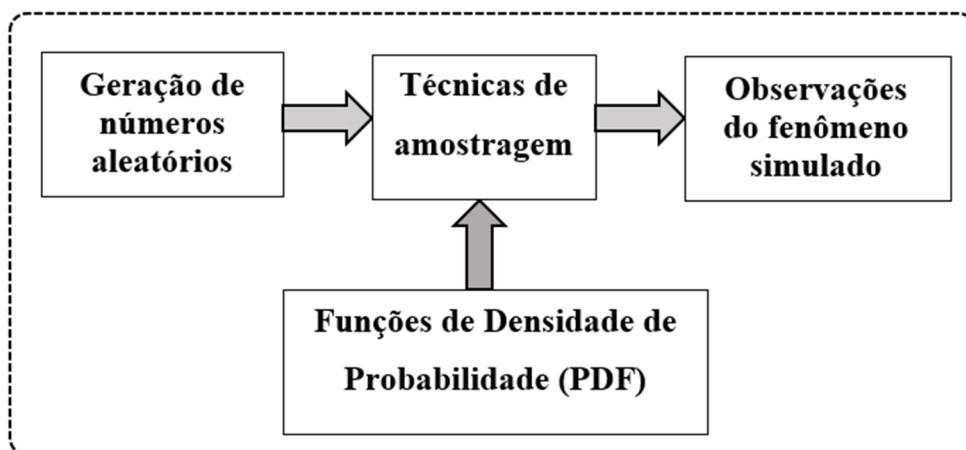


Figura 2.10 - Ilustração simplificada do método de Monte Carlo

3 Capítulo – Metodologia e Desenvolvimento

Nesta sessão é feita uma descrição da microrrede utilizada como objeto deste estudo. Além disso, é apresentada a metodologia desenvolvida para solução do problema proposto.

3.1 Microrrede (MG)

A microrrede pode ser entendida como uma integração de carga e de diversos recursos de geração distribuída, tais como veículos elétricos, baterias e de geração renovável. As MGs podem operar em modo conectado ou ilhado devido a condições de emergência ou manutenção programada. Neste trabalho, os recursos renováveis variáveis em função de condições climáticas, solar e eólica, foram considerados como geração distribuída.

Neste Capítulo, o modelo do sistema empregado é detalhado. Para isso, é considerada uma única MG com dois DERs locais. Os DERs são representados por um sistema fotovoltaico e um sistema de geração eólico.

As equações, apresentadas nas próximas Seções deste Capítulo, são apontadas na sua forma geral, i.e., é suprimida a repetição de cada equação para cada fase com objetivo de simplificar a leitura. No entanto cabe ressaltar que para cada fase a equação se repete.

3.1.1 Recursos de Energia Distribuídos

A geração distribuída local é modelada neste trabalho como carga negativa em uma barra PQ.

3.1.1.1 Modelo do Sistema Fotovoltaico

O modelo exponencial simples de um painel fotovoltaico, por apresentar resposta satisfatória e baixo custo computacional, é utilizado neste trabalho [38]. Ele é representado como na Figura 3.1.




Figura 3.1 - Circuito equivalente do modelo exponencial simples [38]

A característica $I(V)$ é representada pela corrente fornecida à carga,

$$I_{PV} = I_{ph} - I_D - I_{sh} \quad (3.1)$$

As correntes I_D e I_{sh} são dadas por

$$I_D = I_0 \left[e^{\frac{q(V_{PV} + R_S I_{PV})}{AK_B T}} - 1 \right] \quad (3.2)$$

$$I_{sh} = \frac{V_{PV} + R_S I_{PV}}{R_{sh}} \quad (3.3)$$

onde,

I_{PV} é a corrente da carga (A);

I_{ph} é a corrente gerada pelo efeito fotoelétrico (A);

I_D é a corrente do diodo (A);

I_{sh} é a corrente *shunt* (A);

I_0 é a corrente de saturação reversa do diodo (A);

R_S é a resistência série (Ω);

R_{sh} é a resistência *shunt* (Ω);

V_{PV} é a tensão da carga (V);

A é o fator de qualidade da junção *p-n*;

K_B é a constante de Boltzmann's $- 1,38 \times 10^{-23}$ (J/K);

T é a temperatura da junção (K);

q é a carga do elétron $- 1,602 \times 10^{-19}$ (C).

Em (3.1) – (3.3) contem parâmetros $- I_{ph}, I_0, R_S, R_{sh}$ e A , que são determinados através de três pontos observados pela curva $I(V)$: o ponto de curto circuito, o ponto de máxima potência e o ponto de circuito aberto ao utilizar o método iterativo de solução de equações não-lineares, como Newton-Raphson.

Desse modo, substituindo os pontos de curto circuito ($I_{PV} = I_{sc}$ e $V_{PV} = 0$), máxima potência ($I_{PV} = I_{mpp}$ e $V_{PV} = V_{mpp}$) e circuito aberto ($I_{PV} = 0$ e $V_{PV} = V_{oc}$) em (3.1), obtêm-se (3.4), (3.5) e (3.6), respectivamente.

$$I_{sc} = I_{ph} - I_0 \left(e^{\frac{qR_S I_{sc}}{AK_B T}} - 1 \right) - \frac{R_S I_{sc}}{R_{sh}} \quad (3.4)$$

$$I_{mpp} = I_{ph} - I_0 \left[e^{\frac{q(V_{mpp} + R_S I_{mpp})}{AK_B T}} - 1 \right] - \frac{V_{mpp} + R_S I_{mpp}}{R_{sh}} \quad (3.5)$$

$$0 = I_{ph} - I_0 \left(e^{\frac{qV_{oc}}{AK_B T}} - 1 \right) - \frac{V_{oc}}{R_{sh}} \quad (3.6)$$

Derivando (3.1) em relação à tensão fornecida pelo painel fotovoltaico, tem-se

$$\frac{dI_{PV}}{dV_{PV}} = -I_0 \frac{q}{AK_B T} \left(1 + R_S \frac{dI_{PV}}{dV_{PV}} \right) e^{\frac{q(V_{PV} + R_S I_{PV})}{AK_B T}} - \frac{1}{R_{sh}} \left(1 + R_S \frac{dI_{PV}}{dV_{PV}} \right) \quad (3.7)$$

Substituindo I_{PV} e V_{PV} em (3.7) para os pontos de curto circuito e circuito aberto, obtêm-se (3.8) e (3.9):

$$\begin{aligned} \left. \frac{dI_{PV}}{dV_{PV}} \right|_{V_{PV}=0} &= -I_0 \frac{q}{AK_B T} \left(1 + R_S \left. \frac{dI_{PV}}{dV_{PV}} \right|_{V_{PV}=0} \right) e^{\frac{qR_S I_{sc}}{AK_B T}} \\ &\quad - \frac{1}{R_{sh}} \left(1 + R_S \left. \frac{dI_{PV}}{dV_{PV}} \right|_{V_{PV}=0} \right) \end{aligned} \quad (3.8)$$

$$\begin{aligned} \left. \frac{dI_{PV}}{dV_{PV}} \right|_{I_{PV}=0} &= -I_0 \frac{q}{AK_B T} \left(1 + R_S \left. \frac{dI_{PV}}{dV_{PV}} \right|_{I_{PV}=0} \right) e^{\frac{qV_{oc}}{AK_B T}} \\ &\quad - \frac{1}{R_{sh}} \left(1 + R_S \left. \frac{dI_{PV}}{dV_{PV}} \right|_{I_{PV}=0} \right) \end{aligned} \quad (3.9)$$

A potência fornecida pelo painel fotovoltaico e sua derivada em relação à tensão são representadas por (3.10) e (3.11):

$$P_{PV} = V_{PV} I_{PV} \quad (3.10)$$

$$\frac{dP_{PV}}{dV_{PV}} = I_{PV} + V_{PV} \frac{dI_{PV}}{dV_{PV}} \quad (3.11)$$

Para obter a tensão dada no ponto de máxima potência, sabe-se que $\frac{dP_{PV}}{dV_{PV}} = 0$, assim, obtêm-se (3.12) e (3.13).

$$\frac{dI_{PV}}{dV_{PV}} = -\frac{I_{PV}}{V_{PV}} = -\frac{I_{mpp}}{V_{mpp}} \quad (3.12)$$

$$\begin{aligned} \frac{I_{mpp}}{V_{mpp}} = I_0 \frac{q}{AK_B T} \left(1 - R_S \frac{I_{mpp}}{V_{mpp}}\right) e^{\frac{q(V_{mpp} + R_S I_{mpp})}{AK_B T}} \\ + \frac{1}{R_{sh}} \left(1 - R_S \frac{I_{mpp}}{V_{mpp}}\right) \end{aligned} \quad (3.13)$$

Os valores V_{oc} , I_{sc} , V_{mpp} , I_{mpp} , $\left.\frac{dI_{PV}}{dV_{PV}}\right|_{I_{PV}=0}$ e $\left.\frac{dI_{PV}}{dV_{PV}}\right|_{V_{PV}=0}$ são encontrados no catálogo do fabricante. As condições iniciais dos parâmetros podem ser obtidas por (3.14) – (3.21).

$$A = \frac{V_{mpp} + \frac{1}{G_{so}} I_{mpp} - V_{oc}}{V_t \left[\ln(I_{sc} - V_{mpp} G_{sho} - I_{mpp}) - \ln(I_{sc} - V_{oc} G_{sho}) + \frac{I_{mpp}}{I_{sc} - V_{oc} G_{sho}} \right]} \quad (3.14)$$

$$R_{sh} = \frac{1}{G_{sho}} \quad (3.15)$$

$$I_o = \left(I_{sc} - \frac{V_{oc}}{R_S} \right) e^{-\frac{V_{oc}}{AV_t}} \quad (3.16)$$

$$R_S = \frac{1}{G_{so}} - \frac{AV_t}{I_o} e^{-\frac{V_{oc}}{AV_t}} \quad (3.17)$$

$$I_{ph} = I_{sc} \left(1 - \frac{R_S}{R_{sh}} \right) + I_o \left(e^{\frac{R_S I_{sc}}{AV_t}} - 1 \right) \quad (3.18)$$

Onde,

$$G_{so} = \left.\frac{dI_{PV}}{dV_{PV}}\right|_{I_{PV}=0} \quad (3.19)$$

$$G_{sho} = \left. \frac{dI_{PV}}{dV_{PV}} \right|_{V_{PV}=0} \quad (3.20)$$

$$V_t = \frac{K_B T}{q} \quad (3.21)$$

Os parâmetros elétricos dos painéis fotovoltaicos usualmente são fornecidos para uma determinada radiação solar e temperatura de referência igual a 1000 W/m² e 25 °C. Porém, eles variam conforme as condições externas, como por exemplo a temperatura e a radiação, precisando de correções. Tais condições influenciam na intermitência.

O fator de qualidade da junção *p-n*, e a corrente de saturação, dependem da temperatura em Kelvin, sendo aproximadas por (3.22) e (3.23):

$$\frac{A}{A_{STC}} = \frac{T}{T_{STC}} \quad (3.22)$$

$$I_o = I_{oSTC} \left(\frac{T}{T_{STC}} \right)^{3/A} e^{\frac{qR_S I_{sc}}{AK_B T}} e^{\frac{qE_{go}}{AK_B} \left(\frac{T}{T_{STC}} - 1 \right)} \quad (3.23)$$

Onde,

T_{STC} é a temperatura do painel em condições padrões de teste;

A_{STC} é a qualidade da junção *p-n* em condições padrões de teste;

I_{oSTC} é a corrente de saturação em condições padrões de teste;

E_{go} é a energia da banda do semiconductor utilizado na célula fotovoltaica.

A corrente gerada pelo efeito fotoelétrico é aproximadamente uma função linear da radiação solar, e sua equação para diferentes pontos de operação é

$$I_{ph} = \frac{S}{S_{STC}} [I_{phSTC} + K_i(T - T_{STC})] \quad (3.24)$$

Onde,

S_{STC} é o nível de radiação solar incidente na placa em condições padrões de teste;

I_{phSTC} é a corrente gerada pelo efeito fotoelétrico em condições padrões de teste;

K_i é o coeficiente de corrente de curto circuito fornecido pelo catálogo do fabricante.

A curva $V(I)$ é afetada sutilmente próxima ao ponto de potência máxima pela resistência série, enquanto sua inclinação é afetada pela resistência *shunt*. As resistências são encontradas por (3.25) e (3.26).

$$R_s = R_{sSTC} \quad (3.25)$$

$$\frac{R_{sh}}{R_{shSTC}} = \frac{S_{STC}}{S} \quad (3.26)$$

Onde,

R_{sSTC} é a resistência série em condições padrões de teste;

R_{shSTC} é a resistência *shunt* em condições padrões de teste.

A temperatura do painel fotovoltaico é encontrada por

$$T = T_a + S \frac{NOCT - 20}{800} \quad (3.27)$$

Onde,

S é a radiação solar;

T_a é a temperatura ambiente;

$NOCT$ é a temperatura nominal de operação do painel fotovoltaico sob uma radiação solar de 800 W/m², temperatura ambiente de 20 °C e uma velocidade < 1 m/s.

3.1.1.2 Modelo do Sistema de Geração Eólica

O modelo matemático não-linear de geração eólica [39] é empregado. Através da velocidade do vento obtém-se a energia elétrica gerada.

$$P_{wt} = \begin{cases} 0, & \text{para } 0 \leq \omega \leq \omega_{ci} \\ (A + B\omega + C\omega^2)P_n, & \text{para } \omega_{ci} < \omega \leq \omega_r \\ P_n, & \text{para } \omega_r < \omega \leq \omega_{co} \\ 0, & \text{para } \omega > \omega_{co} \end{cases} \quad (3.28)$$

Onde,

ω é a velocidade do vento (m/s);

P_n é a potência nominal da turbina (kW);

ω_r é a velocidade nominal ($\omega > \omega_r$, turbina gera P_n) (m/s);

ω_{ci} é a velocidade de *cut-in* (velocidade mínima para início do movimento) (m/s);

ω_{co} é a velocidade de *cut-off* ($\omega > \omega_{co}$, potência gerada nula) (m/s);

A , B e C são coeficientes responsáveis pelo comportamento parabólico da turbina, sendo fixos e definidos de acordo com as equações [39]:

$$A = \frac{1}{(\omega_{ci} - \omega_r)^2} \left[\omega_{ci}(\omega_{ci} + \omega_r) - 4\omega_{ci}\omega_r \left(\frac{\omega_{ci} + \omega_r}{2\omega_r} \right)^3 \right] \quad (3.29)$$

$$B = \frac{1}{(\omega_{ci} - \omega_r)^2} \left[4(\omega_{ci} + \omega_r) \left(\frac{\omega_{ci} + \omega_r}{2\omega_r} \right)^3 - (3\omega_{ci} + \omega_r) \right] \quad (3.30)$$

$$C = \frac{1}{(\omega_{ci} - \omega_r)^2} \left[2 - 4 \left(\frac{\omega_{ci} + \omega_r}{2\omega_r} \right)^3 \right] \quad (3.31)$$

A resposta do sistema de geração eólico pode ser vista na Figura 3.2. São consideradas medições reais do potencial eólico [40].

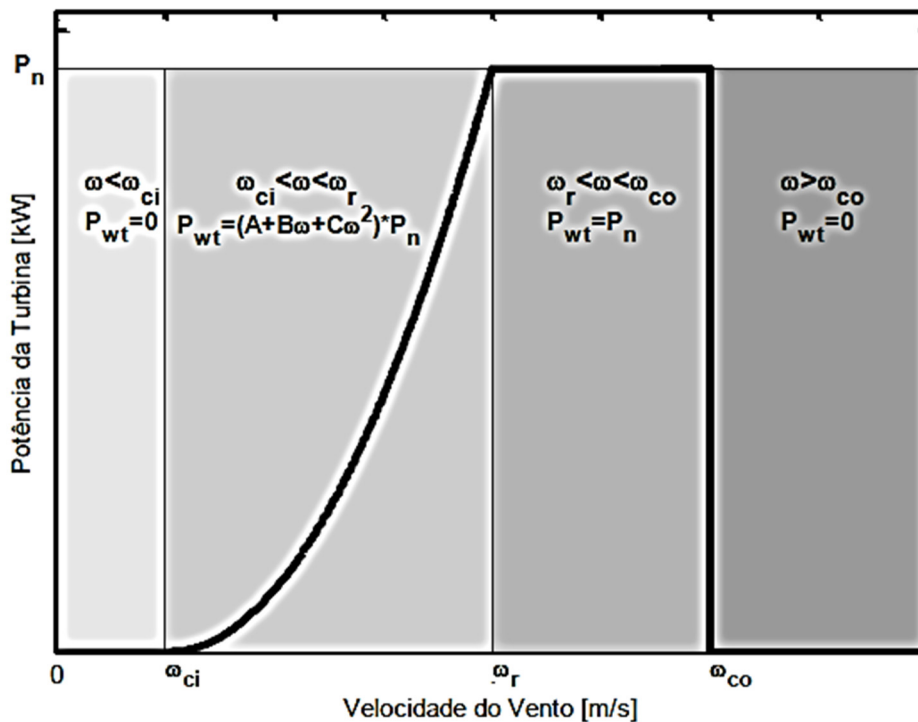


Figura 3.2 -Resposta da turbina [41]

3.1.2 Modelo de Carga

O modelo de carga aplicado foi o polinomial, ZIP (impedância, corrente e potência) [1]. Ele estabelece uma relação não-linear entre as grandezas.

$$P_l(t) = P_{l0} \left[\alpha_{Zp} \left(\frac{V_l(t)}{V_{l0}} \right)^2 + \beta_{Ip} \left(\frac{V_l(t)}{V_{l0}} \right) + \gamma_{Pp} \right] \quad (3.32)$$

$$Q_l(t) = Q_{l0} \left[\alpha_{Zp} \left(\frac{V_l(t)}{V_{l0}} \right)^2 + \beta_{Ip} \left(\frac{V_l(t)}{V_{l0}} \right) + \gamma_{Pp} \right] \quad (3.33)$$

Onde,

P_l é a potência ativa consumida e P_{l0} é seu valor inicial

Q_l é a potência reativa consumida e Q_{l0} é seu valor inicial

V_l é a tensão e V_{l0} é seu valor inicial

t é o tempo

Os parâmetros α_{Zp} , β_{Ip} e γ_{Pp} são respectivamente os percentuais de impedância constante, corrente constante e potência constante da composição da carga. Eles estão sujeitos à seguinte restrição:

$$\alpha_{Zp} + \beta_{Ip} + \gamma_{Pp} = 1 \quad (3.34)$$

3.2 Formulação do Problema

O planejamento e a operação de sistemas elétricos de potência modernos, tal como MGs, são significativamente afetados pela alta penetração de recursos renováveis devido a intermitência no fornecimento de energia dessas fontes. Como consequência, MGs possuem restrições operacionais e técnicas adicionais de modo a assegurar condições operacionais confiáveis e satisfatórias. Estas restrições incluem a capacidade de hospedagem, que representa a quantidade máxima de geração distribuída tolerada pela rede em um ponto específico do sistema de distribuição sem violar limites operativos, incluindo máxima corrente de condução, máxima tensão nodal, potência nominal, limites térmicos, etc.

Dentre estes aspectos, a violação de limites máximos de tensão apresenta uma das condições mais críticas para garantia de uma operação satisfatória para a MG. Essa perspectiva

se torna particularmente crítica devido a não controlabilidade de recursos renováveis não despacháveis, tais como fontes solares e eólicas. Nesta perspectiva, este trabalho propõe uma nova metodologia capitalizando as habilidades de ANNs de reconhecimento de padrão e mapa auto-organizável para: 1) Auxílio nas tomadas de decisões sobre o planejamento da operação de MGs com geradores renováveis distribuídos; 2) Determinação de ações de controle durante operação de MGs com alta penetração de geração distribuída. A abordagem proposta utiliza as ANNs para identificar se o conjunto de geradores renováveis ou qual deles levará o sistema a uma sobretensão (limite superior de tensão, \bar{V}). Esses geradores renováveis estão conectados diretamente à MG fornecendo uma potência ativa, $P_{i\langle G \rangle}$, e não contribuindo com a parcela de geração reativa, $Q_{i\langle G \rangle}$.

$$\Gamma_i = \left\{ (P_{i\langle G \rangle}) : 0 \leq P_{i\langle G \rangle} \leq \overline{P_{i\langle G \rangle}}, (P_{i\langle G \rangle})^2 \leq (S_{i\langle G \rangle})^2 \right\}, \Gamma_i \in \mathbb{R}, \forall i \subseteq \mathcal{G} \quad (3.35)$$

onde $S_{i\langle G \rangle}$ é a potência nominal da unidade i , $\overline{P_{i\langle G \rangle}}$ é a potência máxima da unidade i , \mathcal{G} é o conjunto de barras com geradores renováveis.

Para isso, primeiro o conjunto de condições operativas para treinamento, validação e teste das ANNs para uma MG com n barras é determinado usando Monte Carlo (Seção 2.3). Neste estágio, as diversas entradas de geração renovável randômicas $P_{i\langle G \rangle}$ são inseridas no fluxo de potência trifásico desequilibrado (Seção 2.2), onde para cada amostra k , o conjunto de condições operativas resultantes do fluxo de potência é armazenado em um conjunto de soluções com limite de tensão violado ou não, respectivamente $k \in \mathbb{X}_u$ ou $k \in \mathbb{X}_s$, onde $\mathbf{V}_k = [V_{1,k}, \dots, V_{n,k}]$ representa o vetor de tensões da MG para uma amostra k . Esse processo é executado de forma exaustiva até atingir o valor máximo de amostras \mathcal{K} , conforme ilustrado no fluxograma descrito na Figura 3.3.

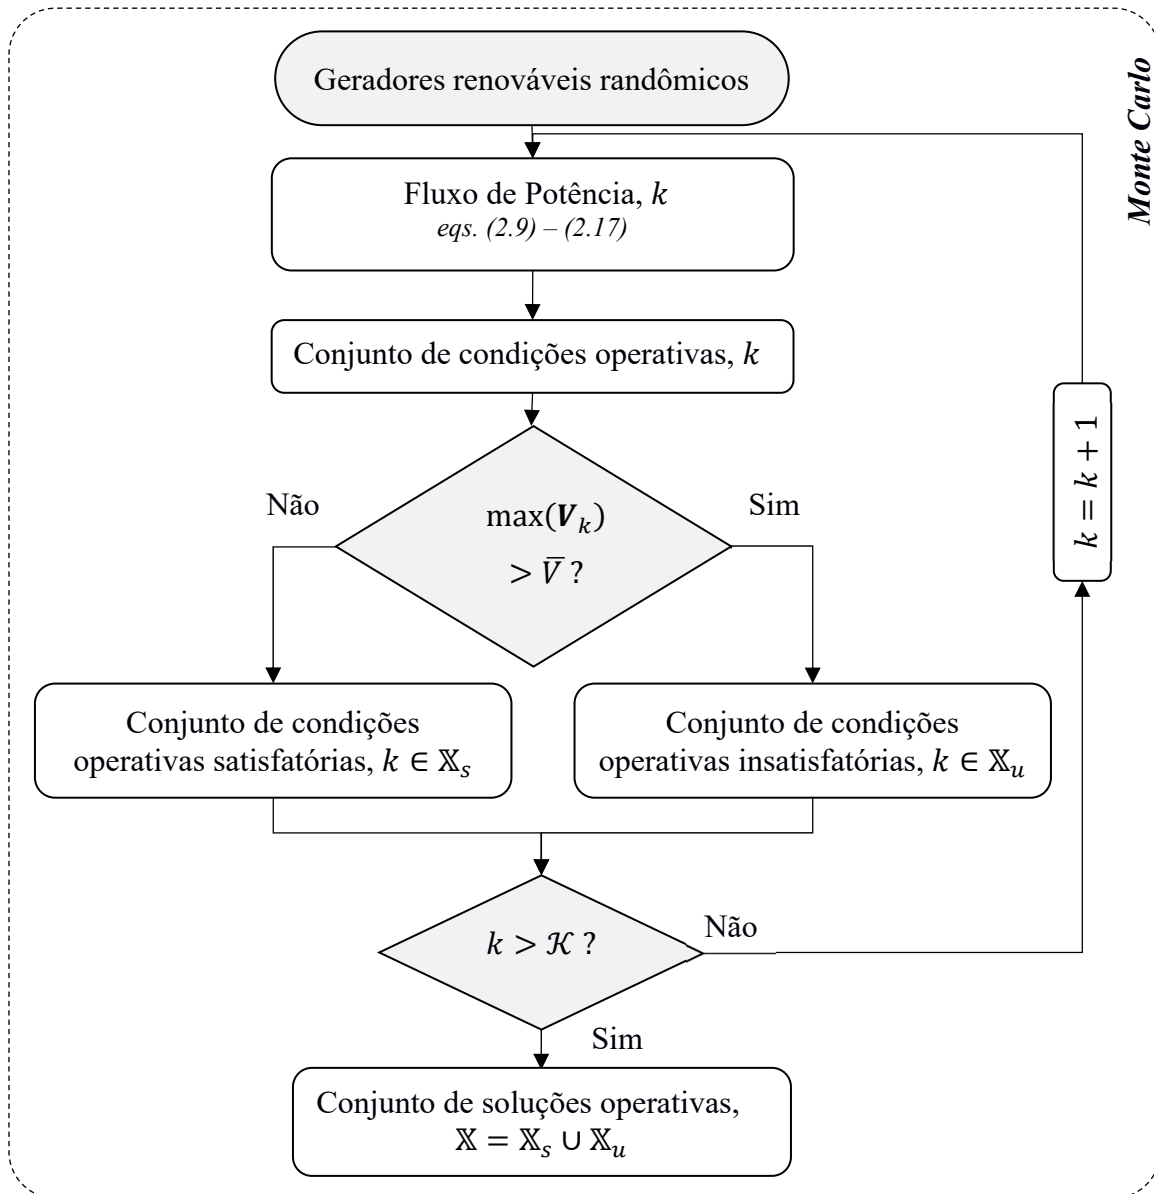


Figura 3.3 - Fluxograma - Monte Carlo

Em seguida, o conjunto de soluções operativas obtidas por Monte Carlo são aplicadas a ANNs de reconhecimento de padrão (Seção 2.1.6). Essas ANNs possuem duas camadas com 20 neurônios, função de ativação sigmoideal, treinamento por retropropagação, 2 neurônios de entrada e 2 neurônios de saída.

Nesta etapa, primeiro o conjunto de soluções operativas \mathbb{X} , é dividido em dados para treinamento e teste. Os dados de treinamento são compostos por 50% de soluções com sobretensão, \mathbb{T}_u , e 50% de soluções em condições normais de operação, \mathbb{T}_s . O conjunto de dados para teste consiste nos dados remanescentes, isto é, que não foram empregados no processo de treinamento. Para o treinamento das ANNs, o critério de porcentagem de sucesso

(CPS) é adotado. Deste modo, a convergência é assumida se a redução do MSE não ocorrer durante seis tentativas consecutivas e sua precisão for igual ou superior a seu CPS.

O fluxograma ilustrado na Figura 3.4 descreve o processo de treinamento, validação e teste dessa ANN, onde ε é o máximo erro adotado.

Após a obtenção das soluções das ANNs de reconhecimento de padrão, os resultados correspondentes aos padrões de geração renovável são agrupados utilizando redes neurais de mapa auto-organizável (Seção 2.1.7). Nesta etapa, os resultados das ANNs de mapa auto-organizável são organizados em conjuntos com condições normais de operação e sobretensão. Essas redes possuem uma camada, treinamento *learnsom*, dois neurônios de entrada e dois neurônios de saída e topologia do tipo hexagonal. O fluxograma ilustrado na Figura 3.5 descreve o processo de treinamento, validação e teste dessa ANN.

Desta forma, a metodologia proposta consiste em uma ferramenta que pode ser empregada para o planejamento e a operação do sistema elétrico de potência em direção a alta penetração de fontes renováveis distribuídas. Nesta perspectiva, a modernização do sistema elétrico de potência pode ser coordenada de forma confiável e segura, onde possíveis condições operativas insatisfatórias poderão ser rapidamente detectadas durante as etapas de planejamento e operação. Isso permite uma redução significativa do custo computacional no planejamento, tal como determinação de ações de controle efetivas em tempo real com baixo custo computacional. O fluxograma ilustrado na Figura 3.6 apresenta uma perspectiva geral da metodologia proposta baseada em ANNs.

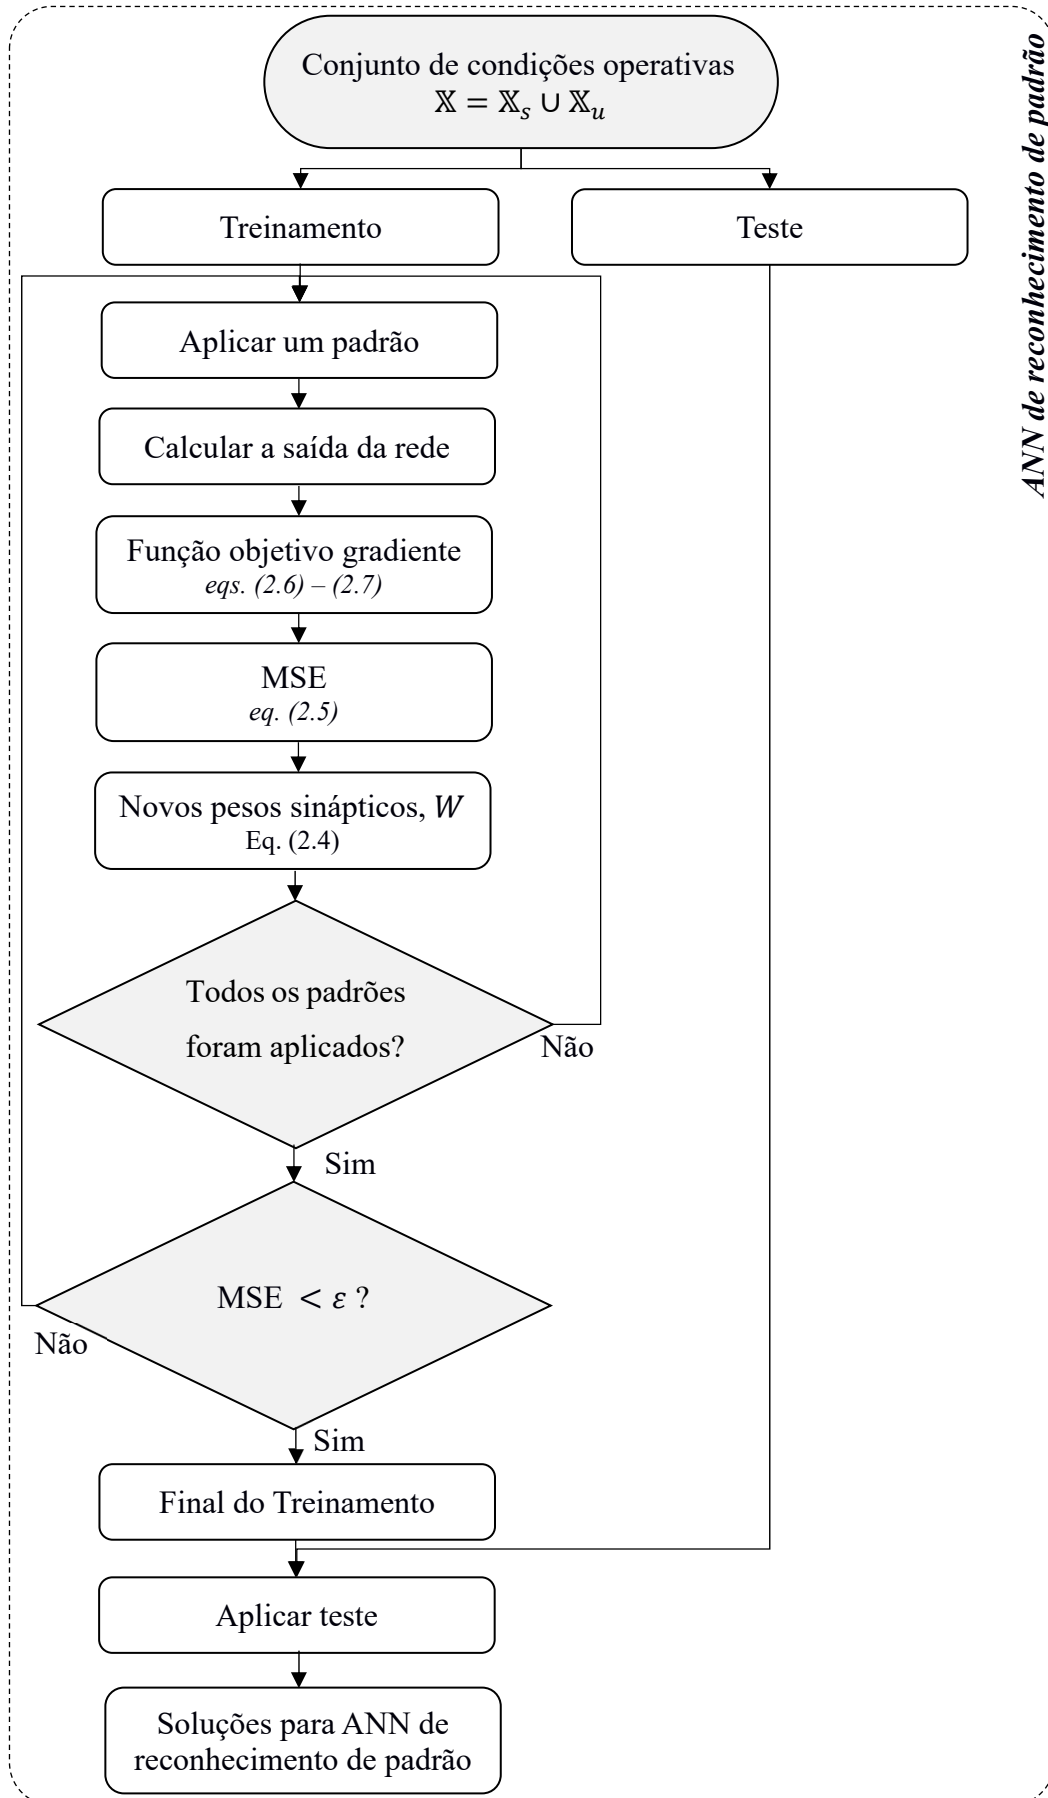


Figura 3.4 - Fluxograma – ANN de reconhecimento de padrão

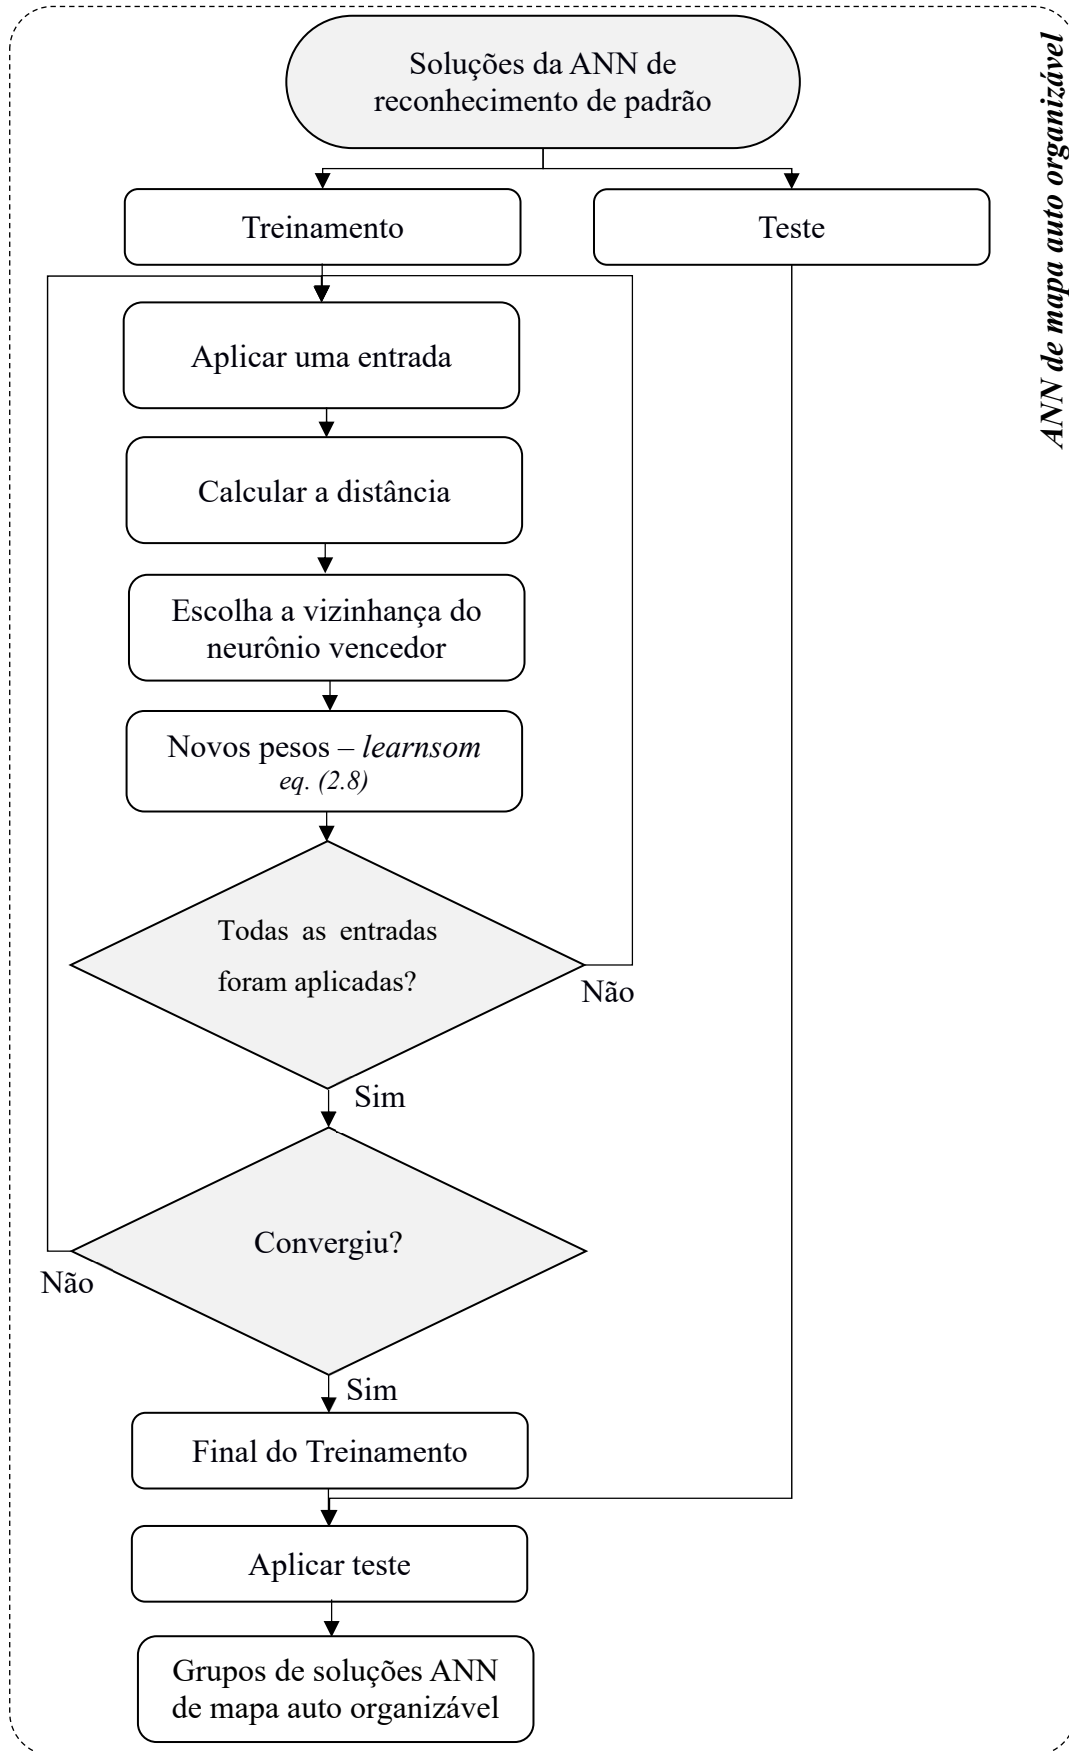


Figura 3.5 - Fluxograma - ANN mapa auto-organizável

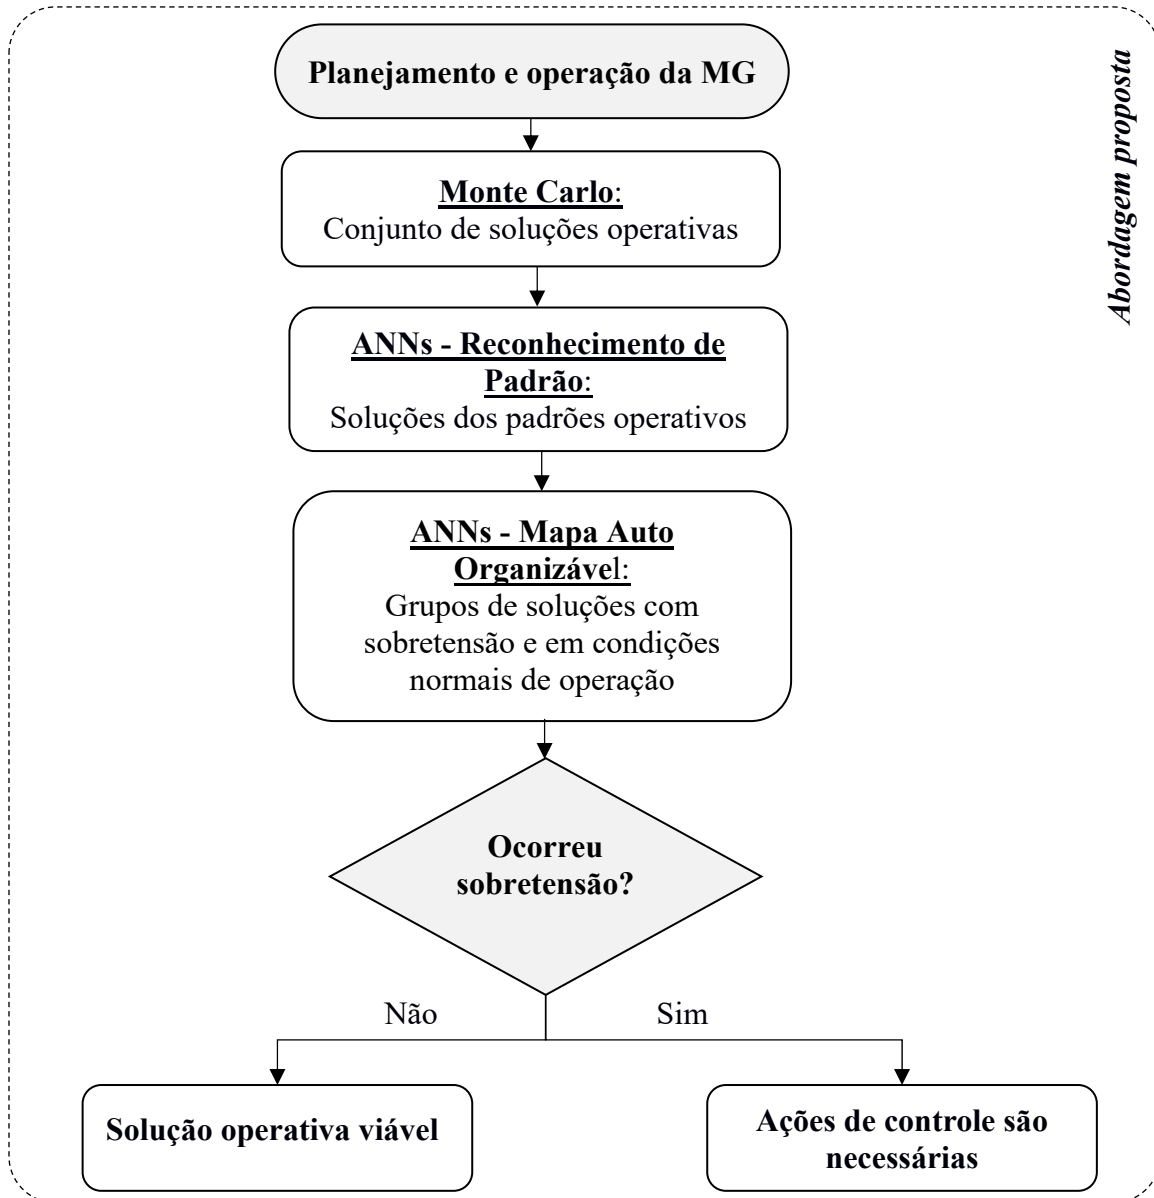


Figura 3.6 - Fluxograma da abordagem proposta

4 Capítulo - Resultados e Análises

Nesta seção, a efetividade da abordagem proposta para determinação das condições operativas de uma MG com alta penetração de geração renovável é verificada. Para validação do método proposto, a MG foi representada pelo sistema IEEE 34-barras modificado, conforme ilustrado na Figura 4.1.




Figura 4.1 - Sistema IEEE 34-barras modificada [42]

O sistema IEEE 34-barras trifásico desequilibrado representa uma rede de distribuição real localizada nos Estados Unidos da América, no estado do Arizona. Suas características incluem um sistema aéreo com topologia radial, reguladores de tensão, derivações monofásicas, compensação *shunt* por capacitores e cargas concentradas e distribuídas constituídas. A potência base é de 2,5 MVA e a tensão de linha base da rede é de 24,9 kV. Os parâmetros e as condições iniciais do sistema aplicados estão disponíveis no Anexo A e os dados originais disponíveis em [43].

Este sistema foi modificado considerando a inserção do conjunto de geradores renováveis intermitentes $\{G_1, G_2\}$, onde G_1 e G_2 correspondem respectivamente a geração eólica e solar. Esses geradores são conectados diretamente no conjunto de barras PQ, $g = \{810, 890\}$.

Baseado na proposta deste trabalho, duas principais análises são realizadas. A primeira análise descreve o treinamento, a validação e o teste das ANNs de reconhecimento de padrão e mapa auto-organizável. Em seguida, a segunda análise demonstra a aplicação do método proposto para determinação de possíveis ações de controle para garantir condições operativas satisfatórias para a MG ao longo do dia.

As análises são realizadas para um conjunto de dados contendo 6100 amostras, que foi obtido empregando o método de Monte Carlo. Esse conjunto de amostras é composto por duas

entradas referentes a cada fonte de geração renovável, $\{P_{1(G)}, P_{2(G)}\}$ e uma saída que representa se o limite de tensão foi violado ou não. Para isso, o limite máximo de tensão adotado corresponde a $\bar{V} = 1,05$ pu, seguindo os padrões estabelecidos pela Agência Nacional de Energia Elétrica (ANEEL) [44].

Na etapa de treinamento das ANNs, 200 amostras foram utilizadas e igualmente divididas entre as condições que violam ou não os limites de tensão e 200 amostras para teste para treinamento. Já na etapa de teste foram empregadas 5900 amostras, como indica a Tabela 4.1. A abordagem proposta emprega três ANNs: 1) A primeira ANN tem como objetivo identificar quando o conjunto de geradores renováveis $\{G_1, G_2\}$ ou se apenas um deles conduzirá o sistema a sobretensão; 2) A segunda e a terceira ANNs determinam respectivamente se será a turbina eólica ou painel solar G_1 ou G_2 que levará o sistema a sobretensão.

Tabela 4.1 - Descrição do conjunto de amostras para treinamento e teste

Rede Neural Artificial	Número de amostras de treinamento		Conjunto de amostras para etapa de validação	Conjunto de amostras para etapa de testes
	$ \mathbb{T}_s $	$ \mathbb{T}_u $		
ANN ₁	100	100	201° – 400°	201° – 6100°
ANN ₂	100	100	201° – 400°	201 st – 6100°
ANN ₃	100	100	201° – 400°	201 st – 6100°

4.1 Treinamento, Validação e Teste das Redes Neurais

Esta seção tem como foco demonstrar os resultados referentes ao treinamento, validação e testes das ANNs de reconhecimento de padrão e mapa auto-organizável.

4.1.1 ANN de Reconhecimento de Padrão

Primeiramente, como dados de entrada para as ANNs, considera-se o conjunto de soluções operativas obtidas ao empregar o método de Monte Carlo, para um conjunto randômico de geração que possui um limite de $\overline{P_{1(G)}} = 10,5$ MW e $\overline{P_{2(G)}} = 5,25$ MW, respectivamente para as fontes de energia eólica e solar.

Para o treinamento das ANN₁, ANN₂ e ANN₃ de reconhecimento de padrão foram empregadas um conjunto de 200 amostras de treinamento e 200 amostras de teste para treinamento, conforme indicado pela Tabela 4.1.

A verificação da validação do erro para cada ANN é apresentada na Figura 4.2. Nota-se que para ANN₁, Figura 4.2a), a convergência ocorre após a época 56 de treinamento uma vez que a redução do MSE não ocorreu durante as seis tentativas consecutivas após a época 50 e sua precisão atingiu o CPS. Em contraste, para as ANN₂ e ANN₃ a convergência ocorre com 55 e 105 épocas conforme ilustram as Figura 4.2b) e Figura 4.2c), respectivamente.

Ainda na etapa de treinamento, a melhor performance de treinamento, validação e teste do treinamento são obtidas e representadas nas Figura 4.3a), 4.3b) e 4.3c), respectivamente para cada ANN. Na Figura 4.3a), para ANN₁ verifica-se que isso ocorre para $MSE = 22,5e^{-3}$, enquanto para as ANN₂ e ANN₃ nas Figura 4.3b) e 4.3c) a convergência ocorre para $MSE = 4,8e^{-5}$ e $MSE = 2,1e^{-6}$.

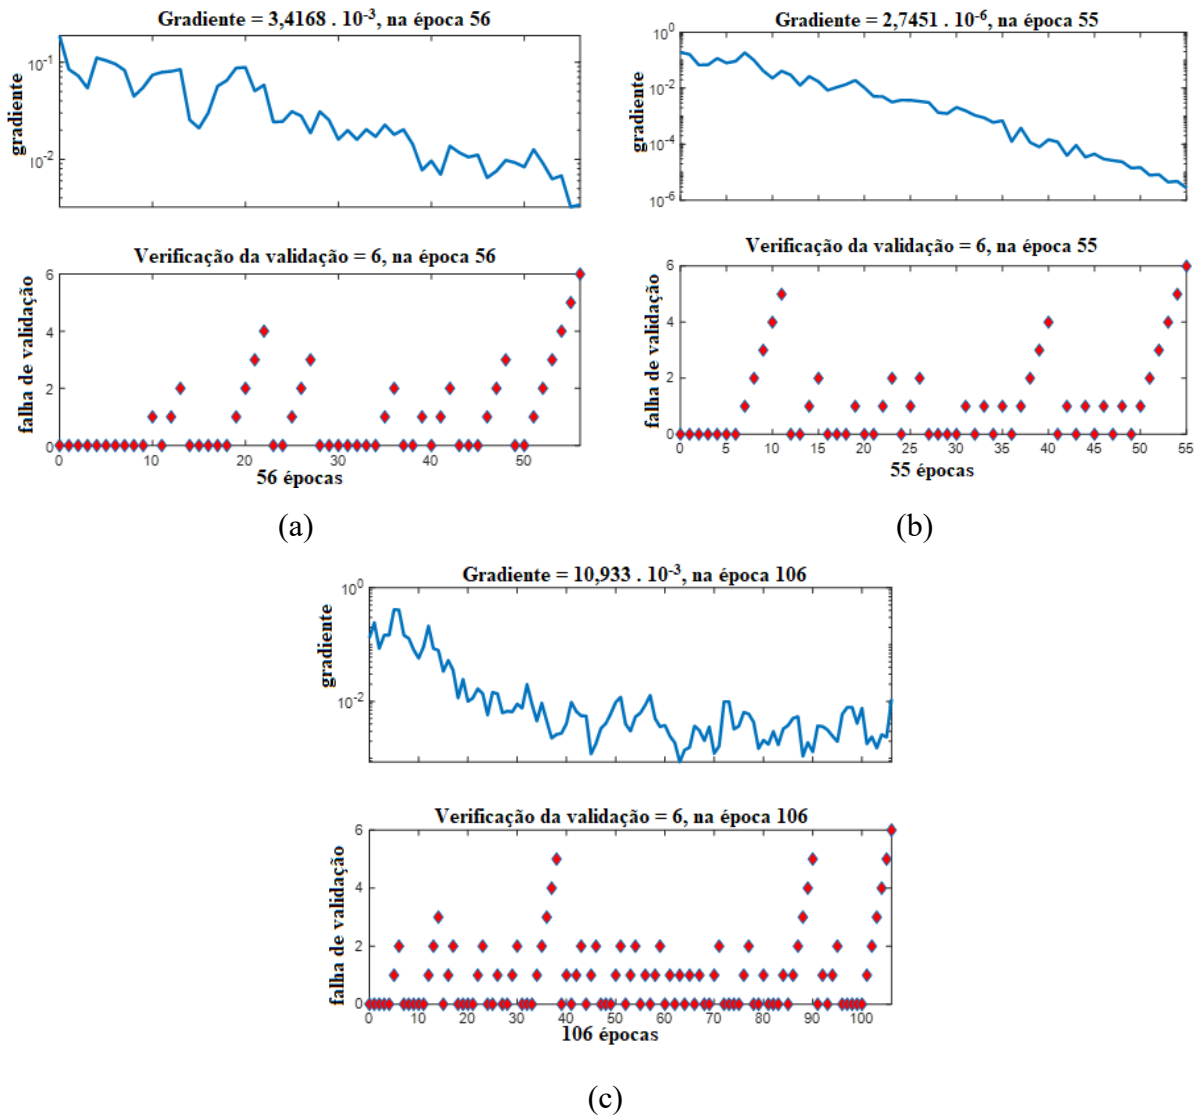


Figura 4.2 - Verificação do erro de validação: (a) ANN1, (b) ANN2, (c) ANN3

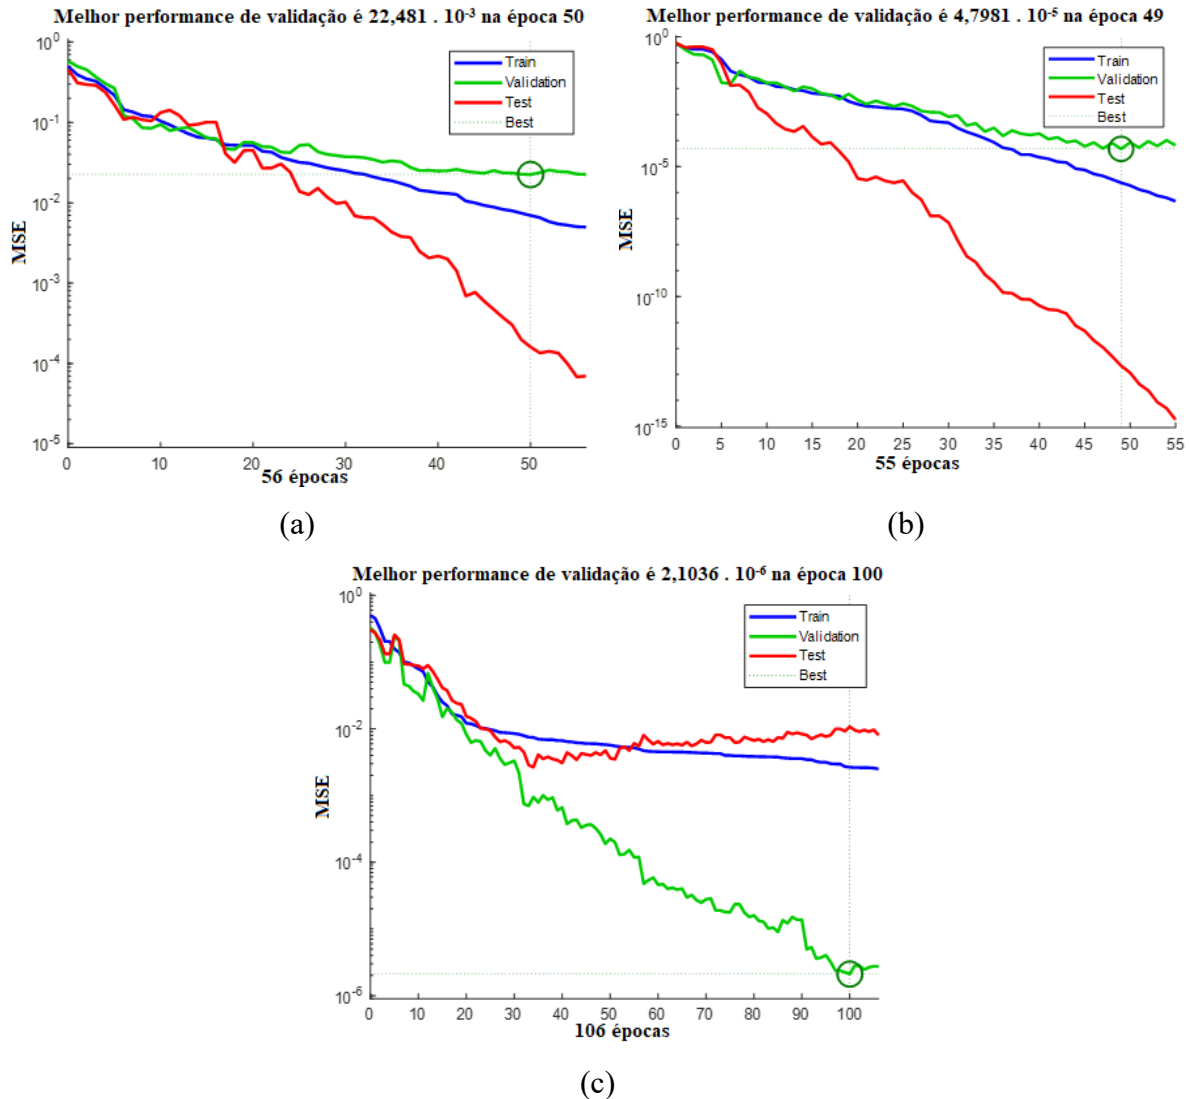


Figura 4.3 - Performance do treinamento das ANNs: (a) ANN1, (b) ANN2, (c) ANN3

Em seguida, a etapa de teste é executada para um conjunto de 5900 amostras e os resultados para cada ANN são descritos nas matriz *confusion* (matriz de confusão) apresentadas respectivamente pelas Figura 4.4a), 4.4b) e 4.4c).

Na matriz de confusão, o índice “1” indica se não houve violação do limite de tensão, já o índice “2” indica se houve violação do limite de tensão. As duas primeiras células da diagonal principal (células com a coloração em verde) indicam o percentual e o número de classificações corretas da rede neural treinada. Em contrapartida, as duas células com a coloração em vermelho indicam o percentual e o número de classificações incorretas que a rede neural gera. A última célula da diagonal principal (célula com a coloração em cinza mais escuro) apresenta a precisão global das previsões corretas e incorretas.

Para o processo de teste da ANN₁, a metodologia proposta apresenta desempenho de 93,1% de precisão para identificar as condições em que a operação de G1 e G2 (ambos ou

individualmente) não resultaram em sobretensão e 6,9% das condições que violaram a ANN₁ foram previstas incorretamente. Ocorreu 99,7% de precisão na determinação de condições que resultaram na sobretensão em alguma barra da MG, enquanto apenas 0,3% não violaram o limite máximo de tensão e foram classificados como violados. Essas classes que são indicadas corretamente e incorretamente são chamadas de taxa falso positiva e taxa de falso negativo, respectivamente.

Além disso, 99,8% foram corretamente classificadas como condições que não violaram e apenas 0,2% das condições que não violaram foram classificadas como cenários de violação. Portanto, 90,3% das condições foram corretamente classificadas como violadas e 9,7% foram erroneamente classificadas. Essas classes classificadas corretamente e incorretamente são chamadas de taxa falso positivo e taxa falso negativo, respectivamente.

Finalmente, a ANN₁ apresentou uma precisão global de previsões corretas de 95,7% e 4,3% de previsões incorretas. Esta informação é mostrada na representação de confusão matricial mostrada na Figura 4.4a). Seguindo o mesmo raciocínio, conforme as Figuras 4.4b) 4.4c) respectivamente para as ANN₂ e ANN₃ foram obtidas precisões globais de previsões corretas de 98,6% e 93,2%; e 1,4% e 6,8% de previsões incorretas.

Matriz de Confusão

Classe de saída	1	3341 56.6%	7 0.1%	99.8% 0.2%
	2	248 4.2%	2304 39.1%	90.3% 9.7%
	3	93.1% 6.9%	99.7% 0.3%	95.7% 4.3%
		1	2	3
		Classe alvo		

(a)

Matriz de Confusão

Classe de saída	1	4050 68.6%	0 0.0%	100% 0.0%
	2	84 1.4%	1766 29.9%	95.5% 4.5%
	3	98.0% 2.0%	100% 0.0%	98.6% 1.4%
		1	2	3
		Classe alvo		

(b)

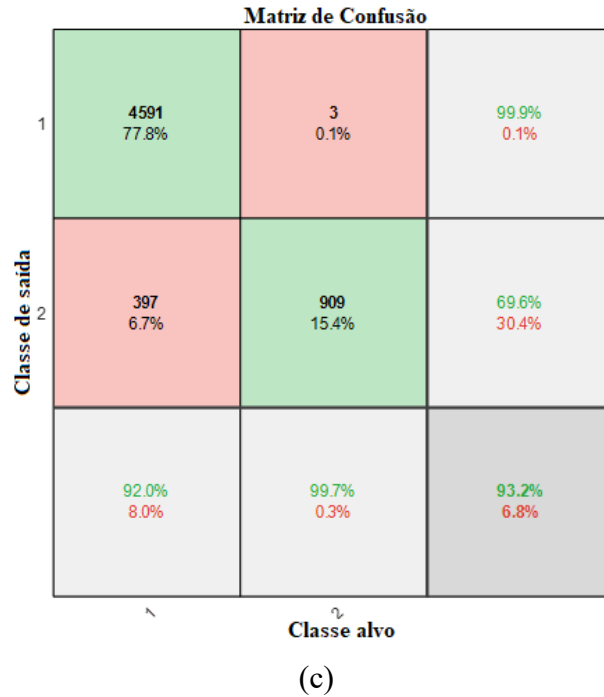


Figura 4.4 - Matriz *Confusion* para o teste de 5900 amostras: (a) ANN1, (b) ANN2, (c) ANN3

A porcentagem de previsões corretas e erradas é apresentada resumidamente para todas as ANNs durante a etapa de treinamento e testes na Tabela 4.2.

Tabela 4.2 - Resultados da etapa de testes das ANNs

	Validação		Teste	
	Correto	Errado	Correto	Errado
<i>ANN1</i>	95,5 %	4,5%	95,7%	4,3%
<i>ANN2</i>	97,5%	2,5%	98,6 %	1,4%
<i>ANN3</i>	93%	7,0%	93,2%	6,8%

4.1.2 ANN de Mapa Auto-Organizável

Após a obtenção dos padrões das gerações que resultam ou não na violação do limite superior de tensão, esses dados são aplicados nas ANN₁, ANN₂ e ANN₃ de mapa auto organizável.

Baseado no treinamento das ANNs pode se verificar quantos dados foram associados a cada neurônio como pode ser observado na Figura 4.5. Nota-se que, como desejável, os dados foram distribuídos de maneira uniforme entre os neurônios para as ANN₁, ANN₂ e ANN₃, respectivamente descritas nas Figuras 4.5a), 4.5b) e 4.5c).

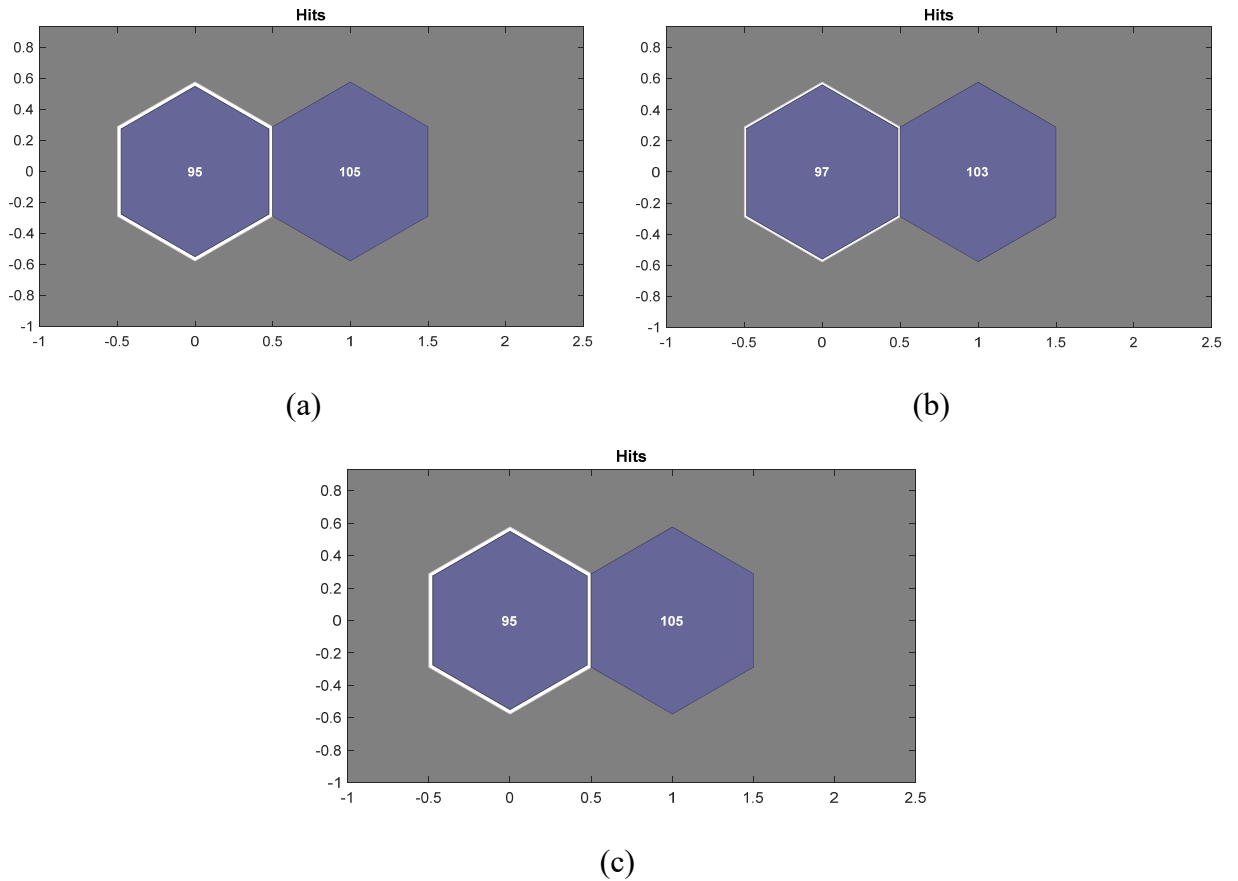


Figura 4.5 - Hits: (a) ANN1, (b) ANN2, (c) ANN3

Em seguida, nas Figuras 4.6a), 4.6b) e 4.6c) é possível observar como a rede SOM classifica o espaço de entrada para as ANN₁, ANN₂ e ANN₃ respectivamente, onde os pontos em verdes são os vetores de entrada, os pontos cinza-azulados correspondem aos pesos de cada neurônio e os neurônios vizinhos são conectados com as linhas vermelhas.

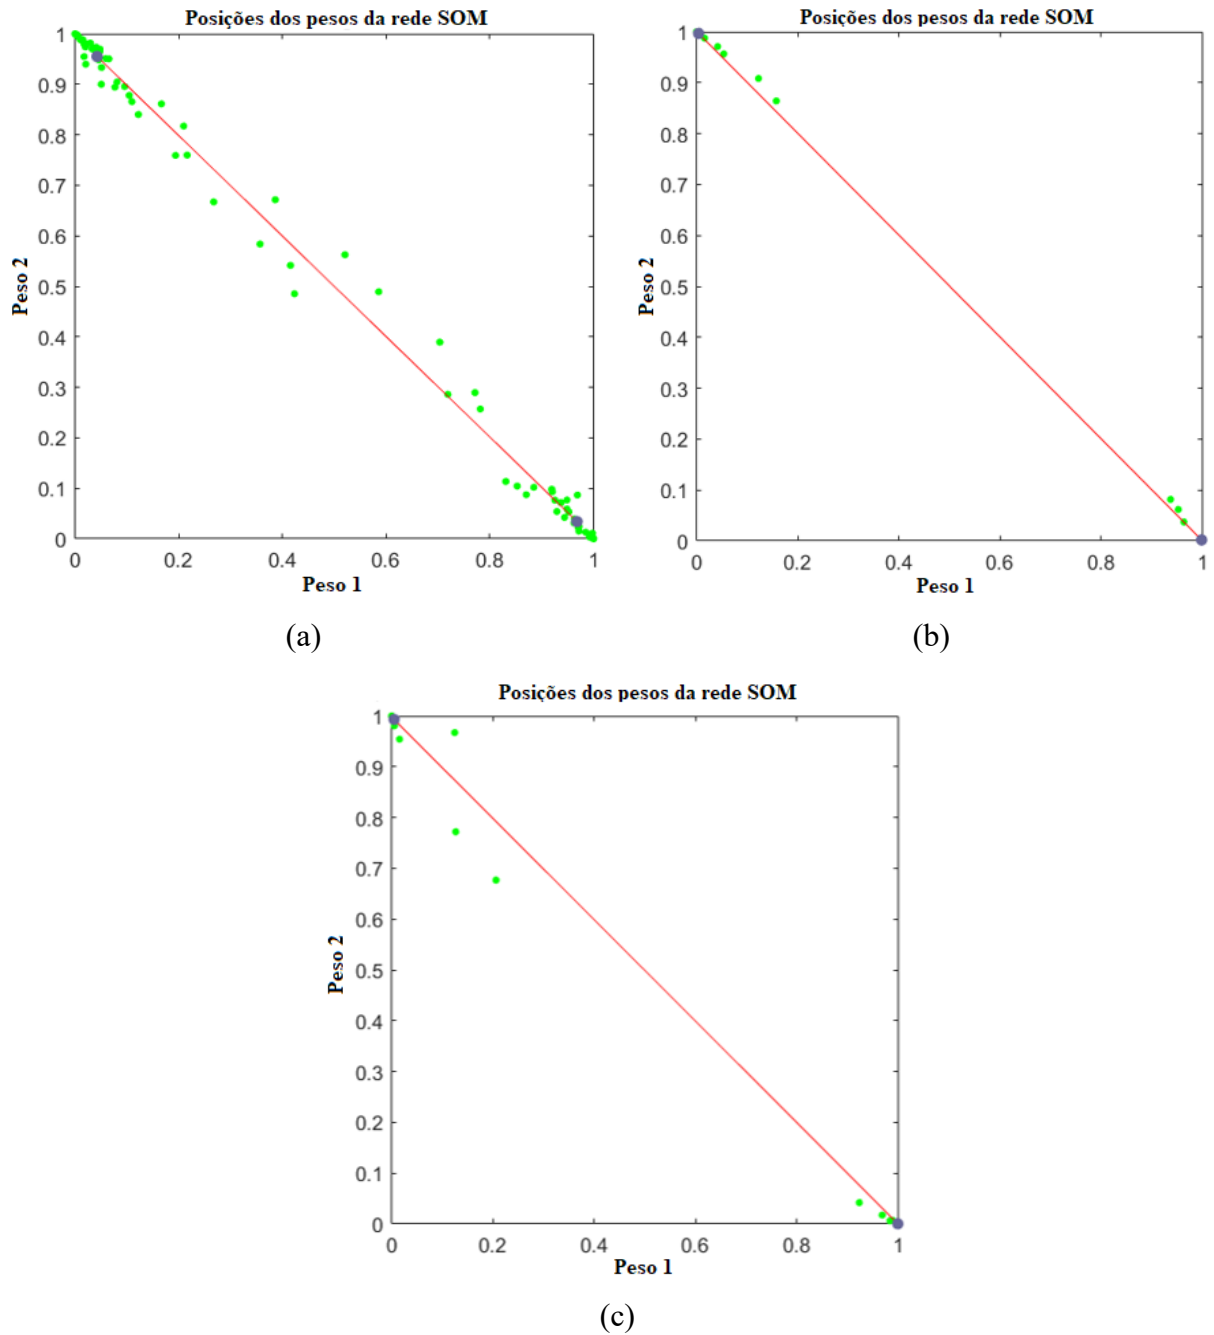


Figura 4.6 - Posições dos pesos da SOM: (a) ANN1, (b) ANN2, (c) ANN3

4.2 Aplicação da Metodologia Proposta

Nesta seção, a aplicabilidade da metodologia proposta baseada nas ANNs abordadas nas subseções anteriores é demonstrada para o planejamento e a operação da MG. Para isso, considera-se a intermitência da geração renovável despachada, eólica e solar, conforme as mudanças climáticas durante um dia inteiro. Para o modelo de geração eólica (Seção 3.1.1.2), uma curva de perfil de vento foi utilizada e ilustrada pela Figura 4.7, enquanto para o modelo de geração solar (Seção 3.1.1.1), os perfis de temperatura e radiação solar são empregados e descritos respectivamente nas Figuras 4.8 e 4.9.




Figura 4.7 - Perfil de velocidade do vento

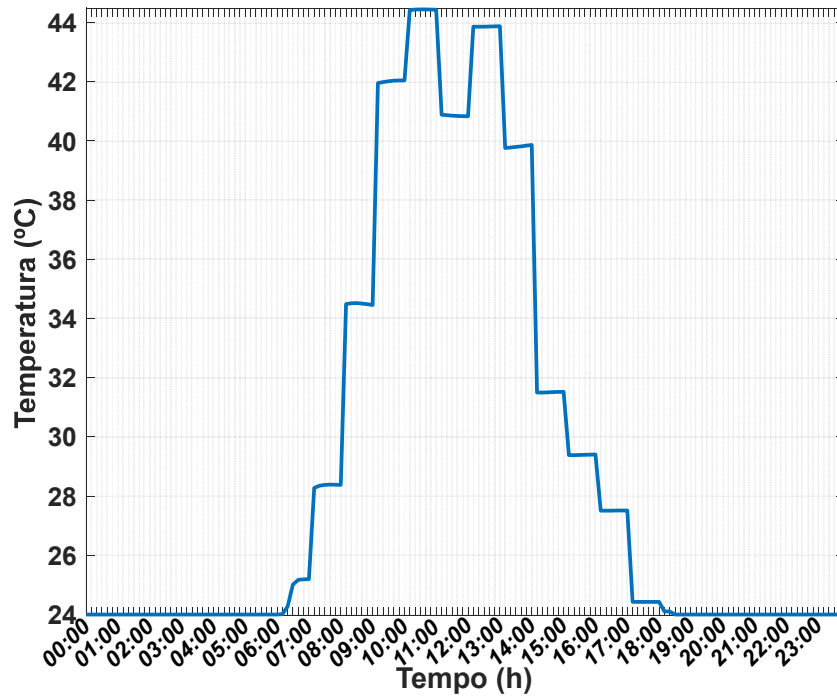


Figura 4.8 - Perfil de temperatura




Figura 4.9 - Perfil de radiação solar

Com base nesses dados, as potências geradas pelas fontes de energia eólica e solar são obtidas e representadas na Figura 4.10. Essas gerações são distribuídas igualmente para cada fase dos nós {810,890} MG. É possível observar que o máximo aproveitamento da fonte eólica

ocorre nos períodos de 6h30min – 14h00min e 16h10min – 19h00min, enquanto os dois maiores picos de geração solar ocorrem nos intervalos de 10h10min – 11h:00min e 12h10min – 13h:00min.

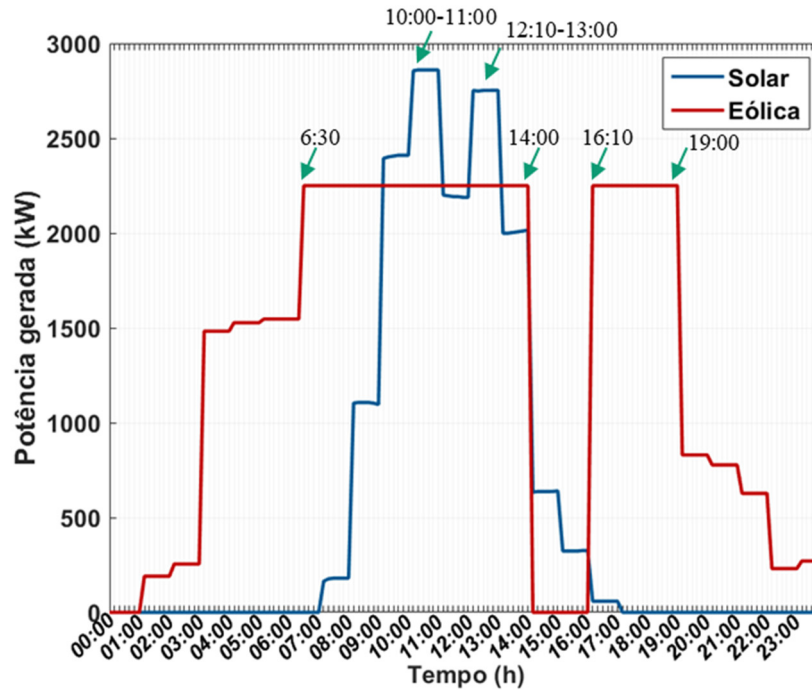


Figura 4.10 - Perfil de geração eólica e solar

O perfil de carga de potência ativa e reativa da MG são representados respectivamente nas Figura 4.11 e Figura 4.12. Pode-se observar claramente que o horário de pico ocorre quando os consumidores retornam do trabalho.




Figura 4.11 - Perfil de carga de potência ativa

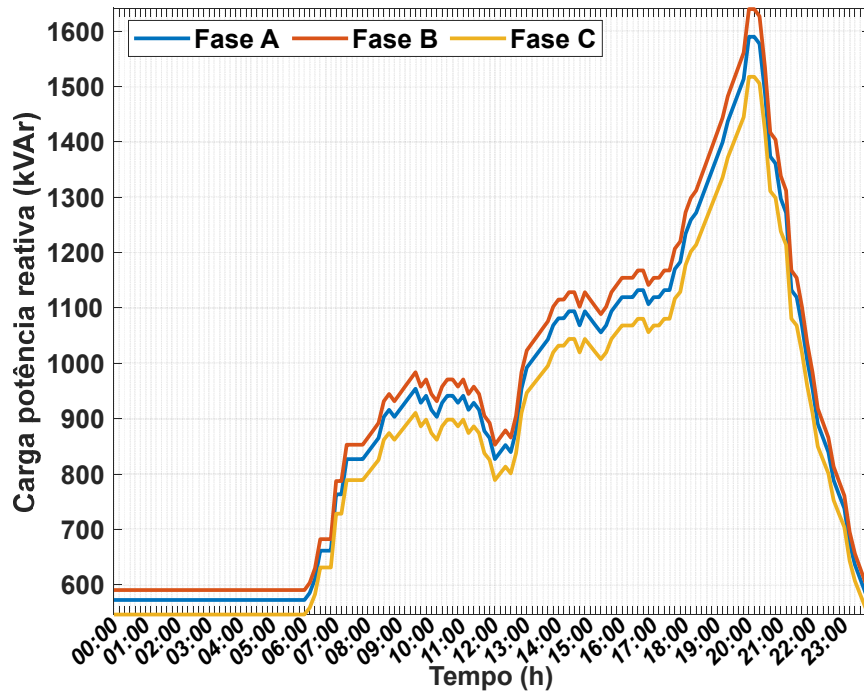


Figura 4.12 - Perfil de carga de potência reativa

Os perfis de tensão para cada fase de todas as barras da MG são representados respectivamente nas Figura 4.13, Figura 4.14 e Figura 4.15 enquanto o maior valor ocorrido para cada fase é ilustrado na Figura 4.16. Pode-se observar que os valores em que ocorreram a sobretensão correspondem aos intervalos onde ocorrem o maior aproveitamento eólico e solar. Além disso, os valores de tensão próximo ao limite de tensão são referentes às barras localizadas na vizinhança dos barramentos que apresentam a geração eólica e solar. Nota-se, nos intervalos de tempo de 10h10min – 11h:00min e 12h10min – 13h:00min da figura 4.14, ocorrem dois picos de sobretensão (curva em verde) cujo o formato da onda é similar a apresentada nas Figuras 4.8 – 4.10. Haja vista, que nestes períodos ocorrem a máxima geração de energia renovável fotovoltaica.




Figura 4.13 - Perfil de tensão na fase a

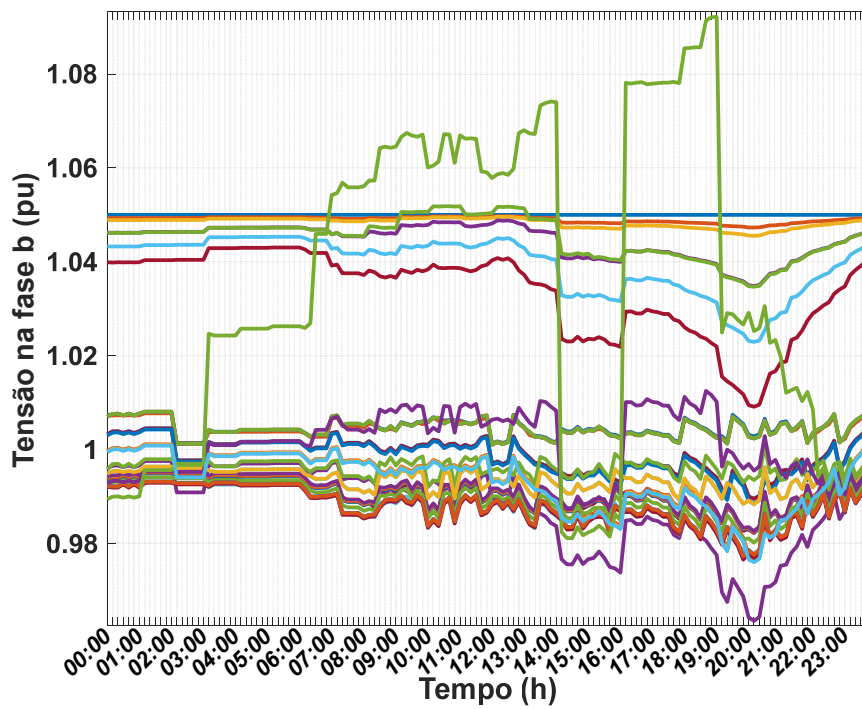


Figura 4.14 - Perfil de tensão na fase b

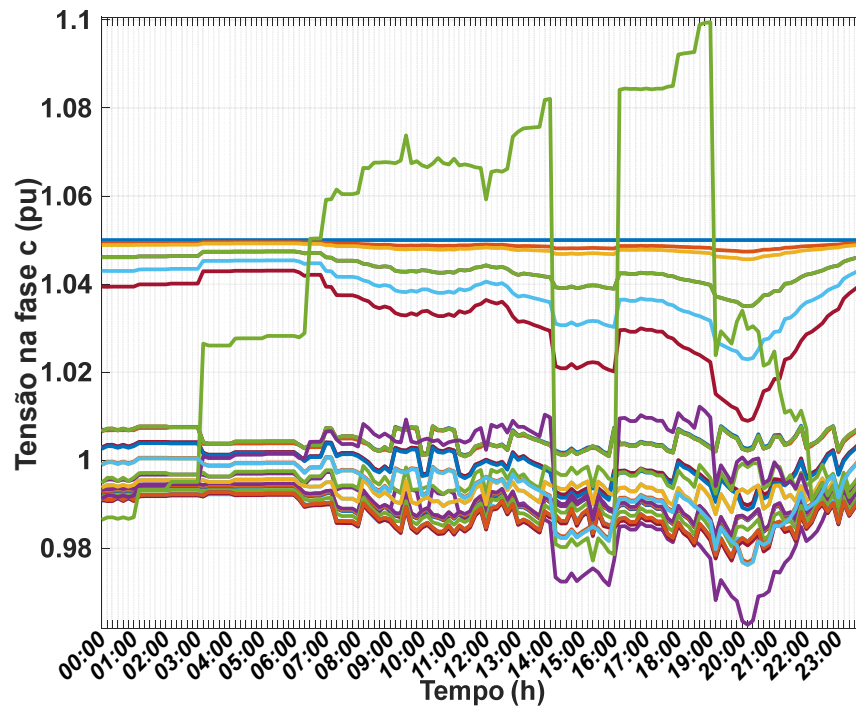


Figura 4.15 - Perfil de tensão na fase c

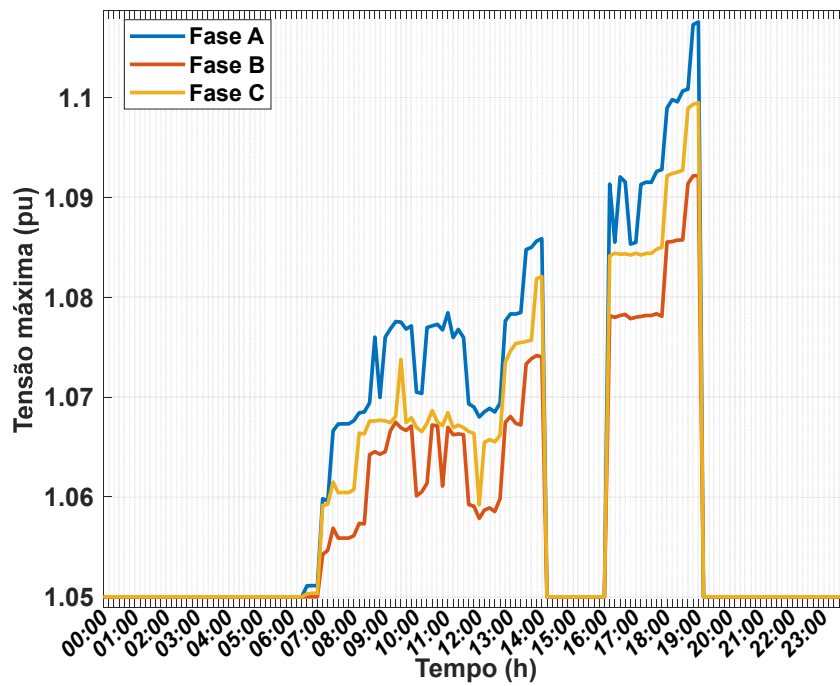


Figura 4.16 - Máxima tensão na fase a, b, c

Com base nesses dados acima, as condições operativas são aplicadas primeiramente às ANNs de reconhecimento de padrão que já foram treinadas anteriormente. Em seguida, as soluções operativas são empregadas nas ANNs de mapa auto organizável e os conjuntos de soluções operativas satisfatórias e insatisfatórias são obtidos. Essas soluções para ANN₁ e ANN₂ são apresentadas pela Figura 4.17, enquanto para ANN₃ as soluções são apresentadas pela Figuras 4.18. Nas Figuras 4.17 e Figura 4.18, '0' indica uma condição satisfatória, i.e., não houve sobretensão, enquanto '1' indica uma condição insatisfatória, em que ocorre a sobretensão.

Conforme visto na Figura 4.17 a geração eólica é a responsável por todos os intervalos com sobretensão, onde a solução determinada pela ANN₁ foi equivalente à ANN₂. No entanto, a geração solar também tem participação conforme ilustra a Figura 4.18. Como era esperado, as condições insatisfatórias ocorrem nos mesmos intervalos de maior aproveitamento de geração renovável mencionados anteriormente.




Figura 4.17 - Identificação da sobretensão na MG e devido ao Gerador 1




Figura 4.18 - Identificação da sobretensão devido ao Gerador 2

Tendo em vista esses resultados, é possível validar a aplicabilidade da metodologia proposta para o planejamento da operação e durante a operação de MGs. Logo, a partir do conhecimento do local onde as ações de controle devem ocorrer, as sobretensões podem ser eliminadas. Para isso, foram adicionados compensadores reativos indutivos de 375 kVA em cada fase nas barras que possuem os potenciais eólicos e solares para os respectivos intervalos indicados nas Figura 4.17 e Figura 4.18.

Após a compensação de reativo, pode-se observar os novos perfis de tensão para as três fases de todas as barras da MG ilustrados nas Figura 4.19, Figura 4.20 e Figura 4.21. Nota-se que a nova condição operativa da MG se encontra satisfatória para o dia inteiro, onde todas as tensões estão respeitando o limite superior.




Figura 4.19 - Perfil de tensão após a compensação na fase a




Figura 4.20 - Perfil de tensão após a compensação na fase b




Figura 4.21 - Perfil de tensão após a compensação na fase c

5 Capítulo - Conclusões

5.1 Considerações Finais

Levando em consideração as modificações que estão ocorrendo na rede elétrica, como por exemplo, a crescente participação de geração renovável, principalmente eólica e solar, este trabalho teve como propósito, de maneira geral, auxiliar e orientar a operação e o planejamento das MGs. O objetivo principal foi propor uma ferramenta para lidar com a intermitência dessas gerações.

Os resultados apresentam uma metodologia robusta capaz de auxiliar o operador do sistema na tomada de decisão sobre a operação de geradores renováveis, uma vez que as contribuições da geração solar e eólica são intermitentes devido às condições climáticas. Além disso, também pode ajudar no planejamento da conexão de novas unidades geradoras. Portanto, além de determinar que existirá um possível cenário operacional que leve à violação dos limites de tensão, essa metodologia também é capaz de indicar qual gerador é a causa.

A proposta de ANN apresentou resultados satisfatórios, uma vez que o percentual de previsões corretas foi superior a 90% e, conseqüentemente, o percentual de previsões incorretas está abaixo de 10% para todos os cenários. Uma vez que a taxa de descoberta falsa e a taxa de falsos negativos também foram inferiores a 10% para todos os casos, este método demonstrou boa capacidade para mapear as características não lineares dos sistemas de energia elétrica e auxiliar grandemente sua operação e planejamento.

Uma ferramenta é proposta para auxiliar a operação e o planejamento do sistema elétrico de curto prazo. Motivada pelo aumento da participação de geração intermitente no sistema de potência.

5.2 Principais Contribuições

As principais contribuições do trabalho na literatura são:

- Desenvolvimento de uma metodologia robusta capaz de orientar o operador do sistema sobre um possível cenário operacional que leve à violação dos limites de tensão diante de mudanças climáticas, indicando a localização da causa,
- Proposta de uma ferramenta para apoiar a operação e o planejamento da expansão da MG, trazendo, assim, eficiência na alocação de novos geradores renováveis distribuídos.

Além dos diversos trabalhos realizados ao longo do Mestrado, esta dissertação em especial gerou a publicação:

L. F. R. Monteiro, J. R. Monteiro, L. H. C. Ferreira, A. C. Z. de Souza and B. I. L. Lopes, “Determination of renewable generation operation with the aid of the ANN,” *IEEE International Conference on Industry Applications, INDUSCON*, São Paulo, BR, 2018, pp. 375-380.

5.3 Propostas de Trabalhos Futuros

- Determinar novas ações de controle corretivas e políticas de gerenciamento de carga;
- Identificar as condições operativas satisfatórias e insatisfatórias para sistemas envolvendo multi-microrredes (MMG),
- Auxiliar no planejamento para expansão do sistema com foco na inserção de novos recursos renováveis.

Referências

- [1] P. Kundur, *Power System Stability and Control*. New York, NY, USA: McGraw-Hill, 1994.
- [2] G. W. Arnold, “Challenges and opportunities in smart grid: a position article,” in *Proc. of the IEEE*, vol. 99, no. 6, pp. 922-927, June 2011.
- [3] S. Davies, “Grid gets the smarts [power smart grid],” in *Engineering & Technology*, vol. 7, no. 12, pp. 42-45, Jan. 2013.
- [4] A. Gómez-Expósito *et al.*, “City-friendly smart network technologies and infrastructures: the spanish experience,” in *Proc. of the IEEE*, vol. 106, no. 4, pp. 626-660, Apr. 2018.
- [5] S. Parhizi, H. Lotfi, A. Khodaei and S. Bahramirad, “State of the art in research on microgrids: a review,” *IEEE Access*, vol. 3, pp. 890-925, June 2015.
- [6] M. Farrokhhabadi *et al.*, “Microgrid stability definitions, analysis, and examples,” *IEEE Trans. Power Syst.*, vol. 35, no. 1, pp. 13-29, Jan. 2020.
- [7] Z. Li, M. Shahidehpour, F. Aminifar, A. Alabdulwahab and Y. Al-Turki, “Networked microgrids for enhancing the power system resilience,” in *Proc. of the IEEE*, vol. 105, no. 7, pp. 1289-1310, July 2017.
- [8] A. Hussain, V. Bui and H. Kim, “Robust optimal operation of AC/DC hybrid microgrids under market price uncertainties,” *IEEE Access*, vol. 6, pp. 2654-2667, Feb. 2018.
- [9] H. Ali, A. Hussain, V. Bui and H. Kim, “Consensus algorithm-based distributed operation of microgrids during grid-connected and islanded modes,” *IEEE Access*, vol. 8, pp. 78151-78165, May 2020.
- [10] Y. Wu, G. J. Lim and J. Shi, “Stability-constrained microgrid operation scheduling incorporating frequency control reserve,” *IEEE Trans. on Smart Grid*, vol. 11, no. 2, pp. 1007-1017, Mar. 2020.
- [11] A. Hussain, V. Bui and H. Kim, “A proactive and survivability-constrained operation strategy for enhancing resilience of microgrids using energy storage system,” *IEEE Access*, vol. 6, pp. 75495-75507, Dec. 2018.
- [12] F. K. Tuffner, K. P. Schneider, J. Hansen and M. A. Elizondo, “Modeling load dynamics to support resiliency-based operations in low-inertia microgrids,” *IEEE Trans. on Smart Grid*, vol. 10, no. 3, pp. 2726-2737, May 2019.
- [13] J. Zhao and Z. Xu, “Ramp-limited optimal dispatch strategy for PV-embedded microgrid,” *IEEE Trans. on Power Systems*, vol. 32, no. 5, pp. 4155-4157, Sept. 2017.
- [14] J. Tang, M. Ding, S. Lu, S. Li, J. Huang and W. Gu, “Operational flexibility constrained intraday rolling dispatch strategy for CHP microgrid,” *IEEE Access*, vol. 7, pp. 96639-96649, Aug. 2019.

- [15] M. F. Shaaban, S. Mohamed, M. Ismail, K. A. Qaraqe and E. Serpedin, "Joint planning of smart EV charging stations and DGs in eco-friendly remote hybrid microgrids," *IEEE Trans. on Smart Grid*, vol. 10, no. 5, pp. 5819-5830, Sept. 2019.
- [16] A. Khayatian, M. Barati and G. J. Lim, "Integrated microgrid expansion planning in electricity market with uncertainty," *IEEE Trans. on Power Systems*, vol. 33, no. 4, pp. 3634-3643, July 2018.
- [17] A. Khodaei, S. Bahramirad and M. Shahidehpour, "Microgrid planning under uncertainty," *IEEE Trans. on Power Systems*, vol. 30, no. 5, pp. 2417-2425, Sept. 2015.
- [18] Q. Chen, M. Xia, Y. Zhou, H. Cai, J. Wu and H. Zhang, "Optimal planning for partially self-sufficient microgrid with limited annual electricity exchange with distribution grid," *IEEE Access*, vol. 7, pp. 123505-123520, Sept. 2019.
- [19] S. Haghifam, K. Zare and M. Dadashi, "Bi-level operational planning of microgrids with considering demand response technology and contingency analysis," *IET Gener., Transmission & Distribution*, vol. 13, no. 13, pp. 2721-2730, July 2019.
- [20] N. Kanwar, N. Gupta, K. R. Niazi and A. Swarnkar, "Optimal distributed resource planning for microgrids under uncertain environment," *IET Renew. Power Gener.*, vol. 12, no. 2, pp. 244-251, Feb. 2018.
- [21] P. Li, D. Xu, Z. Zhou, W. Lee and B. Zhao, "Stochastic optimal operation of microgrid based on chaotic binary particle swarm optimization," *IEEE Trans. on Smart Grid*, vol. 7, no. 1, pp. 66-73, Jan. 2016.
- [22] M. H. Elkazaz, A. A. Hoballah and A. M. Azmy, "Operation optimization of distributed generation using artificial intelligent techniques," *Ain Shams Engineering Journal*, vol. 7, pp. 855-866, June 2016.
- [23] V. L. Merlin, R. C. Santos, A. P. Grilo, J. C. M. Vieira, D. V. Coury and M. Oleskovicz, "A new artificial neural network based method for islanding detection of distributed generators," *Int. J. Electr. Power Energy Syst.*, vol. 75, pp. 139-151, Feb. 2016.
- [24] Y. Hong and M. T. A. M. Cabatac, "Fault detection, classification, and location by static switch in microgrids using wavelet transform and taguchi-based artificial neural network," *IEEE Systems Journal*, vol. 14, no. 2, pp. 2725-2735, June 2020.
- [25] N. Chettibi, A. Mellit, G. Sulligoi and A. Massi Pavan, "Adaptive neural network-based control of a hybrid AC/DC microgrid," *IEEE Trans. on Smart Grid*, vol. 9, no. 3, pp. 1667-1679, May 2018.
- [26] A. Rosato, M. Panella, R. Araneo and A. Andreotti, "A neural network based prediction system of distributed generation for the management of microgrids," *IEEE Trans. on Ind. Appl.*, vol. 55, no. 6, pp. 7092-7102, Dec. 2019.

- [27] F. Rodríguez, A. M. Florez-Tapia, L. Fontán and A. Galarza, “Very short-term wind power density forecasting through artificial neural networks for microgrid control”, *Renew. Energy*, vol. 145, pp. 1517-1527, Jan. 2020.
- [28] J. Faraji, H. Hashemi-Dezaki and A. Ketabi, “Multi-year load growth-based optimal planning of grid-connected microgrid considering long-term load demand forecasting: a case study of Tehran, Iran,” *Sustainable Energy Technologies and Assessments*, vol. 42, pp. 1-19, Dec. 2020,
- [29] J. Reynolds, M. W. Ahmad, Y. Rezgui and J-L. Hippolyte, “Operational supply and demand optimisation of a multi-vector district energy system using artificial neural networks and a genetic algorithm,” *Applied Energy*, vol. 235, pp. 699-713, Feb. 2019.
- [30] M. M. Gupta and N. K Sinha, *Intelligent control systems: theory and applications*. New York, NY, USA: IEEE Press, 1996.
- [31] S. Haykin. *Neural Networks and Learning Machines*. 3 ed. Upper Saddle River, NJ, USA: Pearson Education, 2009.
- [32] I. Lima, C. A. M. Pinheiro e F. A. O. Santos. *Inteligência artificial*. Rio de Janeiro, RJ, BR: Elsevier, 2014.
- [33] A. P. Braga, T. B. Ludermir e A. C. P. L. F. Carvalho. *REDES NEURAIAS ARTIFICIAIS - Teoria e aplicações*. Rio de Janeiro, RJ, BR: LTC, 2000.
- [34] G. Cybenko, “Approximation by superpositions of a sigmoid function,” *Mathematics of Control, Signals and Systems*, 2:303-314, 1989.
- [35] M. H. Beale, M. T. Hagan, H. B. Demuth. *Neural Network Toolbox™ 7 – User’s Guide*. Natick, MA, USA: The Maths Works, Inc, 2010.
- [36] H. E. Farag, E. F. E. Saadany, R. E. Shatshat, and A. Zidan, “A generalized power flow analysis for distribution systems with high penetration of distributed generation,” *Electr. Power Syst. Res.*, vol. 81, pp. 1499-1506, Apr. 2011.
- [37] H. Yoriyaz, “Método de Monte Carlo: princípios e aplicações em Física Médica,” *Revista Brasileira De Física Médica*, vol.3, no.1, pp.141-149. 2009.
- [38] A. B. ALMEIDA, Um modelo unificado para análise de geração distribuída nos sistemas de transmissão e distribuição. Tese (Doutorado em Engenharia Elétrica), Universidade Federal de Itajubá, Itajubá, 2015.
- [39] P. Giorsetto, and K. F. Utsurogi, “Development of a new procedure for reliability modeling of wind turbine generators,” *IEEE Trans. Power App. Syst.*, vol. PAS-102, no. 1, pp. 134-143, Jan. 1983.
- [40] CRESESB, Centro de Referência para as Energias Solar e Eólica Sérgio S. Brito, [Online]. Disponível em: http://www.cresesb.cepel.br/index.php?section=atlas_eolico&. Acessado em: 09 de Maio, 2020.

- [41] B. N. NASCIMENTO, Uma proposta de metodologia de corte de carga em microrredes ilhadas. Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal de Itajubá, Itajubá, 2016.
- [42] L. F. R. Monteiro, J. R. Monteiro, L. H. C. Ferreira, A. C. Z. de Souza and B. I. L. Lopes, "Determination of Renewable Generation Operation with the Aid of the ANN," *2018 13th IEEE International Conference on Industry Applications (INDUSCON)*, São Paulo, Brazil, 2018, pp. 375-380.
- [43] IEEE PES AMPS DSAS Test Feeder Working Group, Test Feeder Cases, 34-bus Feeder, [Online]. Available: <https://site.ieee.org/pes-testfeeders/resources/>. Accessed on: June. 09, 2020.
- [44] ANEEL, PRODIST, Módulo 8 - Qualidade da Energia Elétrica, Agência Nacional de Energia Elétrica, [Online]. Disponível em: https://www.aneel.gov.br/documents/656827/14866914/M%C3%B3dulo_8-Revis%C3%A3o_10/2f7cb862-e9d7-3295-729a-b619ac6baab9. Acessado em: 09 de Maio, 2020.

848	Bus848	1	0	1.0000	1.0000	1.0000	0.0	-120.0	120.0	24.90
0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	848
860	Bus860	1	0	1.0000	1.0000	1.0000	0.0	-120.0	120.0	24.90
0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	860
836	Bus836	1	0	1.0000	1.0000	1.0000	0.0	-120.0	120.0	24.90
0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	836
840	Bus840	1	0	1.0000	1.0000	1.0000	0.0	-120.0	120.0	24.90
0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	840
862	Bus862	1	0	1.0000	1.0000	1.0000	0.0	-120.0	120.0	24.90
0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	862
838	Bus838	1	0	1.0000	1.0000	1.0000	0.0	-120.0	120.0	24.90
0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	838
864	Bus864	1	0	1.0000	1.0000	1.0000	0.0	-120.0	120.0	24.90
0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	864
888	Bus888	2	0	1.0000	1.0000	1.0000	0.0	-120.0	120.0	4.16
0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	888
890	Bus890	2	0	1.0000	1.0000	1.0000	0.0	-120.0	120.0	4.16
0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	890
856	Bus856	1	0	1.0000	1.0000	1.0000	0.0	-120.0	120.0	24.90
0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	856

-999

BRANCH DATA

%De) (Pa) P T (Length) (Config)

800	802	1	0	2580	300	
802	806	1	0	1730	300	
806	808	1	0	10776	300	%32230
808	810	1	0	5804	303	
808	812	1	0	12500	300	%37500
812	814	1	0	14865	300	%29730
814	850	1	0	10	301	
816	818	1	0	1710	302	
816	824	1	0	10210	301	
818	820	1	0	24075	302	%48150
820	822	1	0	13740	302	
824	826	1	0	3030	303	
824	828	1	0	840	301	
828	830	1	0	10222	301	%20440
830	854	1	0	520	301	
832	858	1	0	4900	301	
832	888	1	1	0	1	
834	860	1	0	2020	301	
834	842	1	0	280	301	
836	840	1	0	860	301	
836	862	1	0	280	301	
842	844	1	0	1350	301	
844	846	1	0	3640	301	
846	848	1	0	530	301	
850	816	1	0	310	301	
852	832	1	0	10	301	
854	856	1	0	11665	303	%23330
854	852	1	0	12277	301	%36830
858	864	1	0	1620	302	
858	834	1	0	5830	301	
860	836	1	0	2680	301	
862	838	1	0	4860	304	
888	890	1	0	10560	300	

-999

BRANCH CONFIGURATION DATA

% No) (Pha) (Raa) (Xaa) (Rab) (Xab) (Rac) (Xac) (Rbb) (Xbb)
 (Rbc) (Xbc) (Rcc) (Xcc) (Baa) (Bab) (Bac) (Bbb) (Bbc) (Bcc)

300	ABC	1.3368	1.3343	0.2101	0.5779	0.2130	0.5015	1.3238	1.3569
0.2066	0.4591	1.3294	1.3471	5.3350	-1.5313	-0.9943	5.0979	-0.6212	4.8880
301	ABC	1.9300	1.4115	0.2327	0.6442	0.2359	0.5691	1.9157	1.4281
0.2288	0.5238	1.9219	1.4209	5.1207	-1.4364	-0.9402	4.9055	-0.5951	4.7154
302	A	2.7995	1.4855	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
0.0000	0.0000	0.0000	0.0000	4.2251	0.0000	0.0000	0.0000	0.0000	0.0000
303	B	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	2.7995	1.4855
0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	4.2251	0.0000	0.0000
304	B	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	1.9217	1.4212
0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	4.3637	0.0000	0.0000

-999

TRANSFORMER CONFIGURATION DATA

% No)	(kVA)	(R%)	(X%)	(TapA)	(TapB)	(TapC)	(PhaA)	(PhaB)	(PhaC)	(Pha)
1	500	1.9	4.08	1.000	1.000	1.000	0.0	0.0	0.0	ABC

-999

SHUNT CAPACITORS

%No)	(A-kVAr)	(B-kVAr)	(C-kVAr)
844	100	100	100
848	150	150	150

-999

SPOT LOADS

%No)	(L)	(M)	(A-kW)	(A-kVAr)	(B-kW)	(B-kVAr)	(C-kW)	(C-kVAr)
860	Y	PQ	20	16	20	16	20	16
840	Y	I	9	7	9	7	9	7
844	Y	Z	135	105	135	105	135	105
848	D	PQ	20	16	20	16	20	16
890	D	I	150	75	150	75	150	75
830	D	Z	10	5	10	5	25	10

-999

DISTRIBUTED LOADS

%NoF)	(NoT)	(L)	(M)	(A-kW)	(A-kVAr)	(B-kW)	(B-kVAr)	(C-kW)	(C-kVAr)
802	806	Y	PQ	0	0	30	15	25	14
808	810	Y	I	0	0	16	8	0	0
818	820	Y	Z	34	17	0	0	0	0
820	822	Y	PQ	135	70	0	0	0	0
816	824	D	I	0	0	5	2	0	0
824	826	Y	I	0	0	40	20	0	0
824	828	Y	PQ	0	0	0	0	4	2
828	830	Y	PQ	7	3	0	0	0	0
854	856	Y	PQ	0	0	4	2	0	0
832	858	D	Z	7	3	2	1	6	3
858	864	Y	PQ	2	1	0	0	0	0
858	834	D	PQ	4	2	15	8	13	7
834	860	D	Z	16	8	20	10	110	55
860	836	D	PQ	30	15	10	6	42	22
836	840	D	I	18	9	22	11	0	0
862	838	Y	PQ	0	0	28	14	0	0
842	844	Y	PQ	9	5	0	0	0	0
844	846	Y	PQ	0	0	25	12	20	11
846	848	Y	PQ	0	0	23	11	0	0

-999

REGULATOR DATA

% No)	(NoF)	(NoT)	(Loc)	(CoB)	(P)	(Band)	(PTR)	(CTR)	(Ra)	(Xa)	(Rb)	(Xb)	(Rc)	(Xc)	(VoltA)	(VoltB)	(VoltC)	(tA)	(tB)	(tC)	(mP)	(s)
1	814	850	814	850	ABC	2.0	120	100	2.7	1.6	2.7	1.6	2.7	1.6	122	122	122	0	0	0	ABC	1
2	852	832	852	832	ABC	2.0	120	100	2.5	1.5	2.5	1.5	2.5	1.5	124	124	124	0	0	0	ABC	1

-999