

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Thales Schuabb de Almeida

**Estimação de Estados Multi-Área de Sistemas de Distribuição de Energia
Elétrica com Suporte de Redes Neurais Artificiais Considerando Variações
Topológicas e Erros Grosseiros**

Juiz de Fora

2023

Thales Schuabb de Almeida

Estimação de Estados Multi-Área de Sistemas de Distribuição de Energia Elétrica com Suporte de Redes Neurais Artificiais Considerando Variações Topológicas e Erros Grosseiros

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas de Energia

Orientador: Prof. D.Sc Leonardo Willer de Oliveira

Coorientador: Prof. D.Sc Edimar José de Oliveira

Juiz de Fora

2023

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF
com os dados fornecidos pelo(a) autor(a)

Schuabb de Almeida, Thales.

Estimação de Estados Multi-Área de Sistemas de Distribuição de Energia Elétrica com Suporte de Redes Neurais Artificiais Considerando Variações Topológicas e Erros Grosseiros / Thales Schuabb de Almeida. – 2023.

90 f. : il.

Orientador: Leonardo Willer de Oliveira

Coorientador: Edimar José de Oliveira

Dissertação (Mestrado) – Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2023.

1. Estimação de Estados. 2. Multi-Area. 3. Redes Neurais Artificiais. I. Willer de Oliveira, Leonardo, orient. II. José de Oliveira, Edimar, coorient. III. Título.

Thales Schuabb de Almeida

Estimação de Estados MultiÁrea de Sistemas de Distribuição de Energia Elétrica com Suporte de Redes Neurais Artificiais Considerando Variações Topológicas e Erros Grosseiros

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas de Energia Elétrica

Aprovada em 23 de maio de 2023.

BANCA EXAMINADORA

Prof. Dr. Leonardo Willer de Oliveira - Orientador

Universidade Federal de Juiz de Fora

Prof. Dr. Julio Cesar Stacchini de Souza - Coorientador

Universidade Federal Fluminense

Prof. Dr. Edimar José de Oliveira - Coorientador

Universidade Federal de Juiz de Fora

Prof. Dr. Helder Roberto de Oliveira Rocha

Universidade Federal do Espírito Santo

Prof. Dr. Igor Delgado de Melo

Universidade Federal de Juiz de Fora

Juiz de Fora, 03/05/2023.



Documento assinado eletronicamente por **Leonardo Willer de Oliveira, Professor(a)**, em 23/05/2023, às 11:59, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Igor Delgado de Melo, Professor(a)**, em 23/05/2023, às 12:32, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Helder Roberto de Oliveira Rocha, Usuário Externo**, em 23/05/2023, às 12:33, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Julio Cesar Stacchini de Souza, Usuário Externo**, em 23/05/2023, às 13:46, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Edimar Jose de Oliveira, Professor(a)**, em 23/05/2023, às 14:01, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **1263758** e o código CRC **DCD9E0DC**.

AGRADECIMENTOS

Agradeço aos meus pais, João Graciliano (*in memoriam*) e Jaqueline, por todo o amor incondicional, carinho e sacrifício que me trouxeram até aqui.

Agradeço aos meus irmãos, Caio e Hugo, pelo apoio, companheirismo e toda a orientação.

Agradeço aos meus avós, Antônio (*in memoriam*), Donária (*in memoriam*), Elberto e Thereza (*in memoriam*), por todo o carinho e exemplo de vida.

Agradeço ao meu orientador, Professor Leonardo Willer, por todo o conhecimento e experiência adquiridos nos anos de pesquisa.

Agradeço ao meu colega de pesquisa, Lucas Braga, sem o qual o desenvolvimento deste trabalho não seria o mesmo.

Agradeço à FAPEMIG e a CAPES pelo apoio financeiro à pesquisa.

RESUMO

O presente trabalho apresenta uma metodologia para Estimação de Estados (EE) de Sistemas de Distribuição de Energia Elétrica (SDEE) baseada no uso de Redes Neurais Artificiais (RNA), considerando a divisão do SDEE em áreas, e realizando sua estimação a partir de RNA separadas para cada área, caracterizando a estimação multi-áreas. As estimações são realizadas a partir de poucas medições de variáveis elétricas da rede, obtidas a partir de Unidades de Medição Fasoriais, do inglês *Phasor Measurement Units* (PMU) ou de Medidores Inteligentes (MI). As RNA são treinadas a partir de padrões de medições e os referentes estados reais da rede elétrica, se tornando capazes de estimar estados para novas medições futuras não observadas durante seu treinamento. A modelagem dos SDEE considera variações topológicas, que são identificadas a partir do monitoramento dos estados das chaves da rede, e também englobam as variáveis alimentadas às RNA para realizar a estimação. Além disso, a metodologia também contempla métodos de detecção e correção tanto de erros grosseiros nas medidas das variáveis elétricas, quanto na aquisição dos estados das chaves do SDEE, de modo a garantir maior robustez do estimador frente à ocorrência de erros grosseiros nas medições. Por fim, as estimações realizadas nos estimadores de cada área são enviadas a um agente central responsável pelo sincronismo das variáveis elétricas estimadas para formar o estado atual estimado do SDEE completo. Testes foram realizados considerando dois sistemas de teste frequentemente utilizados na literatura, além de um sistema real brasileiro simulado computacionalmente. As implementações foram realizadas no *software MATLAB*, e os resultados obtidos apontam a eficácia da metodologia para realizar a estimação das redes testadas considerando variações de carga, variações topológicas, e tratamento dos erros grosseiros detectados durante o monitoramento.

Palavras-chave: Estimação de Estados Multi-Área. Sistemas de Distribuição de Energia Elétrica. Redes Neurais Artificiais. Variações Topológicas. Erros Grosseiros.

ABSTRACT

This work presents a methodology for State Estimation (SE) of Electrical Distribution Systems (EDS) based on Artificial Neural Networks (ANN), considering the division of EDS into different areas, and performing the estimation using separate ANN for each area, characterizing Multi-Area State Estimation (MASE). The estimations are performed using few electrical measurements obtained from Phasor Measurement Units or Smart Meters. The ANN are trained considering the measurement patterns and their related true states of the electrical network, becoming able to estimate state for future measurements not observed during the training process. The EDS modeling considers topology changes, which are identified by monitoring the network switches status, and also encompass the input variables of the ANN. Furthermore, the methodology also includes methods for detection and correction of gross errors on the electrical measurements and monitored switch status, as to ensure the estimator robustness against gross errors on the measurements. Lastly, the estimations performed by each area's estimators are sent to a central agent responsible for synchronizing the estimated electrical variables and composing the estimated state of the EDS as a whole. Tests were performed considering two networks frequently used on the literature, and also on a real brazilian network computationally simulated. The implementations were performed using the MATLAB software, and the obtained results showcase the methodology effectiveness for state estimation considering load variations, topology changes, and gross errors detected during monitoring.

Keywords: Multi-Area State Estimation. Electrical Distribution Systems. Artificial Neural Networks. Topology Changes. Gross Errors.

LISTA DE ILUSTRAÇÕES

Figura 1 – Modelo de neurônio artificial - <i>perceptron</i>	24
Figura 2 – Função Degrau Linear	25
Figura 3 – Função Sigmoide	26
Figura 4 – Rede <i>MultiLayer Perceptron</i>	26
Figura 5 – Modelo π da linha	33
Figura 6 – Rede Neural Hopfield	40
Figura 7 – Distribuição Normal de Probabilidade	44
Figura 8 – Rede <i>MultiLayer Perceptron</i> para Estimaco de Estados Multi-Área em SDEE	49
Figura 9 – Rede <i>MultiLayer Perceptron</i> para Estimaco de Estados Centralizada em SDEE	52
Figura 10 – Exemplo de Curva de Carga em SDEE	53
Figura 11 – Exemplo de Perfil de Tenso em SDEE	54
Figura 12 – Fluxograma do Algoritmo Proposto	60
Figura 13 – Sistema IEEE 33 barras	62
Figura 14 – Áreas do Sistema IEEE 33 barras	63
Figura 15 – Variao de topologia do Sistema IEEE 33 barras	64
Figura 16 – Sistema IEEE 119 barras	64
Figura 17 – Áreas do Sistema IEEE 119 barras	65
Figura 18 – Áreas do Primeiro Alimentador do Sistema de 476 barras	65
Figura 19 – Áreas do Segundo Alimentador do Sistema de 476 barras	66
Figura 20 – Estimaco do Mdulo de Tenso do Sistema 33 barras com Comparaco entre Medidores.	72
Figura 21 – Estimaco do Ângulo de Tenso do Sistema 33 barras com Comparaco entre Medidores	72
Figura 22 – Estimaco do Mdulo de Tenso do Sistema 119 barras com Comparaco entre Medidores	73
Figura 23 – Estimaco do Ângulo de Tenso do Sistema 119 barras com Comparaco entre Medidores	73
Figura 24 – Estimaco do Mdulo de Tenso do Sistema 476 barras com Comparaco entre Medidores	74
Figura 25 – Estimaco do Ângulo de Tenso do Sistema 476 barras com Comparaco entre Medidores	74
Figura 26 – Estimaco do Sistema 33 barras com Erros Topolgicos	77
Figura 27 – Estimaco do Sistema 33 barras com Erro Grosseiro e Correo via RNB	80
Figura 28 – Estimaco de 48 horas da Barra 19 do Sistema 33 barras com Erros Grosseiros e Correo via RNB	80

Figura 29 – Estimação do Sistema 119 barras com Erro Grosseiro e Correção via RNB	81
Figura 30 – Estimação de 48 horas da Barra 65 do Sistema 119 barras com Erros Grosseiros e Correção via RNB	81
Figura 31 – Estimação do Sistema 476 barras com Erro Grosseiro e Correção via RNB	82
Figura 32 – Estimação de 48 horas da Barra 104 do Sistema 476 barras com Erros Grosseiros e Correção via RNB	83

LISTA DE TABELAS

Tabela 1 – Dados do Sistema 33 barras	62
Tabela 2 – Topologias do Sistema 33 barras	62
Tabela 3 – Topologias do Sistema 119 barras	63
Tabela 4 – Topologias do Sistema 476 barras	66
Tabela 5 – Alocação de PMUs para os sistemas de teste	67
Tabela 6 – Tempo computacional de estimação	68
Tabela 7 – Tempo de Treinamento das RNA	68
Tabela 8 – Análises para o sistema IEEE 33 barras	69
Tabela 9 – Análises para o sistema IEEE 119 barras	69
Tabela 10 – Análises para o sistema de 476 barras	69
Tabela 11 – Comparação de Estimação com Medidores Inteligentes	71
Tabela 12 – Resultados da Análise de Mínima Tensão	75
Tabela 13 – Taxa de Sucesso de Correção de Erros Topológicos	75
Tabela 14 – Comparação de Estimação com Erros Topológicos	77
Tabela 15 – Limites Z_l do algoritmo Z-Score para os sistemas de teste	79

LISTA DE ABREVIATURAS E SIGLAS

EE	Estimação de Estados
SDEE	Sistemas de Distribuição de Energia Elétrica
RNA	Redes Neurais Artificiais
PMU	<i>Phasor Measurement Unit</i>
MI	Medidores Inteligentes
SE	<i>State Estimation</i>
EDS	<i>Electrical Distribution Systems</i>
ANN	<i>Artificial Neural Networks</i>
MASE	<i>Multi-Area State Estimation</i>
MQP	Mínimos Quadrados Ponderados
WLS	<i>Weighted Least Squares</i>
EOPF	<i>Extented Optimal Power Flow</i>
MLP	<i>MultiLayer Perceptron</i>
μ PMU	<i>Micro Phasor Measurement Unit</i>
RNH	Redes Neurais Hopfield
RNB	Redes Neurais <i>Backup</i>
SIN	Sistema Interligado Nacional
SCADA	<i>Supervisory Control And Data Acquisition</i>
COD	Centro de Operação de Distribuição
EEE	Erro de Estimação de Estados
GPS	<i>Global Positioning System</i>
IEEE	<i>Institute of Electrical and Electronic Engineers</i>

SUMÁRIO

1	INTRODUÇÃO	12
1.1	CONSIDERAÇÕES INICIAIS	12
1.2	REVISÃO BIBLIOGRÁFICA	12
1.2.1	Estimação de Estados	12
1.2.2	Redes Neurais Artificiais na Estimação de Estados	16
1.3	MOTIVAÇÃO	18
1.4	OBJETIVOS	19
1.5	PUBLICAÇÕES DECORRENTES	19
1.5.1	Publicação em periódico	19
1.5.2	Publicação e apresentação em congresso	20
1.5.3	Publicação em congresso	20
1.6	ESTRUTURA DA DISSERTAÇÃO	20
2	FUNDAMENTAÇÃO TEÓRICA - ESTIMAÇÃO DE ESTADOS EM SISTEMAS DE DISTRIBUIÇÃO	21
2.1	INTRODUÇÃO	21
2.2	SISTEMAS DE DISTRIBUIÇÃO	21
2.2.1	Divisão em Áreas	22
2.3	REDES NEURAIS ARTIFICIAS	23
2.3.1	Redes <i>MultiLayer Perceptron</i>	25
2.3.2	Processo de Treinamento	27
2.4	ESTIMAÇÃO DE ESTADOS	28
2.4.1	Estimação via Métodos Iterativos	29
2.4.2	Estimação via Redes Neurais Artificiais	31
<i>2.4.2.1</i>	Geração de Cenários	31
2.4.2.1.1	Formulação do Fluxo de Potência	32
2.4.2.1.2	Resolução do Fluxo de Potência	35
2.4.3	Métrica de Estimação	37
2.5	MEDIÇÕES E ERROS ASSOCIADOS	38
2.5.1	Tipos de Medidores	38
2.5.2	Erros Grosseiros de Medição	39
2.5.3	Erros Topológicos	39
2.6	CONCLUSÕES PARCIAIS	41
3	METODOLOGIA	42
3.1	INTRODUÇÃO	42
3.2	GERAÇÃO DE CENÁRIOS DE CARGA	42
3.2.1	Variação de Carga	43
3.2.2	Divisão dos Conjuntos de Cenários	45

3.3	MEDIÇÕES	46
3.3.1	Alocação das Medições	47
3.3.2	Tratamento das Medições	47
3.4	REDES NEURAIIS ARTIFICIAIS	48
3.4.1	Sincronismo das Estimacões Locais	49
3.4.2	Rede Neural Centralizada	51
3.5	ERROS GROSSEIROS	52
3.5.1	Detecção de Erros Grosseiros	52
3.5.2	Correção de Erros Grosseiros	54
3.5.2.1	Redes Neurais Backup	55
3.6	ERROS TOPOLOGICOS	56
3.6.1	Rede Neural Hopfield	57
3.7	ALGORITMO PROPOSTO	58
3.8	CONCLUSÕES PARCIAIS	59
4	RESULTADOS	61
4.1	SISTEMAS DE TESTE	61
4.1.1	Sistema IEEE 33 Barras	61
4.1.2	Sistema IEEE 119 Barras	62
4.1.3	Sistema Real Brasileiro de 476 Barras	63
4.2	ANÁLISES PROPOSTAS	65
4.3	RESULTADOS	67
4.3.1	Análises Principais	67
4.3.1.1	Tempo Computacional	67
4.3.1.2	Resultados das Análises	69
4.3.2	Análise com Medidores Inteligentes	70
4.3.3	Análise de Mínima Tensão	72
4.3.4	Análise de Erros Topológicos	75
4.3.5	Análise de Erros Grosseiros	76
4.4	CONCLUSÕES PARCIAIS	82
5	CONCLUSÃO	84
5.1	CONSIDERAÇÕES FINAIS	84
5.2	PROPOSTAS DE TRABALHOS FUTUROS	86
	REFERÊNCIAS	87

1 INTRODUÇÃO

Este capítulo apresenta uma revisão bibliográfica sobre Estimação de Estados (EE) em Sistemas de Distribuição de Energia Elétrica (SDEE) bem como a utilização de Redes Neurais para solução do problema de Estimação de Estado. Em seguida, descreve-se a motivação para realização do trabalho e os objetivos alcançados. Por fim, este capítulo também apresenta as publicações decorrentes e a organização desta dissertação.

1.1 CONSIDERAÇÕES INICIAIS

Os Sistemas de Distribuição de Energia Elétrica constituem parte fundamental da infraestrutura das cidades modernas. O consumo de energia elétrica se apresenta fortemente relacionado ao desenvolvimento econômico dos países [1], [2]. Dessa forma, é imprescindível que esforços sejam feitos para que a manutenção, operação e modernização desses sistemas ocorram de maneira a proporcionar um fornecimento de energia elétrica com qualidade e segurança.

Um dos aspectos principais para garantir a operação segura dos SDEE é a observabilidade do sistema, ou seja, conhecimento sobre os valores das variáveis elétricas, como módulo e ângulo de fase de tensão, em todos os pontos de interesse do sistema. Porém, a indisponibilidade de equipamentos de medição elétrica em todos os pontos ou barras do sistema afeta esse requisito. Portanto, é necessário o uso de técnicas matemáticas para estimar grandezas elétricas em pontos sem medição. Nesse contexto, utiliza-se a Estimação de Estados, que visa estimar grandezas não medidas de um dado sistema a partir de medições, considerando suas incertezas e as características físicas da rede elétrica.

1.2 REVISÃO BIBLIOGRÁFICA

Na literatura, diversos trabalhos versam sobre o problema de estimação de estados aplicado a sistemas de distribuição. São encontrados trabalhos que utilizam desde modelos iterativos estocásticos até aplicações de inteligência artificial. Esta última vertente, por ser parte integrante deste trabalho, será objeto de revisão bibliográfica mais detalhada ao longo desta seção. Além disso, os avanços das técnicas de EE possibilitaram a sua aplicação em SDEE divididos em áreas, o que compõe outro aspecto da metodologia desenvolvida nesta dissertação.

1.2.1 Estimação de Estados

O estudo de Estimação de Estados tem origem em aplicações militares, destinadas a estimar trajetórias de mísseis e aeronaves baseadas em conjuntos de medições das variáveis pertinentes ao movimento do objeto, dotadas de seus respectivos erros de precisão [4]. Foi

somente a partir do trabalho de [5] que a EE passou a ser aplicada no campo da Engenharia Elétrica, mais precisamente em Sistemas de Transmissão. Este primeiro trabalho descreveu o uso do método dos Mínimos Quadrados Ponderados (*WLS - Weighted Least Squares*) para solução do problema de EE baseado nas medições disponíveis dos estados do sistema, aliado à pseudomedidas (valores de dados históricos com alta imprecisão) e nas características físicas da rede elétrica.

O uso da Estimação de Estados se tornou, desde então, vital para o monitoramento de sistemas elétricos. Novos trabalhos foram desenvolvidos acerca do tema, buscando aperfeiçoar alguns pontos fracos do WLS: baixa robustez contra erros grosseiros, alto tempo computacional de processamento. Sobre o primeiro ponto, em [6] foi proposta a linearização do problema, junto à filtragem de erros grosseiros para solução como um problema de minimização. Visando a redução do tempo computacional, foi proposta em [7] a utilização de uma matriz de ganho constante durante as iterações do WLS, evitando o cálculo exaustivo de matrizes complexas durante a execução do programa, e ainda mantendo uma precisão adequada nas estimações finais.

O método WLS se firmou, ao passar dos anos, como o mais utilizado para Estimação de Estados, e melhorias constantes sobre o método original são ainda estudadas. A aplicação do método para EE em Sistemas de Distribuição, porém, só foi explorada na literatura a partir de [8], que passou a considerar os modelos de curva de carga a partir de transformadores de distribuição. Algumas características dos SDEE, como radialidade dos sistemas, predominância de cargas trifásicas desequilibradas e baixa abertura angular entre barras, motivaram autores a explorar novos aprimoramentos para que o já clássico método WLS pudesse ser amplamente implementado em nível de distribuição.

Em [9], foi proposta a utilização de um método trifásico de EE visando melhorar a previsão de curvas de carga a partir de medições em tempo real, tanto de tensões e correntes, como das injeções de potência do sistema. Em [10], foi proposta a utilização de coordenadas retangulares para modelar o estado da rede, representado através das correntes trifásicas nos trechos do sistema, ao invés das tensões nodais. O método se mostrou eficaz para sistemas de distribuição e ainda é utilizado em aplicações de fluxo de potência e EE para a distribuição.

Os autores de [11] introduziram a discussão acerca da influência da alocação de medidores no SDEE na qualidade das estimativas, destacando como o posicionamento e a precisão dos medidores influencia os resultados do WLS. Em [12], a identificação de erros topológicos começa a ser tratada dentro da Estimação de Estados. Os autores consideram as chaves comutáveis do sistema como restrições do problema de EE, e utilizam os multiplicadores de Lagrange correspondentes como ferramenta para identificação de erros topológicos.

Tomando um viés de otimização, em [13] foi proposta a resolução da EE através de

um problema de otimização considerando as tensões como variáveis de estados, as injeções de potência nulas nas barras de passagem como restrições de igualdade e as potências nas barras não monitoradas como restrições de desigualdade, admitindo-se limites inferiores e superiores a partir de dados históricos de carga. Já [14] tomou não apenas as tensões, mas também as injeções de potência como variáveis a serem otimizadas durante o processo iterativo, culminando na criação de um Fluxo de Potência Ótimo Estendido (*EOPF - Extended Optimal Power Flow*).

Em [15], o problema de EE é tratado a partir de um conceito hierárquico, considerando sistemas de grande porte. A solução é obtida a partir de cálculos em dois níveis: um nível inferior constituído de diversos estimadores locais simultâneos, um para cada subsistema; já a coordenação dos estimadores locais é feita no nível superior, unindo as estimações locais para formar a estimação total do sistema. Este trabalho alavancou trabalhos subsequentes no estudo de estimação em áreas, culminando na formulação de uma nova técnica chamada Estimação de Estados Multi-Área, que, segundo [16], pode ser subdivida em duas vertentes: hierárquica e descentralizada.

Em [17], um método de decomposição do problema de EE em subproblemas a partir do particionamento do sistema em diversos ramos, cada um resolvido a partir da aplicação local do WLS, reduzindo a complexidade do problema e o tempo computacional de forma descentralizada. O autor de [18] descreve uma metodologia de estimação em área na qual o operador de cada área é responsável por realizar a estimação de seus estados usando as medições locais, e as informações pertinentes às barras de fronteiras são compartilhadas com um estimador coordenador central de modo a realizar a estimação do sistema como um todo. A divisão das áreas é feita baseada em critérios geográficos dos sistemas de teste, e as análises de observabilidade e detecção de erros grosseiros são feitos a nível local de cada estimador individual, após serem realizadas as estimações. O autor, porém, não descreve estratégia de correção dos erros grosseiros detectados.

A utilização de técnicas de Estimação de Estados Multi-Área se apresenta como uma interessante estratégia para tratar sistemas de grande porte, subdividindo-os em sistemas de menor complexidade, reduzindo o tempo computacional necessário para estimar o sistema com completo através do paralelismo do processamento de dados. Essa divisão contempla, também, a possibilidade de flexibilizar o uso de estimadores diferentes para cada área, uma vez que apenas os estados estimados precisam ser enviados ao nível de coordenação central, independe do modelo de estimador de origem. Além disso, a divisão em áreas garante maior robustez ao processo de estimação, pois falhas locais ou problemas de comunicação afetam apenas os estados da área faltosa, não comprometendo, assim, a estimação dos estados do restante do sistema.

Outro fator importante para o monitoramento de Sistemas de Distribuição é o conhecimento da topologia da rede elétrica. A presença de chaves normalmente abertas,

também conhecidas como recurso ou interconexão entre alimentadores, traz flexibilidade para sua operação. Seja por motivos de falta nas linhas ou correção do perfil de tensão durante sobrecargas, a topologia de um sistema pode variar durante sua operação normal. Embora o estado das chaves do sistema possa ser monitorado, os dados estão sujeitos a erros de monitoramento, de comunicação, ou até mesmo ataques cibernéticos [19]. Dessa forma, se faz necessária uma estratégia de identificação e correção dos possíveis erros topológicos de um SDEE. Em [20], é utilizado um modelo do grafo do sistema, aliado às medições fasoriais disponíveis para se computar o estado das chaves referente ao momento de operação. O método também pode ser adaptado para utilização com Medidores Inteligentes, fornecendo apenas medição dos módulos de tensão. Já em [21], uma Rede Neural *Autoencoder* é utilizada para recuperar os padrões de informação dos estados das chaves para ocorrências de falha de comunicação. A *Autoencoder* é responsável por estimar valores para dados faltantes a partir daqueles disponíveis, englobando tanto dados topológicos como de variáveis de estado. Assim, erros grosseiros podem ser mitigados durante a operação de um SDEE, ainda que os dados de medição afetados não possam ser obtidos.

Os equipamentos de medição utilizados em SDEE são propensos à ocorrência de erros grosseiros em suas variáveis mensuradas. A natureza desses erros pode variar desde problemas de calibração dos medidores até erros na comunicação dos dados [22]. A detecção desses erros é tratada na literatura principalmente a partir de análises residuais de medidas reais e de pseudo-medidas utilizadas no estimador WLS [23]. Em [24], é proposta a utilização do método *Chi-Quadrado* (χ^2) em todas as amostras de medição para detecção de erros grosseiros, dada a rápida execução do método. Sendo detectada a presença de erro grosseiro em uma amostra, é realizada a análise residual para identificar a medida afetada dentro da amostra, reduzindo a utilização do método residual apenas em amostras com erro já detectado. Já em [25], além da utilização de testes de hipótese baseados do método *Chi-Quadrado* para detecção dos erros grosseiros, os autores propõem a utilização de um normalizador de erros para corrigir o valor da medição afetada para dentro de um intervalo de confiança previamente estipulado. Dessa forma, a medição afetada não precisa ser descartada do processo de estimação, o que poderia causar problemas de observabilidade no método WLS, e é substituída por uma pseudo-medida com erro associado dentro de uma margem de erro aceitável.

Em [26], os autores utilizam o algoritmo *Z-Score* para realizar a detecção de erros grosseiros em amostras de medição. O algoritmo é calculado, a partir da média das observações em uma determinada janela, o desvio da amostra atual em relação às anteriores dentro da janela, em busca dos chamados *outliers*, ou pontos fora da curva. Dessa forma, ao obter valores de desvio em relação à média superior a um valor pré-determinado, o algoritmo indica a presença de um *outlier* de medição. A técnica, por considerar uma janela temporal para análise das amostras, é útil para utilização de monitoramento de

SDEE, com pequenos intervalos de tempo entre amostragens, embora os autores apliquem a técnica para análise de estabilidade de tensão.

1.2.2 Redes Neurais Artificiais na Estimação de Estados

O desenvolvimento de técnicas de inteligência artificial data desde 1958, quando [27] propôs o primeiro modelo de Rede Neural Artificial (RNA), o *Perceptron*. O modelo visa à atuação semelhante a de neurônios animais, contemplando os processos de reconhecimento de padrões e retenção de memória. Desde então, diversos trabalhos foram dedicados ao aprimoramento da técnica, culminando na criação das redes *Multi-Layer Perceptron (MLP)*, contendo três ou mais camadas de neurônios artificiais (*perceptrons*): camada de entrada; camadas ocultas, que realizam cálculos a partir de pesos sinápticos e das entradas; e, por fim, a camada de saída, que interpreta os resultados obtidos pela camada oculta, gerando as saídas da MLP. A capacidade de aprendizado e de identificação de padrões das redes MLP, aliada à boa velocidade de processamento, motivou as primeiras aplicações da técnica em estimação de estados de sistemas elétricos de potência.

Em [28], o uso de Redes Neurais Artificiais para estimação de estados em SDEE mostrou-se robusto e vantajoso em relação a métodos iterativos para aplicação do estimador em tempo real, devido ao requisito por velocidade de processamento. A alta velocidade para obtenção das estimativas não implicou queda significativa na qualidade das mesmas. Apesar do tempo de treinamento da RNA ser mais elevado, essa operação pode ser feita previamente à operação em tempo real do estimador, não impactando no tempo de resposta da aplicação pós-treinamento. Uma comparação direta com o método clássico WLS é feita por [29], demonstrando que a qualidade da estimativa via RNA é compatível com a do estimador clássico, sendo até 40% mais precisa. Outra aplicação de RNA é na geração de pseudo-medidas de cargas do sistema em tempo real para o estimador clássico WLS, como feito em [30], unindo ambas as técnicas em um estimador multi-agente.

As RNA são modelos computacionais que relacionam um conjunto amostral específico de entradas a um conjunto correspondente de saídas desejadas. A natureza e o tamanho desses conjuntos de dados, porém, podem variar dependendo da aplicação desejada. Dada a flexibilidade das RNA quanto aos padrões de entrada e saída, diversos trabalhos exploram diferentes combinações de medidas elétricas como entradas, em que os estados do sistema são considerados como saídas. Em [31], são considerados como entrada os fatores de carga em cada instante de tempo, e são estimadas, além dos fatores de tensão, as perdas de potência nos trechos da rede elétrica. O autor compara as estimativas obtidas com as respectivas variáveis calculadas por fluxo de potência, consideradas como valores exatos, a fim de aferir a precisão do método.

Em [32], são consideradas como medições e entradas da RNA as tensões nodais em módulo e fase, injeções de potência ativa e reativa nas barras, e correntes nos trechos

ligados às barras medidas. O autor também considera como entradas os estados, aberto ou fechado, das chaves manobráveis do sistema, que representam a topologia da rede elétrica. A consideração de diferentes topologias é essencial para aplicações em SDEE, pois os sistemas podem apresentar uma variedade de configurações possíveis, que podem variar por motivos de falhas em alimentadores ou por questões operativas, como correção de perfil de tensão e redução de perdas. Logo, aplicações de RNA devem ser capazes de lidar com topologias variáveis durante a operação do SDEE.

Em [33], as medidas obtidas são de fasor de tensão nodal, injeções nodais de potência real e imaginária e fluxos de potência nos trechos conectados às barras com medição. Simulações são feitas considerando inserção de Geração Distribuída, variação topológica e erros grosseiros para avaliar a robustez da solução. O autor considera, porém, um banco de RNA, sendo uma arquitetura para cada topologia entre as consideradas. A estratégia garante a qualidade da estimativa com variação topológica, mas ao custo de gerar inúmeras RNA diferentes para cada topologia, o que pode causar a inviabilidade prática do método para aplicações em sistemas de grande porte com muitas combinações topológicas praticáveis. Um filtro de estados também é proposto e aplicado ao fim do processo de estimação, a partir de um modelo de curva de tensão real do sistema, para reduzir variações bruscas de queda de tensão entre as barras, que podem causar erros elevados nos cálculos de fluxo de potência nos trechos a partir das estimativas obtidas.

Em [34], são consideradas duas RNA complementares para realização da Estimação de Estados. A primeira considera medições fasoriais do sistema como entrada e tem como saída os estados estimados das barras monitoradas, com objetivo de reduzir o impacto de eventuais ruídos nas medidas. Daí, as estimativas da primeira RNA alimentam a segunda rede, responsável por estimar os estados das barras não monitoradas do sistema.

Em [35], um novo modelo de RNA é proposto, baseando as conexões das camadas ocultas no grafo do sistema a ser estimado. Dessa forma, todas as conexões elétricas são mapeadas por neurônios artificiais. A metodologia considera o particionamento da rede em ramos menores, a partir das barras com medição, a fim de obter redes menores baseadas em grafos mais simples. A alocação de medidores é feita de modo a gerar sub-redes de tamanhos mais uniformes entre si quanto possível. Os medidores considerados são do tipo *Micro Phasor Measurement Unit* (μPMU), obtendo os fasores de tensão nodais e as correntes nos ramos associados às barras medidas. O método traz como limitação, porém, a operação limitada a uma topologia por RNA treinada, pois cada estimador é personalizado para as conexões elétricas encontradas na topologia atual do sistema, não garantindo, assim, flexibilidade para operar sob variação topológica. Além disso, o método apresenta tempo computacional muito grande para sistemas de maior porte. Em [36], os mesmos autores aperfeiçoaram a técnica, realizando a divisão dos sistemas, primeiro em múltiplas áreas, e depois aplicando a técnica de particionamento da sub-rede criada em cada área. A proposta foi capaz de reproduzir a precisão do trabalho anterior com redução

do tempo de treinamento das RNA e da comunicação entre os operadores de cada área, ao criar múltiplas RNA simplificadas para as áreas.

Redes Neurais Artificiais também são encontradas em aplicações de avaliação topológica de SDEE. Em [37], é proposto o uso de uma RNA para grafos a fim prever o estado de chaves manobráveis não monitoradas do sistema. Assim, o método apresenta uma ferramenta para identificação topológica que, baseada nas informações disponíveis do grafo da rede, ainda apresenta boa tolerância para falhas no sistema e erros de medição. Já em [38], o uso de RNA como classificador para grafos visa a uma análise de contingência $N - 1$ sobre sistemas de média tensão, a fim de determinar se na ocorrência da queda de qualquer trecho do sistema, há uma reconfiguração capaz de manter o fornecimento de energia para todos os consumidores.

1.3 MOTIVAÇÃO

A motivação deste trabalho surge da necessidade de se manter um monitoramento em tempo real dos estados de sistemas de distribuição de energia elétrica. Diversos métodos iterativos descritos na literatura [9], [14] são capazes de realizar a estimação de SDEE com boa precisão, mas apresentam tempo de resposta que podem inviabilizar a operação em tempo real do sistema. Nesse contexto, a utilização de redes neurais artificiais se apresenta como opção, devido à sua capacidade de gerar respostas quase instantâneas a partir do aprendizado dos padrões de comportamento dos SDEE, por meio de treinamento intensivo previamente realizado fora de operação.

A divisão de um SDEE em áreas, por motivos geográficos e econômicos, traz à tona a necessidade de se formular um modelo de estimador descentralizado, capaz de operar em cada área separadamente [16]. A flexibilidade de operação dos SDEE a partir da variação de suas topologias deve ser considerada no desenvolvimento de um estimador, de modo que este seja capaz de fornecer estimações para operação em qualquer uma das topologias praticadas no sistema, sem necessidade de desenvolvimento de um estimador para cada topologia. Ademais, levando em consideração que erros grosseiros podem ocorrer no processo de aquisição de dados de um SDEE, seja nos medidores empregados ou no processo de comunicação de dados, é importante a utilização de estratégias de detecção e correção de tais erros que, se não corrigidos, podem propagar grandes imprecisões nas estimativas.

O monitoramento em tempo real de sistemas de distribuição, por se tratar de um processo complexo, haja vista as características descritas anteriormente, requer o desenvolvimento de ferramentas de estimação de estados robustas às diversas particularidades de operação possíveis. Desse modo, o desenvolvimento de um estimador que contemple soluções para todos os pontos de interesse elencados é de suma importância para o aprimoramento das técnicas de monitoramento em tempo real de SDEE.

1.4 OBJETIVOS

O objetivo geral deste trabalho é desenvolver um modelo de estimação de estados, a partir de redes neurais artificiais, para sistemas de distribuição de energia elétrica. O estimador proposto tem como característica principal a alta velocidade de resposta a amostras de medição, de modo a viabilizar sua utilização no monitoramento em tempo real de SDEE. Além disso, podem ser destacados os seguintes aspectos contidos no estimador da metodologia proposta:

- Divisão do SDEE em áreas, considerando a estimação de cada área realizada separadamente, e posterior sincronização dos estados estimados junto a um operador central.
- Capacidade de operação em sistemas com várias topologias possíveis, com treinamento simultâneo das RNA para todas as topologias, sem necessidade de criação de um banco de RNA para tratar separadamente cada topologia do sistema. A identificação das topologias é feita a partir dos estados binários, aberto ou fechado, das chaves do sistema.
- Integração de Redes Neurais Hopfield (RNH) para correção de eventuais erros na informação dos estados das chaves. As RNH são utilizadas para cada amostragem do estimador e atuam apenas em estados não conhecidos durante o seu treinamento. Ou seja, deixa inalterados os estados das chaves que representem topologias viáveis e já observadas durante treinamento da Rede Neural Hopfield.
- Método de detecção de erros grosseiros de medição, a partir do algoritmo *Z-Score*, aliado a uma nova proposta de geração de pseudo-medidas para substituição das amostras defeituosas. É proposta a utilização de Redes Neurais *Backup* (RNB) para estimação da área afetada por erro grosseiro em suas medições. As RNB utilizam os estados estimados da barra de fronteira de áreas vizinhas como pseudo-medida para a área afetada pelo erro grosseiro.

1.5 PUBLICAÇÕES DECORRENTES

A presente dissertação resultou em publicações em periódicos e congressos, além de apresentação em congresso, conforme:

1.5.1 Publicação em periódico

- DE ALMEIDA, Thales Schuabb; BRAGA, Lucas Eduardo; DE OLIVEIRA, Leonardo Willer; DE OLIVEIRA, Edimar José; DE SOUZA, Julio Cesar Stacchini. A Hybrid Meta-Heuristic approach for optimal meter allocation in Electric Power Distribution

Systems. Learning and Nonlinear Models - Journal of the Brazilian Society on Computational Intelligence (SBIC), Vol. 21, Iss. 1, pp. 36-46, 2023

1.5.2 Publicação e apresentação em congresso

- DE ALMEIDA, Thales Schuabb; BRAGA, Lucas Eduardo; FRACETTI, Pedro Caruso; DE OLIVEIRA, Leonardo Willer; DE OLIVEIRA, Edimar José; CARVALHO, Jerson dos Santos. Aplicação de Sistema Imunológico Artificial para Alocação Ótima de Medidores com Suporte de Rede Neural Artificial. XV Congresso Brasileiro de Inteligência Computacional, 2021.

1.5.3 Publicação em congresso

- BRAGA, Lucas Eduardo; DE ALMEIDA, Thales Schuabb; FRACETTI, Pedro Caruso; DE OLIVEIRA, Leonardo Willer; DE OLIVEIRA, Edimar José. Aplicação de Redes Neurais Artificiais com Tratamento de Erros via Z-Score em Sistemas de Distribuição de Energia Elétrica. Simpósio Brasileiro de Automação Inteligente, 2021.

1.6 ESTRUTURA DA DISSERTAÇÃO

Além deste capítulo, esta dissertação está dividida em outros quatro capítulos. O capítulo 2 apresenta a fundamentação teórica acerca do tema tratado, a estimação de estados em sistemas de distribuição, e suas particularidades. O capítulo 3 traz a descrição da metodologia proposta para o estimador, assim como a descrição de como é realizada a geração da base de dados de treinamento das redes neurais.

O capítulo 4 apresenta a descrição dos sistemas de teste utilizados, os resultados obtidos com a metodologia proposta e as análises realizadas. Finalmente, o capítulo 5 apresenta as conclusões finais do trabalho, assim como as propostas de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA - ESTIMAÇÃO DE ESTADOS EM SISTEMAS DE DISTRIBUIÇÃO

2.1 INTRODUÇÃO

Este capítulo apresenta uma fundamentação teórica acerca do objeto da presente dissertação, contemplando sistemas de distribuição de energia elétrica e o problema de estimação de estados desses sistemas. Aspectos dos SDEE relevantes para a estimação de estados são abordados. Além disso, os principais métodos de EE são apresentados junto a suas vantagens e desvantagens, culminando na escolha do uso de redes neurais artificiais como ferramenta para a resolução desse problema.

2.2 SISTEMAS DE DISTRIBUIÇÃO

O desenvolvimento das sociedades atuais está diretamente atrelado ao consumo de energia, em especial, elétrica [1]. A disponibilidade do fornecimento de energia elétrica configura, então, um fator crucial para o desenvolvimento econômico de um país. Os sistemas de distribuição se apresentam como a estrutura responsável por manter esse fornecimento de forma contínua e segura. Formam os sistemas de distribuição as redes de média e baixa tensão, não pertencentes à rede de operação do Sistema Interligado Nacional (SIN) [40].

Para que o fornecimento de energia elétrica seja realizado com as devidas considerações de continuidade e segurança, faz-se necessário que os operadores dos sistemas de distribuição tenham a mais completa observabilidade possível desses sistemas. Ou seja, em um dado momento de operação, é importante que se saibam as características das variáveis elétricas do sistema em todos os seus pontos de interesse, as chamadas barras do sistema. Para realizar a medição dessas variáveis, são utilizados equipamentos de medição como Unidades de Medição Fasorial, Medidores Inteligentes e equipamentos Sistema de Supervisão e Aquisição de Dados, ou *SCADA* (*Supervisory Control And Data Acquisition*) em inglês. Entretanto, o preço elevado desses equipamentos, aliado ao grande número de pontos de interesse de medição, inviabiliza o seu uso em todas as barras do sistema. É necessário, então, o uso de técnicas para estimar o valor das variáveis de interesse, os estados da rede, nos demais pontos onde não há possibilidade de se contemplar a alocação de equipamentos de medição. Para isso, é utilizada a estimação de estados, estratégia central de estudo deste trabalho, detalhada mais adiante neste capítulo.

A modernização dos Sistemas de Distribuição, constituindo as chamadas Redes Elétricas Inteligentes (*Smart Grids*) [3], agrega ainda mais complexidade para o monitoramento desses sistemas. Esse monitoramento é realizado a partir de um Centro de Operação de Distribuição (COD). Conforme expresso na Seção 4.5 do Módulo 4 das Regras e Procedimentos de Distribuição (Prodist) [40], são atribuições de um Centro de Operação

de Distribuição:

O Centro de Operação da distribuição – COD tem as seguintes atribuições: coordenar, supervisionar, comandar e executar as ações operativas nas instalações de distribuição que não pertençam à rede de operação do SIN; obter junto aos usuários as informações necessárias à coordenação, supervisão e controle da operação de instalações; elaborar, atualizar e disponibilizar aos usuários as instruções de operação com procedimentos para instalações que interferem no sistema de distribuição; e informar aos usuários sobre condições operativas no sistema de distribuição que possam interferir na operação de suas instalações.

Dessa forma, a responsabilidade do COD, a partir das redes de média e baixa tensão não pertencentes ao SIN, recai sobre as atribuições decorrentes do monitoramento dessas redes. As atribuições de coordenação, supervisão, comando e execução de ações operativas derivam diretamente da observação de fenômenos elétricos na rede a partir do monitoramento existente. Para obtenção das informações necessárias junto aos usuários e realização das medições elétricas pertinentes, é necessária uma infraestrutura de comunicação robusta. Além das supracitadas continuidade e segurança, existem outros fatores que compõe pré-requisitos para o devido funcionamento de uma *Smart Grid* [41]:

- Confiabilidade: probabilidade de um Sistema de Distribuição responder de maneira adequada dentro de um determinado período.
- Qualidade: manutenção das ondas de tensão e corrente dentro de limites estipulados de amplitude, frequência e componentes harmônicas.
- Comunicação: interligação das informações entre os equipamentos e os Centros de Operação da Distribuição.

A constante evolução dos SDEE rumo à implantação em massa de *Smart Grids* aumenta a necessidade de se manter o monitoramento em tempo real desses sistemas. A fim de manter os padrões de qualidade e segurança necessários para a operação dos sistemas, é de suma importância o desenvolvimento de técnicas de estimação de estados com baixo tempo de resposta e que sirvam aos CODs de forma confiável.

2.2.1 Divisão em Áreas

Em sistemas de distribuição modernos, é comum a divisão em diferentes áreas. Por vezes, mais de um COD são responsáveis por um mesmo sistema de média tensão. Essa divisão é comumente acarretada por fatores geográficos, que separam partes de um mesmo SDEE em municípios diferentes, que podem ainda ter diferentes concessionárias de energia elétrica. Nestes casos, é comum que as diferentes concessionárias não realizem o

compartilhamento completo de dados de medição e estimativas de suas áreas no sistema, por motivos de privacidade e segurança. É necessário, então, um esforço conjunto para que a estimação de estados desses sistemas seja feita separadamente em cada área por seu COD, e para que apenas informações cruciais sejam compartilhadas entre os agentes.

A interligação das áreas de um SDEE pode se dar das seguintes maneiras:

- Barra de Fronteira: um barramento pertencente a duas áreas simultaneamente. Para essa interligação, é necessário um mecanismo de sincronismo para as estimativas feitas por diferentes agentes para a barra compartilhada [42].
- Barra Virtual de Fronteira: é criado um barramento virtual para representar a interligação entre as áreas, feita através de um trecho de alimentador, requerendo, também, sincronismo para o barramento virtual [43].
- Trecho de Interconexão: um ou mais trechos do sistema são responsáveis pela conexão entre as áreas. Neste caso, são sincronizadas as informações de fluxos de potência e corrente nos referidos trechos [44].


A presente dissertação considera a interligação entre as diferentes áreas de um SDEE como sendo do tipo barra de fronteira. Dessa forma, o sincronismo é feito para as variáveis módulo e ângulo de fase de tensão das barras de fronteira. Estimadores que utilizam técnicas iterativas muitas vezes realizam o processo de sincronismo a nível de iteração, ou seja, a cada iteração dos estimadores por área, é realizado o procedimento de sincronismo. Essa abordagem, porém, pode ser muito custosa computacionalmente, pois requer que os dados dos estados da barra de fronteira sejam transmitidos entre os CODs para sincronismo a cada iteração do método de estimação de estados. Esse trabalho, por considerar estimadores a partir de redes neurais artificiais, cujo processo de estimação não é iterativo, realiza um único sincronismo após cada estimação por área.

2.3 REDES NEURAIS ARTIFICIAS

As redes neurais artificiais são sistemas computacionais que objetivam modelar matematicamente os meios que o cérebro humano processa informações e resolve problemas [45]. O componente estrutural básico do cérebro, responsável pelo processamento de informações, é o neurônio, célula que realiza as atividades de reconhecimento dos padrões sensoriais. Essas células têm uma característica de plasticidade que as permite se adaptar ao meio ambiente e aos estímulos que dele recebem. Com isso, o cérebro, a partir da cooperação entre seus inúmeros neurônios, é capaz de aprender padrões sensoriais com os quais entra em contato, e reconhecê-los posteriormente ao entrar em contato com estímulos iguais ou semelhantes.

A capacidade de reconhecer padrões presente no cérebro humano é o grande motivador do desenvolvimento das RNA. O primeiro passo em direção a esse desenvolvimento foi a criação do neurônio artificial, chamado *perceptron* por [27]. A representação de um exemplo de *perceptron* pode ser vista na Figura 1. Neste modelo, as entradas x_1 e x_2 são ponderadas pelos seus respectivos pesos sinápticos w_1 e w_2 , antes de serem somadas para formar a saída do combinador linear u , que é a entrada da função de ativação φ , conforme a Equação 2.1, em que n representa o número de entradas do neurônio artificial. Essa função de ativação relaciona o resultado do combinador linear u , acrescido de um valor arbitrário de *bias* b , com a saída desejada y do *perceptron*, como descrito pela Equação 2.2.

Figura 1 – Modelo de neurônio artificial - *perceptron*



Fonte: Elaborado pelo autor (2022)

$$u = \sum_{i=1}^n w_i x_i \quad (2.1)$$

$$y = \varphi(u + b) \quad (2.2)$$

A capacidade de adaptabilidade do *perceptron* se dá pelo ajuste dos valores dos pesos sinápticos w_i , de modo a relacionar a combinação linear das entradas com a função de ativação e obter as saídas desejadas. Essa adaptabilidade é obtida através do chamado processo de treinamento do neurônio artificial e, de forma geral, da RNA formada por uma combinação de *perceptrons*.

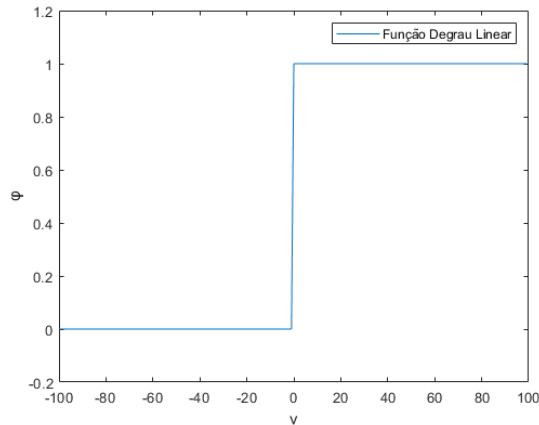
A função de ativação utilizada em um neurônio artificial com resposta binária, sendo $v = u + b$, pode ser uma das seguintes opções:

1. Função Degrau Linear

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (2.3)$$

A representação do comportamento de uma função do tipo Degrau Linear pode ser vista na Figura 2, qual a resposta da função de ativação varia instantaneamente de 0 para 1 no limiar da variável de entrada $v = 0$.

Figura 2 – Função Degrau Linear



Fonte: Elaborado pelo autor (2022)

2. Função Sigmoide


$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (2.4)$$

Onde e é a constante de Euler $e = 2,7182$; e a é um parâmetro de inclinação da função sigmoide, que pode ser ajustado para a aplicação desejada. Uma função sigmoide com inclinação $a = 0.2$ pode ser vista na Figura 3, que apresenta uma transição mais suave de resposta em torno do limiar da variável de entrada $v = 0$ quando comparada com a função degrau Linear. Devido a esse comportamento suavizado de transição da resposta, a função sigmoide é utilizada com maior frequência do que a do tipo degrau Linear para aplicações em RNA, ao passo que valores de entrada próximos ao limiar podem ter interpretações da saída mais precisas do que a resposta binária linear. A função Sigmoide foi empregada nas Redes Neurais Artificiais utilizadas neste trabalho.

2.3.1 Redes *MultiLayer Perceptron*

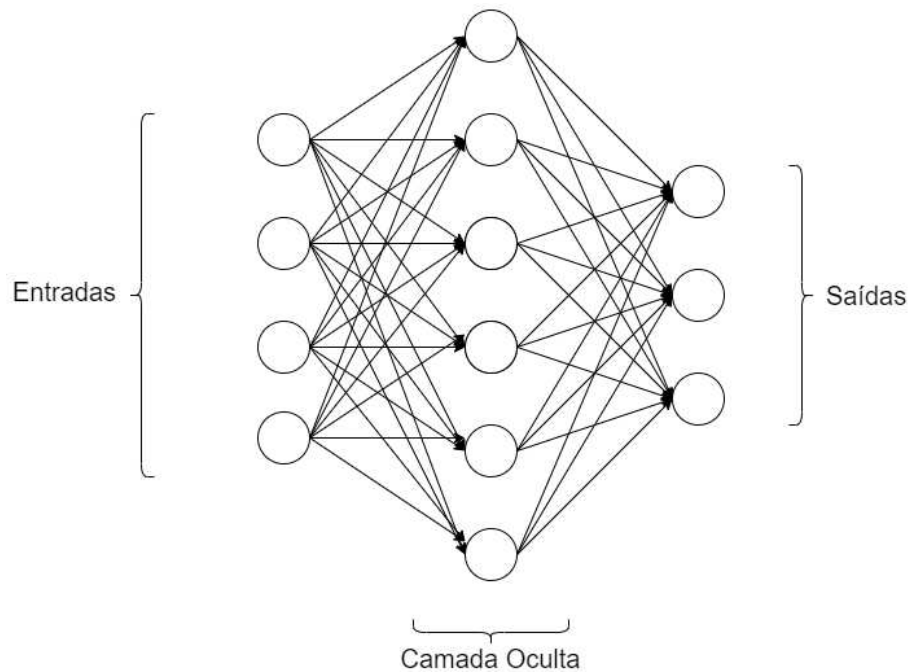
Perceptrons, operando isoladamente, têm a capacidade de solucionar problemas simples, como por exemplo, tomada de decisão binária a partir de um vetor de n entradas. A associação de diversos *perceptrons*, por sua vez, confere a capacidade de resolução de problemas mais complexos. É nesse contexto que se desenvolveram as redes *MultiLayer Perceptron (MLP)* [45]. A Figura 4 demonstra um exemplo de Rede *MultiLayer Perceptron*, na qual cada unidade *perceptron* é representada por um círculo, sendo os diversos neurônios

Figura 3 – Função Sigmoide



Fonte: Elaborado pelo autor (2022)

artificiais conectados em camadas. A primeira camada representa as entradas da rede; a camada intermediária é chamada camada oculta; e a última é a camada de saída. Importante citar que redes *MLP* podem ter diversas camadas ocultas, conforme necessário pela complexidade do problema a ser resolvido. Em aplicações de estimação de estados, porém, é comum o uso de apenas uma camada oculta, cujo número de neurônios artificiais é parâmetro a ser ajustado para cada aplicação.

Figura 4 – Rede *MultiLayer Perceptron*

Fonte: Elaborado pelo autor (2022)

2.3.2 Processo de Treinamento

A habilidade das RNA de reconhecer os padrões de entrada dos dados de um dado problema tem origem no seu processo de treinamento. É a partir dele que são ajustados os pesos sinápticos dos neurônios artificiais, em um processo iterativo, de modo a minimizar o erro das respostas obtidas. Esse processo é realizado a partir de um algoritmo de aprendizagem. Diversos tipos de algoritmos já foram desenvolvidos na literatura, e diferem entre si, principalmente, pela forma com a qual o erro das saídas das amostras de treinamento ajusta os pesos sinápticos.

Os processos de aprendizagem podem ser divididos em dois grupos: supervisionados e não-supervisionados. O aprendizado supervisionado é realizado em problemas cuja base de dados é formada por amostras de entrada com padrões de saída associados. O treinamento é realizado ajustando-se os pesos sinápticos de modo a minimizar os erros entre os valores das saídas obtidas e os respectivos padrões de resposta disponíveis. Já o treinamento não-supervisionado é destinado a problemas cuja base amostral não apresenta dados previamente rotulados e que precisam, portanto, ser interpretados livremente pela própria RNA. Esse tipo de aplicação é importante para explorar dados desconhecidos e encontrar padrões de agrupamento entre os mesmos, que não sejam facilmente determinados por observação e análise humana.

Dentre os algoritmos de aprendizagem supervisionada, se destaca o algoritmo de retropropagação (*backpropagation*, em inglês) [46]. Seu objetivo é ajustar os parâmetros de pesos sinápticos dos neurônios artificiais, a fim de minimizar o erro médio das amostras analisadas durante o treinamento. Esse ajuste é feito a partir de dois passos principais:

- Passo para frente: com os pesos sinápticos inalterados, são determinadas as saídas para o padrão de entrada da amostra atual, e é calculado o sinal de erro em relação ao padrão de saída da amostra.
- Passo de retropropagação: o sinal de erro da saída é alimentado de forma retropropagada nos neurônios artificiais, sendo multiplicado junto às derivadas de suas funções de ativação (saídas dos neurônios).

A variação dos pesos sinápticos durante cada iteração do algoritmo de aprendizagem é afetada pela Taxa de Aprendizagem η . Quanto maior for esse parâmetro, maiores serão as modificações em cada iteração, acelerando a aprendizagem, ao custo de causar eventuais instabilidades no processo iterativo. Reduzindo esse valor, é possível suavizar as variações e obter um processo de aprendizagem mais estável, ainda que mais lento.

Por se tratar de um processo iterativo, a aprendizagem das RNA necessita de algum critério de parada que determine sua convergência. Três principais critérios são utilizados para determinar o fim do processo de aprendizagem:

- **Mínimo Gradiente:** A partir da avaliação, a nível de iteração, dos vetores gradientes que relacionam as derivadas entre os neurônios de uma camada com as camadas adjacentes, é capaz de encontrar um ponto de mínimo local ou, eventualmente, global no espaço de soluções. Mínimos locais são determinados pela obtenção do vetor gradiente nulo em um ponto do espaço de soluções. Logo, tomando um limite suficientemente pequeno, pode-se aproximar o ponto de um mínimo local a partir da avaliação do vetor gradiente.
- **Mínimo Erro:** A partir do próprio erro entre saída obtida e padrão de resposta da amostra, é possível determinar um critério de parada, tomando também um limite suficientemente pequeno para esse erro, que esteja dentro de uma faixa de erro aceitável para o problema proposto.
- **Validação Cruzada:** Utilizando uma parcela do conjunto de dados, separada para essa função, é possível avaliar o desempenho da rede durante seu treinamento com um conjunto de dados ainda não visto por ela. Após um determinado número de épocas de treinamento, este é paralisado, os pesos sinápticos são mantidos fixos, e é realizada uma avaliação dos erros para o conjunto de validação. Se para um determinado número de validações sequenciais realizadas, o erro de validação não for reduzido, o processo de treinamento é encerrado de forma antecipada, sem que seja atendido nenhum dos dois critérios anteriores. Essa parada antecipada é essencial para que a RNA não perca uma característica importante de seu funcionamento: capacidade de generalização

A capacidade de generalização mencionada pode ser descrita como a eficácia de uma RNA em produzir saídas acuradas para padrões de entrada inéditos. Tomando a RNA como um processo de mapeamento não linear, uma boa generalização é análoga a uma boa interpolação feita em uma curva da qual apenas alguns pontos são conhecidos, e se deseja obter a função que os representa [46]. Logo, a parada antecipada do treinamento, proporcionada pelo critério de validação cruzada, ajuda a garantir que a interpolação feita no espaço de soluções não seja específica aos dados utilizados em seu treinamento, e que possa gerar boas respostas quando alimentadas com dados ainda não apresentados.

O emprego das RNA deste trabalho considera o uso de Redes *Multi-Layer Perceptron*, com algoritmo de treinamento de retropropagação, e função de ativação Sigmoide. O critério de parada dos treinamentos foi o de validações cruzadas.

2.4 ESTIMAÇÃO DE ESTADOS

A operação de sistemas elétricos, em geral, requer a observabilidade de suas variáveis. Os sistemas de distribuição, em especial, por terem baixa disponibilidade de equipamentos

de medição, demandam um processo de estimação de estados com características específicas, que atenda suas particularidades e requisitos de qualidade de operação.

O desenvolvimento de técnicas de estimação de estados, desde o primeiro trabalho de [5], teve foco em sistemas de transmissão, que são dotados de uma redundância considerável de medições elétricas, ou seja, dispõem de maior número de variáveis medidas do que de estados a serem estimados. Essas medições, porém, são afetadas por erros de diversas naturezas, como imprecisão e saturação de transformadores de corrente e potencial, interferência eletromagnética e falhas de comunicação. O processo de EE é empregado, então, para gerar a melhor estimativa possível dos estados do sistema, nas condições de operação das medições obtidas, considerando a incerteza esperada de cada medição. Com isso, erros grosseiros nas medições, assim como dados faltantes, podem ser filtrados e compensados durante o processo de estimação [47].

Em Sistemas de Distribuição, porém, não existe a mesma redundância de medições encontrada na transmissão. O custo dos equipamentos de medição torna inviável a sua instalação em todos os pontos de interesse de SDEE, pois esses sistemas, além de serem extensos, têm menor potência e importância econômica associada, se comparados à rede básica [48]. O processo clássico de EE precisou, então, ser adaptado, principalmente no que tange à garantia de observabilidade do sistema, ou seja, número de medições maior ou igual ao número de variáveis a serem estimadas. Isso se deu pelo uso de pseudo-medidas de carga [8]. Considerando dados históricos das injeções de potência do sistema, são geradas medidas fictícias dos dados de carga, com alta incerteza associada. A alta incerteza gera menor influência das pseudo-medidas no processo de estimação, que será melhor detalhado na subseção seguinte, mas garante a observabilidade do sistema, viabilizando a aplicação dos métodos clássicos de estimação desenvolvidos anteriormente para sistemas de transmissão.

2.4.1 Estimação via Métodos Iterativos

O problema de Estimação de Estados, aplicado a SDEE pode ser formulado a partir dos estados do sistema [49]. Tomando um sistema com nb barras, são determinadas $2nb - 1$ variáveis de estado: tensão em módulo e ângulo de fase para todas as barras, exceto o ângulo de fase da barra da Subestação (SE), que é fixo em zero. Essa estratégia é possível pois, o a variável de interesse do ângulo de fase compreende apenas a abertura angular entre barras, e com isso é possível fixar um referencial arbitrário com o ângulo em zero na SE para simplificar a análise dos demais aberturas angulares em relação à SE. O vetor de variáveis de estado \mathbf{x} é definido como:

$$\mathbf{x} = [\theta_2, \theta_3, \dots, \theta_{nb}, V_1, V_2, \dots, V_{nb}] \quad (2.5)$$

A associação das medições disponíveis com o vetor de estados do sistema é dado por:

$$\mathbf{z} = h(\mathbf{x}) + \mathbf{e} \quad (2.6)$$

Onde:

- θ_k é o ângulo de fase de tensão da barra k ;
- V_k é o módulo de tensão da barra k ;
- \mathbf{z} é o vetor de medições;
- \mathbf{x} é o vetor de variáveis de estado;
- $h(\mathbf{x})$ é o vetor das funções não lineares que relacionam os estados com as medições;
- \mathbf{e} é o vetor de erros associados às medições.

Os erros associados às medições são consideradas como variáveis aleatórias com distribuição normal de probabilidade, valor esperado nulo e variância determinada a partir da precisão do medidor. A matriz de covariância R do vetor de erros associados às medições é dado a partir do valor esperado $E[\mathbf{e}\mathbf{e}^T]$ das medições:

$$R = E[\mathbf{e}\mathbf{e}^T] \quad (2.7)$$

A matriz de covariância R compreende uma matriz diagonal, cujos valores da diagonal são as variâncias de cada medição, dadas pelo quadrado do desvio padrão de cada medida:

$$var_m = \sigma_m^2 \quad (2.8)$$

A solução do problema de EE definido acima é, geralmente, dada pelo uso do algoritmo Mínimos Quadrados Ponderados (MQP), o chamado método clássico *WLS* na terminologia em inglês. O *WLS* compreende um processo iterativo de minimização da função de custo $J(\mathbf{x})$ definido como:

$$\min J(\mathbf{x}) = [\mathbf{z} - h(\mathbf{x})]^T [R]^{-1} [\mathbf{z} - h(\mathbf{x})] \quad (2.9)$$

A minimização da função de custo $J(\mathbf{x})$ é obtida quando se satisfaz a nulidade da equação diferencial:

$$g(\mathbf{x}) = \frac{\partial J(\mathbf{x})}{\partial \mathbf{x}} = H^T(\mathbf{x})R^{-1}[\mathbf{z} - h(\mathbf{x})] = 0 \quad (2.10)$$

Onde $H(\mathbf{x})$ é a matriz Jacobiana definida pelas derivadas parciais $[\frac{\partial h(\mathbf{x})}{\partial \mathbf{x}}]$ do vetor de funções das medições em relação ao vetor de estados. Tratando a função $g(\mathbf{x})$ em sua forma matricial, o processo iterativo do Método de Newton é realizado da forma:

$$\mathbf{x}^{j+1} = \mathbf{x}^j - [G(\mathbf{x}^j)]^{-1}g(\mathbf{x}^j) \quad (2.11)$$

Onde:

- j é o contador de iterações;
- \mathbf{x}^j é o vetor de estados para a iteração j ;
- $G(\mathbf{x})$ é chamada matriz de ganho: $G(\mathbf{x}^j) = \frac{\partial g(\mathbf{x}^j)}{\partial \mathbf{x}} = H^T(\mathbf{x}^j)R^{-1}H(\mathbf{x}^j)$.

A resolução iterativa do Método de Newton é feita observando-se o incremento do vetor de estado $\Delta x^j = x^{j+1} - x^j$, e comparando-o, ao fim de cada iteração, com uma tolerância predefinida ϵ . O processo iterativo é dito convergente quando $|\Delta x^j| \leq \epsilon$.

O método WLS é o mais comumente utilizado para estimação de estados, tanto em sistemas de transmissão como de distribuição. Sua popularidade como método clássico justifica a sua descrição, implementação e comparação. Em vista disso, a implementação do método será realizada na presente dissertação para fins de comparação com os resultados obtidos por RNA, para sistemas de teste no Capítulo 4.

2.4.2 Estimação via Redes Neurais Artificiais

O processo de estimação de estados pode ser considerado como um problema de reconhecimento de padrões, em que, a partir de um conjunto de medidas elétricas em um dado instante, deseja-se obter estimativas para as variáveis não diretamente monitoradas do sistema. Se para um SDEE são conhecidas suas conexões entre barramentos e impedâncias de trechos, e se pode estipular valores prováveis de demanda de carga, uma RNA, como previamente descrita, pode ser treinada a partir de um conjunto de entradas referentes às medidas disponíveis e de respectivas saídas referentes às variáveis não monitoradas. Com o auxílio de uma ferramenta de fluxo de potência, é possível determinar o estado da rede para um dado cenário de carga. Daí, gerando-se combinações de possíveis cenários de carga, o fluxo de potência é capaz de gerar uma base de dados de estados do sistema, considerada como base de padrões para o treinamento de uma RNA.

2.4.2.1 Geração de Cenários

A capacidade de aprendizado de uma RNA está fortemente atrelada aos dados utilizados em seu treinamento. Para que a RNA possa estimar de forma precisa os estados

de um SDEE durante sua operação, é imprescindível a utilização de dados de treinamento que representem todo o espectro de cenários possíveis de operação da rede, contemplando não apenas as variações de consumo de carga, mas também variações topológicas da rede.

2.4.2.1.1 Formulação do Fluxo de Potência

A obtenção de estados-padrão do sistema, a partir de possíveis cenários de carga, é feita a partir do fluxo de potência, formulado a partir de um sistema de equações não-lineares correspondentes às leis de Kirchhoff aplicadas ao sistema estudado [49]. A formulação do problema inclui quatro variáveis para cada barra do sistema:

- V_k é o módulo de tensão da barra k ;
- θ_k é o ângulo de fase de tensão da barra k ;
- P_k é a injeção de potência ativa da barra k ;
- Q_k é a injeção de potência reativa da barra k ;

A depender do tipo de barra do sistema, duas variáveis são dadas, e as outras duas são incógnitas no problema:

- Barra PQ: P_k e Q_k dados, V_k e θ_k incógnitas;
- Barra PV: P_k e V_k dados, Q_k e θ_k incógnitas;
- Barra V θ : V_k e dados, P_k e Q_k incógnitas;


Em suma, as barras PQ e PV são de carga e de geração, respectivamente. O barramento do tipo V θ é a referência angular do sistema, $\theta_k = 0 \text{ rad}$, tomado como a subestação no caso de SDEE. Os trechos são modelados com base em impedâncias e susceptâncias, segundo o modelo π , que pode ser visto na Figura 5, numa ligação entre as barras k e m . Cada trecho apresenta três parâmetros: resistência série r_{km} , reatância série x_{km} e susceptância *shunt* b_{km}^{sh} . A impedância série do ramo é dada por: $z_{km} = r_{km} + jx_{km}$

A admitância série do ramo é dada por:

$$y_{km} = g_{km} + jb_{km} = z_{km}^{-1} = \frac{r_{km}}{r_{km}^2 + x_{km}^2} - j \frac{x_{km}}{r_{km}^2 + x_{km}^2} \quad (2.12)$$

A admitância pode, então, ser separado nos elementos de condutância série g_{km} e susceptância série b_{km} :

$$g_{km} = \frac{r_{km}}{r_{km}^2 + x_{km}^2} \quad (2.13)$$

Figura 5 – Modelo π da linha

Fonte: Elaborado pelo autor (2022)

$$b_{km} = \frac{-x_{km}}{r_{km}^2 + x_{km}^2} \quad (2.14)$$

A formulação dos fluxos de potência ativa e reativa em uma linha que conecta as barras k e m considera os valores de abertura angular entre as barras como:

$$\theta_{km} = \theta_k - \theta_m \quad (2.15)$$

Os fluxos de potência ativa P_{km} e reativa Q_{km} em cada linha são determinados a partir de:

$$P_{km} = V_m^2 g_{km} - V_k V_m g_{km} \cos(\theta_{km}) - V_k V_m b_{km} \sin(\theta_{km}) \quad (2.16)$$

$$Q_{km} = -V_k^2 (b_{km} + b_{km}^{sh}) + V_k V_m b_{km} \cos(\theta_{km}) - V_k V_m g_{km} \sin(\theta_{km}) \quad (2.17)$$

A formulação do fluxo de carga e aplicação das leis de Kirchhoff são feitas de forma matricial, a partir das matrizes de injeção líquida de corrente nas barras, tensão nas barras, e a matriz de admitância nodal. A injeção líquida de corrente na barra k é obtida a partir das correntes de todos os trechos conectados:

$$I_k = \sum_{m \in \Omega_k} I_{km} \quad (k = 1, \dots, nb) \quad (2.18)$$

A corrente em uma linha conectando as barras k e m é dada por:

$$I_{km} = (y_{km} + jb_{km}^{sh})V_k + (-y_{km})V_m \quad (2.19)$$

A expressão matricial da lei dos nós de Kirchhoff pode, então, ser definida como:

$$\underline{I} = Y\underline{V} \quad (2.20)$$

Onde:

- \underline{I} é o vetor complexo das injeções de corrente nodais
- \underline{V} é o vetor complexo das tensões nodais
- Y é a matriz de admitância nodal

A matriz de admitância nodal Y tem seus elementos formados a partir das Equações 2.21 e 2.22. Essa matriz é esparsa, pois todo elemento Y_{km} entre barras k e m não conectadas eletricamente é nulo.

$$Y_{km} = -y_{km} \quad (2.21)$$

$$Y_{kk} = jb_k^{sh} + \sum_{m \in \Omega_k} (jb_{km}^{sh} + y_{km}) \quad (2.22)$$

O conjunto Ω_k contempla todas as barras m conectadas à barra k , excluindo a própria barra k . A matriz de admitância nodal Y pode ser descrita como $Y = G + jB$, onde G é a matriz de condutância e B a matriz de susceptância.

A corrente nodal na barra k pode ser definida, então, como:

$$I_k = Y_{kk}V_k = \sum_{m \in K} (G_{km} + jB_{km})(V_m e^{j\theta_m}) \quad (2.23)$$

A injeção de potência complexa S_k^* na barra k é dada por:

$$S_k^* = P_k - jQ_k = V_k^* I_k \quad (2.24)$$

Substituindo a expressão para a corrente nodal da Equação 2.23 na expressão da potência complexa da Equação 2.24, tem-se:

$$S_k^* = V_k e^{j\theta_k} \sum_{m \in K} (G_{km} + jB_{km})(V_m e^{j\theta_m}) \quad (2.25)$$

Onde K é o conjunto de todas as barras m conectadas à barra k , incluindo a própria barra k . Separando a parte real referente a potência ativa da parte imaginária referente a potência re ativa, obtém-se:

$$P_k = V_k \sum_{m \in K} V_m (G_{km} \cos(\theta_{km}) + B_{km} \sen(\theta_{km})) \quad (2.26)$$

$$Q_k = V_k \sum_{m \in K} V_m (G_{km} \text{sen}(\theta_{km}) - B_{km} \text{cos}(\theta_{km})) \quad (2.27)$$

2.4.2.1.2 Resolução do Fluxo de Potência

A resolução do problema de fluxo de potência é feita através de métodos iterativos, geralmente, o Método de Newton [49]. Para um dado sistema de NB barras contendo NPQ barras do tipo PQ e NPV barras do tipo PV, dois subsistemas principais são definidos:

- Subsistema 1: Dimensão $2NPQ + NPV$

$$\begin{cases} P_k^{esp} - V_k \sum_{m \in K} V_m (G_{km} \text{cos}(\theta_{km}) + B_{km} \text{sen}(\theta_{km})) = 0 \\ Q_k^{esp} - V_k \sum_{m \in K} V_m (G_{km} \text{sen}(\theta_{km}) - B_{km} \text{cos}(\theta_{km})) = 0 \end{cases} \quad (2.28)$$

A primeira equação é resolvida para todas as barras dos tipos PQ e PV, enquanto a segunda apenas para as barras PQ. Para esse subsistema, são dados os valores de P_k e Q_k das barras PQ, e de P_k e V_k das barras PV. São incógnitas a serem calculadas os valores de V_k e θ_k para as barras PQ e θ_k para as barras PV.

- Subsistema 2: Dimensão $NPV + 2$

$$\begin{cases} P_k = V_k \sum_{m \in K} V_m (G_{km} \text{cos}(\theta_{km}) + B_{km} \text{sen}(\theta_{km})) \\ Q_k = V_k \sum_{m \in K} V_m (G_{km} \text{sen}(\theta_{km}) - B_{km} \text{cos}(\theta_{km})) \end{cases} \quad (2.29)$$

A primeira equação é referente a barra de referência $V\theta$, enquanto a segunda para todas as barras PV e também para a barra de referência. A formulação considera apenas uma barra de referência no sistema. A solução do subsistema 2 é obtida de forma trivial, uma vez que todas as suas incógnitas foram previamente definidas pela solução do subsistema 1.

Para a resolução via Método de Newton, define-se o vetor das variáveis desejadas como:

$$\underline{x} = \begin{bmatrix} \underline{\theta} \\ \underline{V} \end{bmatrix} \quad (2.30)$$

Escrevendo o subsistema 1 considerando o valor da injeção das potências calculadas nas Equações 2.26 e 2.27 como P_k^{calc} e Q_k^{calc} , obtém-se o sistema:

$$\begin{cases} P_k^{esp} - P_k^{calc} = \Delta P_k = 0 \\ Q_k^{esp} - Q_k^{calc} = \Delta Q_k = 0 \end{cases} \quad (2.31)$$

O processo de resolução gira em torno de se determinar o vetor de correção $\Delta \underline{x}$ para as variáveis do problema em cada iteração h . Isso é feito a partir da resolução matricial do sistema linear:

$$\underline{g}(\underline{x}^h) = -J(\underline{x}^h) * \Delta \underline{x}^h \quad (2.32)$$

Onde:

- $\underline{g}(\underline{x}^h) = \begin{bmatrix} \Delta \underline{P}^h \\ \Delta \underline{Q}^h \end{bmatrix}$ é o vetor das diferenças entre as potências especificadas e calculadas na iteração h ;
- $\Delta \underline{x}^h = \begin{bmatrix} \Delta \underline{\theta}^h \\ \Delta \underline{V}^h \end{bmatrix}$ é o vetor de correção das variáveis na iteração h ;
- $J(\underline{x}^h)$ é matriz Jacobiana na iteração h .

A matriz Jacobiana para o problema de Fluxo de Potência considera as derivadas parciais das potências ativa e reativa em relação ao ângulo de fase e módulo de tensão, conforme:

$$J(\underline{x}^h) = \begin{bmatrix} \frac{\partial(\Delta \underline{P})}{\partial(\underline{\theta})} & \frac{\partial(\Delta \underline{P})}{\partial(\underline{V})} \\ \frac{\partial(\Delta \underline{Q})}{\partial(\underline{\theta})} & \frac{\partial(\Delta \underline{Q})}{\partial(\underline{V})} \end{bmatrix} \quad (2.33)$$

A partir da definição das variáveis, equações de potência e da matriz Jacobiana, o processo iterativo do método de Newton é realizado, seguindo o algoritmo a seguir:

1. Montagem da matriz de admitância nodal Y ;
2. Inicialização das variáveis $\underline{V} = 1p.u.$, $\underline{\theta} = 0rad$ e o contador de iterações $h = 0$;
3. Calculo de \underline{P}^{calc} , $\Delta \underline{P}^h$, \underline{Q}^{calc} e $\Delta \underline{Q}^h$;
4. Enquanto $|\Delta \underline{P}^h| > \epsilon_p$ ou $|\Delta \underline{Q}^h| > \epsilon_q$, repetir:
 - a) Incremento do contador de iterações $h = h + 1$;
 - b) Montagem da matriz Jacobiana $J(\underline{x}^h)$;
 - c) Resolução do sistema da Equação 2.32 para obter $\Delta \underline{\theta}^h$ e $\Delta \underline{V}^h$;

- d) Atualização das variáveis $\underline{\theta}^{h+1} = \underline{\theta}^h + \Delta\underline{\theta}^h$ e $\underline{V}^{h+1} = \underline{V}^h + \Delta\underline{V}^h$;
- e) Cálculo de \underline{P}^{calc} , $\Delta\underline{P}^{h+1}$, \underline{Q}^{calc} e $\Delta\underline{Q}^{h+1}$.

Ao fim do processo iterativo, quando a maior diferença entre as potências especificadas e calculadas for menor que as tolerâncias definidas ϵ_p para potência ativa e ϵ_q para potência reativa, obtém-se os vetores das variáveis de estados desejadas $\underline{\theta}$ e \underline{V} com precisão equivalente às tolerâncias definidas.

Dessa forma, ao se gerar uma vasta gama de cenários de carga, ou seja, dos valores de potência ativa e reativa nas barras de carga do sistema, e se calcular o fluxo de potência para esses cenários, é possível obter os padrões para as estimativas das variáveis não monitoradas correspondentes aos cenários de carga. Variando os valores das cargas buscando cobrir o espectro possível de operação do sistema, os dados a serem utilizados para treinamento contemplam os possíveis estados do sistema para qualquer intervalo de carga factível durante sua operação, garantindo que o treinamento da RNA forneça capacidade de generalização suficiente para a estimação de estados.

Não obstante, para criação de dados com variação de topologia, basta realizar a alteração dos dados do sistema, modificando, assim a matriz de admitância e o resultado dos cálculos do Fluxo de Potência.

2.4.3 Métrica de Estimação

A avaliação dos resultados do processo de Estimação de Estados é comumente realizada a partir de métricas conhecidas na literatura [50]. A principal métrica utilizada para avaliação quantitativa dos resultados é o Erro de Estimação de Estados (*EEE*), calculado conforme a Equação 2.34. Essa métrica mensura o erro total de estimação, aferindo o erro quadrático de todos os estados estimados em relação aos valores reais desejados, e apresentando o resultado como a raiz quadrada do somatório de todos os erros quadráticos, em formato percentual. Sua utilização é essencial, principalmente no que tange a comparação direta dos resultados obtidos com métodos clássicos da literatura, como o *WLS*.

$$EEE = \sqrt{\sum_{k=1}^{nb} (V_k^* - \hat{V}_k)^2 + \sum_{k=1}^{nb} (\theta_k^* - \hat{\theta}_k)^2} * 100 \quad (2.34)$$

Onde:

- V_k^* é o valor real do módulo tensão na barra k ;
- \hat{V}_k é o módulo de tensão estimado na barra k ;
- θ_k^* é o valor real do ângulo de fase da tensão na barra k ;

- $\hat{\theta}_k$ é o ângulo de fase de tensão estimado na barra k ;
- nb é o número de barras do sistema.

2.5 MEDIÇÕES E ERROS ASSOCIADOS

O desempenho do processo de estimação de estados está fortemente atrelado às medições disponíveis no sistema a ser estimado. Entre os diversos tipos de medidores encontrados em SDEE, destacam-se as PMUs e os Medidores Inteligentes. Cada tipo de medidor tem suas particularidades em relação às variáveis elétricas medidas e à classe de precisão das medidas, cujo erro associado é aspecto importante não apenas para a formulação de métodos de solução iterativos, como o WLS descrito na Seção 2.4.1, mas também para aplicações com RNA.

2.5.1 Tipos de Medidores

O principal equipamento de medição em SDEE é a PMU. Este equipamento tem a capacidade de realizar a captação de dados do sistema com referência geográfica e temporal, a partir do uso do Sistema de Posicionamento Global, do inglês *Global Positioning System* (GPS). As medições elétricas são obtidas em fasores, ou seja, medição de módulo e ângulo de fase das grandezas elétricas (tensão e corrente). A comunicação dos dados medidos, com referência temporal do GPS, permite a medição dos ângulos de fase das grandezas elétricas, uma vez que esses são medidos a partir da abertura angular entre o fasor mensurado e um fasor de referência.

O sistema GPS é responsável por enviar, de forma contínua, pulsos temporais com precisão da ordem de $1\mu s$ para todas as unidades PMU dispostas no SDEE [51]. Essa ordem de precisão é suficiente para garantir a operação sincronizada dos equipamentos de medição espalhados pelo Sistema de Distribuição. As medições obtidas são formatadas conforme previsto no padrão IEEE C37.118 [52], que estabelece um formato padrão para a transmissão de dados fasoriais, permitindo que esta seja feita ainda que por equipamentos de fabricantes diferentes. A precisão das medições das PMUs consideradas neste trabalho é de $\pm 0,4\%$ para medições de módulo e ângulo de fase de tensão, e de $\pm 0,8\%$ para os fasores de corrente, conforme [47], embora estes valores possam variar para outros equipamentos semelhantes.

Outro equipamento de medição que vem tendo seu uso difundido em SDEE são os Medidores Inteligentes. Esses medidores vêm sendo empregados no lugar dos medidores convencionais para faturamento nas unidades consumidoras dos SDEE, devido à sua capacidade de comunicação bidirecional, que os permite não apenas receber informações, mas também enviar dados das medições para o Centro de Operação da Distribuição. Esses equipamentos são capazes de medir apenas os módulos de tensão e corrente, e têm precisão

de medição na ordem de $\pm 2,0\%$ [53]. Apesar de não fornecerem medições fasoriais, os Medidores Inteligentes podem contribuir com informações vitais dos estados do sistema nos pontos onde estão instalados, seja considerando sua operação conjunto com PMUs para estimação, ou até mesmo de forma isolada.

2.5.2 Erros Grosseiros de Medição

O processo de aquisição de medidas está suscetível à ocorrência de diversos tipos de erros cuja magnitude excede à dos erros de precisão esperados do medidor. Esse tipo de ocorrência é denominada de erro grosseiro e contempla falhas na aquisição dos dados de medição, falhas na comunicação dos dados medidos, ataques cibernéticos, ou defeito no próprio equipamento. Os erros grosseiros, por apresentarem magnitudes muito superiores aos erros de precisão dos equipamentos, afetam de forma drástica a qualidade da estimação de estados, caso sejam incorporados neste processo. Por isso, é importante a adequação de técnicas de detecção e correção de erros grosseiros junto à EE.

A detecção de erros grosseiros pode ser feita a partir do algoritmo *Z-Score* [39]. Esse algoritmo tem natureza estatística e visa averiguar se um determinado valor de medição está dentro ou fora de um intervalo de confiança obtido a partir da média de observações passadas da mesma medida. Para a amostra atual da medição z sob análise, é calculado o seu valor *score* Z a partir de:

$$Z = \frac{(z - \mu_z)}{\sigma_z} \quad (2.35)$$

Onde μ_z é a média de um determinado número n_z de observações passadas, e σ_z é o desvio padrão dessas observações. O *score* Z da amostra atual é, então, comparado com um limite pré-definido Z_l . Em caso de *score* superior ao limite Z_l , a amostra é identificada como erro grosseiro. A definição do limite Z_l é feita a partir da análise temporal das variações de medidas durante um período de observações históricas, de modo que o limite seja superior ao maior *score* obtido dentro do histórico para operação normal do SDEE. Dessa forma, variações normais de carga durante a operação não são falsamente detectadas como erros grosseiros. Um maior detalhamento sobre a utilização de dados históricos para escolha dos limites Z_l é dado na seção **3.5.2** da Metodologia Proposta.

2.5.3 Erros Topológicos


Além das medidas de variáveis elétricas do sistema, estados de chaves (aberto ou fechado) também são informações relevantes para o monitoramento de um SDEE. Essa informação é essencial para que o COD seja capaz de identificar a topologia atual do sistema e interpretar adequadamente as informações oriundas das medidas elétricas. Assim como essas medidas, os dados topológicos são passíveis de erros grosseiros. A informação de estado das chaves, por ser binária, aberto ou fechado, pode apresentar apenas dois tipos

de erro grosseiro: chave aberta informada como fechada, ou chave fechada informada como aberta. Esse tipo de erro pode inviabilizar o processo de EE, por exemplo, na utilização do método clássico WLS, que requer as informações da topologia da rede para cálculo das estimativas durante as iterações, pois, por exemplo, uma chave fechada informada como aberta pode caracterizar um SDEE desconexo, impossível de ser solucionado através de métodos que utilizem conexões elétricas como base de cálculo. Para RNA, o erro topológico também pode afetar negativamente a EE, pois o conjunto de dados de chaves contaminado por erro grosseiro pode compor um padrão inexistente, portanto, não mapeado pela RNA durante seu treinamento.

Portanto, a detecção e a correção de erros topológicos é essencial para a qualidade de estimadores de estado que considerem informações topológicas em sua formulação. Uma ferramenta capaz de realizar ambas tarefas simultaneamente é a Rede Neural Hopfield, que foi primeiro descrita por [54]. As RNH são chamadas do tipo *feedback*, pois as saídas realimentam as entradas em um processo iterativo que visa minimizar a função de energia [55], descrita pela Equação 2.36, onde $w_{g,h}$ é o peso da conexão entre os neurônios g e h , S_g e S_h são as saídas dos neurônios g e h , e b_g é o valor de *bias* para o neurônio g . Um exemplo de Rede Neural Hopfield pode ser visto na Figura 6, onde três neurônios são exemplificados pelas suas interconexões.

$$E = -\frac{1}{2} \sum_g \sum_h w_{g,h} S_g S_h - \sum_g b_g S_g \quad (2.36)$$

Figura 6 – Rede Neural Hopfield



Fonte: Elaborado pelo autor (2022)

A utilização de Redes Neurais Hopfield para tratar erros topológicos é possível a partir da consideração de cada neurônio como o estado de uma chave do SDEE. Para uma dada topologia, um padrão de estados é utilizado para treinar a RNH, que aprende quais chaves devem estar fechadas e quais devem estar abertas. Daí, durante a operação do SDEE, se um erro topológico ocorrer, por exemplo, identificando uma chave fechada como aberta, o respectivo neurônio da RNH receberá um valor diferente do observado

durante o treinamento, e a rede entra em processo de regeneração para que esse neurônio afetado volte a apresentar o padrão aprendido. Dessa forma, os erros topológicos são identificados e corrigidos pelo mesma Rede Neural Hopfield, que deve ser empregada de forma contínua durante a operação do EE, estando antes do próprio do estimador, em um funcionamento em cascata, para que apenas os estados das chaves pós-RNH sejam alimentados no estimador. A utilização contínua da Rede Neural Hopfield é segura, pois, ao ser alimentada com um padrão de entradas sem erro, a rede não realiza ajuste algum nas saídas, ou seja, apenas dados com erro são corrigidos, ao passo que dados corretos são mantidos inalterados.

2.6 CONCLUSÕES PARCIAIS

Este capítulo apresentou uma contextualização teórica acerca da temática tratada na dissertação, tratando desde a caracterização dos sistemas de distribuição, pelo processo de estimação de estados, e até a apresentação das ferramentas matemáticas que são utilizadas para resolução desse problema. Os SDEE foram descritos a partir de suas características e particularidades que trazem à tona a necessidade de se realizar um processo de monitoramento contínuo de suas variáveis elétricas, a fim de possibilitar uma operação segura. Em seguida, foram apresentadas as RNA e sua capacidade de estimar variáveis desconhecidas a partir de treinamento prévio com dados históricos observados. O processo de EE, em si, foi, então, apresentado tanto em sua forma clássica de resolução via métodos iterativos, quanto pela resolução via RNA, que compõe o foco deste trabalho. A métrica de avaliação da qualidade das estimações também foi apresentada. Não obstante, foram também apresentados os equipamentos de medição comuns em SDEE, e quais os tipos de erros se espera deles, tanto na precisão para qualquer medição, quanto na ocorrência de erros grosseiros. Esses últimos, por não apresentarem um comportamento específico à classe de precisão do equipamento de medição, requerem técnicas para detecção, que podem afetar drasticamente a qualidade da estimativa caso não sejam identificados e corrigidos. Além dos erros grosseiros nas medidas elétricas, também são descritos os erros topológicos e o ferramental necessário para lidar com os mesmos.

É possível concluir que o problema de EE para SDEE compreende uma vasta gama de aspectos peculiares que devem ser levados em consideração durante a formulação de uma metodologia de EE robusta a divisões em áreas, variações de carga, de topologia e inserção de geração distribuída; além dos possíveis erros grosseiros que podem ocorrer nas medidas elétricas e estados de chaves do sistema. Com isso, a metodologia proposta no capítulo seguinte visa contemplar todos esses aspectos para atender os SDEE com um modelo de estimador de estados robusto às particularidades apresentadas no presente capítulo.

3 METODOLOGIA

3.1 INTRODUÇÃO

A metodologia proposta nesta dissertação tem por objetivo o desenvolvimento de um Estimador de Estados Multi-Área para Sistemas de Distribuição a partir do uso de Redes Neurais Artificiais. O aspecto Multi-Área compreende o uso de uma RNA como estimador para cada área, de forma independente das demais durante operação normal, mas capaz de utilizar dados das fronteiras com as áreas vizinhas como pseudo-medidas em caso de detecção de erros grosseiros em suas medições. Os estados estimados a partir de cada RNA são, posteriormente sincronizados por um agente central, que reúne todas as estimações de cada área, e aplica um critério de decisão para definir a estimação mais adequada para as barras de fronteira, pois estas terão seus estados estimados por ambas as áreas que a contêm. Com isso, a estimação total do sistema é obtida pelo agente central, sem que haja necessidade de intercâmbio de todos os dados estimados entre os estimadores locais de cada área.

O estimador proposto é capaz de operar considerando variações topológicas através das mudanças dos estados das chaves do sistema, ao considerar os estados das chaves como dados medidos e utilizando-os como entradas das RNA. Durante a operação, é empregada de forma contínua uma Rede Neural Hopfield para cada área, além da RNA para estimação, de modo a detectar e corrigir eventuais erros nos estados das chaves, restaurando os dados para obter uma combinação de estados das chaves que se refira a uma das topologias viáveis do sistema e conhecidas da RNA durante seu treinamento. Além da correção de erros topológicos, o Estimador proposto também apresenta robustez contra erros grosseiros de medição, a partir do uso do Algoritmo *Z-Score* para detecção de erros grosseiros nas medições das variáveis elétricas, e do uso de Redes Neurais *Backup* para estimação da área afetada a partir de pseudo-medidas obtidas da barra de fronteira da área vizinha.

Este capítulo prossegue com o detalhamento de cada aspecto do Estimador proposto, com seções contemplando desde a geração dos cenários para treinamento das RNA, a especificação das RNA, os métodos de detecção e correção de erros grosseiros, e, por fim, o método de operação do algoritmo proposto a partir do agente central coordenando os estimadores locais de cada área.

3.2 GERAÇÃO DE CENÁRIOS DE CARGA

A utilização de Redes Neurais Artificiais para estimação de qualquer problema requer, de forma imperativa, uma base de dados que contemple todo o espectro de valores que as variáveis de interesse possam assumir. Para o problema de Estimação de Estados em SDEE, os dados a serem utilizados para treinamento das RNA precisam cobrir todas

as condições operativas que o SDEE pode encontrar, considerando variações das potências demandadas durante os intervalos de operação, além das variações topológicas que podem ocorrer no sistema. As subseções seguintes detalham o processo de variação de parâmetros de um SDEE para a geração da base de dados utilizada para sua estimação via RNA.

3.2.1 Variação de Carga

Durante a operação de um SDEE, as cargas demandadas pelos consumidores variam estocasticamente, porém, dentro de faixas conhecidas. Os horários de menor demanda e de pico de carga são, geralmente, conhecidos pelas concessionárias de energia, o que facilita o processo de geração de cenários de carga. Considerando a potência nominal $1,0 p.u.$ de um dado barramento de um SDEE como o pico de carga do barramento, é possível dividir intervalos de tempo de um dia de operação da seguinte forma:

- 50% do tempo - Carga leve - Potência média demandada: $0,5 p.u.$
- 30% do tempo - Carga média - Potência média demandada: $0,8 p.u.$
- 20% do tempo - Carga alta - Potência média demandada: $1,0 p.u.$

Ou seja, durante metade de um dia normal de operação, a carga média demandada é baixa, em torno de 50% do seu valor nominal; durante 30% do tempo o SDEE apresenta carga média em torno de 80% do valor nominal; e em apenas 20% do tempo ocorre o pico de carga em torno do seu valor nominal. Dessa forma, durante a geração de cenários, a divisão temporal apresentada é incorporada para determinar a fração de cenários gerados em cada nível de carga (leve, média ou alta).


A partir da divisão temporal em níveis de carga, é preciso considerar a incerteza sobre a carga em cada determinado momento. Em [14], o processo de Estimação de Estados é realizado considerando uma possível variação de carga de $\pm 40\%$ em cima do valor nominal de cada barramento. Considerando este valor de incerteza sobre os patamares de carga leve, média e alta descritos anteriormente, obtemos as seguintes faixas de variação de carga para os cenários gerados:

- Carga leve - Faixa de Potência média demandada: $0,3 p.u.$ até $0,7 p.u.$
- Carga média - Faixa de Potência média demandada: $0,48 p.u.$ até $1,12 p.u.$
- Carga alta - Faixa de Potência média demandada: $0,6 p.u.$ até $1,4 p.u.$

A incerteza da carga de $\pm 40\%$ é considerada como variando aleatoriamente dentro de uma distribuição normal de probabilidade, com sua média sendo a carga média do nível de carga atual, e desvio padrão de 13,33%, de modo que 99,7% dos cenários gerados se

encontrem dentro do intervalo de variação de $\pm 40\%$ desejado. Uma representação gráfica de uma distribuição normal de probabilidade pode ser vista na Figura 7, na qual uma função $f(x)$ representa a probabilidade de ocorrência de um evento genérico, sendo esta probabilidade centrada na média μ , e apresentando desvio padrão σ . Observa-se que 99,7% das ocorrências se encontram dentro do intervalo de $\pm 3 * \sigma$ em torno da média μ .

Figura 7 – Distribuição Normal de Probabilidade



Fonte: André Zibetti (2018)

Para cada cenário de carga, tendo já sido definido seu patamar de carga, é sorteada a incerteza de carga aleatória para cada barramento do SDEE, é obtido o valor de Potência Ativa no barramento, multiplicando a carga aleatória obtida pelo valor nominal da barra, conforme a Equação 3.1. Note que, embora todas as barras de encontrem dentro do mesmo patamar de carga simultaneamente, a incerteza de carga incide de forma aleatória em cada uma, de forma a garantir uma maior flexibilidade nos cenários obtidos. A partir do valor de Potência Ativa, é obtida a Potência Reativa considerando o fator de potência nominal fixo no barramento, como descrito na Equação 3.2:

$$P_k = NP_k \pm 3 * \sigma_k \quad (3.1)$$

$$Q_k = P_k * \tan(\arccos(\Psi_k)) \quad (3.2)$$

Onde:

- P_k é a potência ativa na barra k em um dado cenário;
- Q_k é a potência reativa na barra k no mesmo cenário;
- NP_k é a potência ativa nominal da barra k ;

- σ_k é o desvio padrão da potência ativa na barra k ;
- Ψ_k é o fator de potência nominal na barra k .

Com isso, obtém-se os valores de Potência Ativa e Reativa em todos os barramentos do sistema de forma aleatória, construindo, assim um cenário de carga gerado. Como descrito na Seção 2.4.2.1.2, a partir das potências sorteadas em todos os barramentos, e dos dados físicos de conexão entre as barras, e as impedâncias das linhas, é possível realizar o cálculo de um Fluxo de Potência, obtendo os estados do sistema, Módulo e Ângulo de Fase de Tensão, além de outras informações, como Corrente e Fluxo de Potência nas linhas para o dado cenário de carga.

Para considerar a Variação Topológica dentro da geração de cenários, é necessário o cálculo do Fluxo de Potência do cenário gerado considerando a alteração das conexões físicas do sistema, conforme a topologia atual do SDEE. Logo, dentro da geração de cenários, também são consideradas as variações topológicas, realizando o mesmo processo de geração aleatória de cenários descrito acima para cada uma das Nt topologias consideradas.

Para um determinado número Nc de cenários gerados para uma topologia de um SDEE, são compilados os dados gerados de Potência Ativa e Reativa, além dos calculados (Fasores de Tensão e Corrente, e Fluxos de Potência nas linhas), formando a base de dados com $Nc * Nt$ cenários para criação dos conjuntos de treinamento, validação e teste da RNA, como será descrito na seção seguinte.

3.2.2 Divisão dos Conjuntos de Cenários

A partir dos $Nc * Nt$ cenários gerados para o sistema, já levando em conta todas as topologias consideradas, é necessária a divisão desses dados para atribuir a um dos três conjuntos de dados a serem utilizados nas RNA. A divisão é feita seguindo o algoritmo abaixo:

1. Inicializar contador de cenários $jj = 1$
2. Inicializar divisor de cenários $kk = 1$
3. Enquanto $jj \leq Nc * Nt$:
 - a) Se $kk = 1$ ou $kk = 3$:
 - i. Cenário jj para o Conjunto de Treino
 - ii. Incremento do contador de cenários $jj = jj + 1$
 - iii. Incremento do divisor de cenários $kk = kk + 1$
 - b) Se $kk = 2$:
 - i. Cenário jj para o Conjunto de Validação

- ii. Incremento do contador de cenários $jj = jj + 1$
 - iii. Incremento do divisor de cenários $kk = kk + 1$
- c) Se $kk = 4$:
- i. Cenário jj para o Conjunto de Testes
 - ii. Incremento do contador de cenários $jj = jj + 1$
 - iii. Reinicialização do divisor de cenários $kk = 1$

Desta forma, a divisão dos dados formará os três conjuntos:

- Conjunto de Treino - 50% dos cenários;
- Conjunto de Validação - 25% dos cenários;
- Conjunto de Teste - 25% dos cenários.

A separação dos dados utilizando o algoritmo descrito acima garante que os dados gerados seguindo a divisão temporal proposta na Seção **3.2.1** serão divididos de forma uniforme entre os três conjuntos, independente de estarem dispostos em ordem ou de já estarem dispostos de forma aleatória.

O conjunto de treino é utilizado para o treinamento das Redes Neurais Artificiais. É a partir desses dados que a RNA ajusta seus pesos sinápticos no processo iterativo de treinamento, de modo a aprender os padrões de resposta do sistema, a partir das respectivas entradas. Para garantir a capacidade de generalização da RNA, se faz uso o conjunto de validação. O critério de Validação Cruzada, descrito na Seção **2.3.2**, é utilizado durante o treinamento das RNA para determinar a convergência do processo iterativo e o fim do treinamento caso sejam observadas N_{vc} amostras de validações sequenciais sem aumento no erro de estimação. Neste trabalho, são consideradas como $N_{vc} = 10$ o número de validações sequenciais necessárias para determinar a parada antecipada do treinamento. Já o conjunto de teste é separado do treinamento e validação da rede, de modo a se obter uma massa de dados nunca antes vista pela RNA para avaliar o desempenho posterior da Estimação de Estados tanto nas métricas quanto em avaliações gráficas de comparação entre os estados reais e estimados.

3.3 MEDIÇÕES

Os dados que alimentam as RNA para Estimação de Estados vêm dos medidores alocados em algumas barras do SDEE. Este trabalho considera que os medidores são previamente alocados, não fazendo parte do escopo do trabalho uma metodologia de alocação ótima dos medidores. A partir da posição de cada medidor, são obtidas as medições das variáveis elétricas monitoradas pelo equipamento, variáveis estas que podem

ser diferentes a depender do tipo de equipamento empregado. Neste trabalho, as medições são consideradas a partir dos dados presentes nos cenários gerados a partir do processo demonstrado na Seção **3.2.1**.

3.3.1 Alocação das Medições

A alocação dos medidores praticada neste trabalho segue o requisito mínimo para utilização da RNA de Estimação de cada área, ou seja, é necessário ao menos um equipamento fornecendo medições elétricas dentro de uma determinada área do SDEE, para que as medições possam ser utilizadas para treinamento e operação do Estimador local. Este trabalho não propõe estratégia de alocação ótima de medidores, apenas empenha-se em demonstrar a funcionalidade da metodologia considerando a operação atendendo o requisito mínimo de um medidor por área.

Dois tipos diferentes de equipamentos de medição são considerados neste trabalho, o primeiro deles a Unidade de Medição Fasorial, comumente chamada de PMU, e o segundo, o Medidor Inteligente. As PMUs, como sugere o nome, são capazes de realizar medições fasoriais das variáveis elétricas, ou seja, medem tanto Módulo quanto Ângulo de Fase de tensão e corrente. Já os Medidores Inteligentes conseguem medir apenas os módulos dessas variáveis, e sua utilização visa comprovar a capacidade das RNA de também estimar Ângulos de Fase dos estados ainda que sendo alimentadas apenas com medições de Módulo de tensão e corrente.

3.3.2 Tratamento das Medições

A metodologia proposta considera os dados dos cenários como sendo os valores reais para treinamento das RNA, e considera também os dados dos cenários gerados como sendo as medições provenientes dos medidores alocados. Essas medições, porém, são acometidas pelos erros de precisão intrínsecos dos equipamentos. Portanto, é necessária a inclusão dos erros de precisão nos dados das medições durante os testes de estimação das RNA. Embora os erros de precisão possam ocorrer em qualquer valor dentro da faixa de precisão, a fim de obter uma análise conservadora do Estimador proposto, este trabalho considera a inclusão do erro em seu valor máximo em todas as medições advindas dos dados do conjunto de testes das RNA. Dessa forma, é possível obter o resultado considerando o pior caso de imprecisão dos equipamentos instalados. Importante notar que os erros de precisão são aplicados apenas nos dados de teste, não estando presente nas medições consideradas durante o treinamento das RNA, pois caso os erros fossem considerados durante o treinamento, as RNA estariam condicionadas a operar com conhecimento prévio do erro de precisão presente nas amostras de treino, potencialmente melhorando seu desempenho a partir da imprecisão, e não piorando, como é de esperar.

Como descrito na Seção **2.5.1**, a precisão das PMUs é de $\pm 0,4\%$ para medições de

fasores de tensão, e $\pm 0,8\%$ para de fasores de corrente [47]. Já os Medidores Inteligentes apresentam precisão na faixa de $\pm 2,0\%$ para suas medições de Módulo de tensão e corrente [53]. Dessa forma, para todos as medições vindas dos dados do conjunto de teste, os erros de precisão são aplicados em seu valor máximo positivo.

3.4 REDES NEURAIAS ARTIFICIAIS

As Redes Neurais Artificiais utilizadas para Estimação de Estado nesse trabalho são do tipo *MultiLayer Perceptron*, e são criadas a partir do comando *newff* do Matlab. Dada a natureza do problema de EE para Sistemas de Distribuição, no qual são conhecidos dados históricos das entradas (medições) e saídas (estados estimados) das RNA, é utilizado esse tipo de RNA pela sua capacidade de realizar o aprendizado supervisionado. As Redes Neurais propostas utilizam como função de ativação dos neurônios da camada oculta e de saída a Função Sigmoide, e são treinadas a partir do algoritmo *backpropagation*. É utilizada a arquitetura das RNA com apenas uma camada oculta, cujo número de neurônios é dependente do número de entradas e saídas da RNA, conforme determinado por [32] e expresso pela Equação 3.3:

$$NNCA_a = \left(\frac{2}{3} * NE_a\right) + NS_a \quad (3.3)$$

Onde NE_a representa o número de entradas da RNA referente a área a , referente ao número de variáveis elétricas medidas NM_a mais o número de estados das chaves NSW_a da área; e NS_a seu número de saídas, o dobro do número de barras NB_a estimadas da área, pois os estados compreendem tanto Módulo quanto Ângulo de Fase de tensão. Ambos valores são obtidos conforme as Equações 3.4 e 3.5, respectivamente.

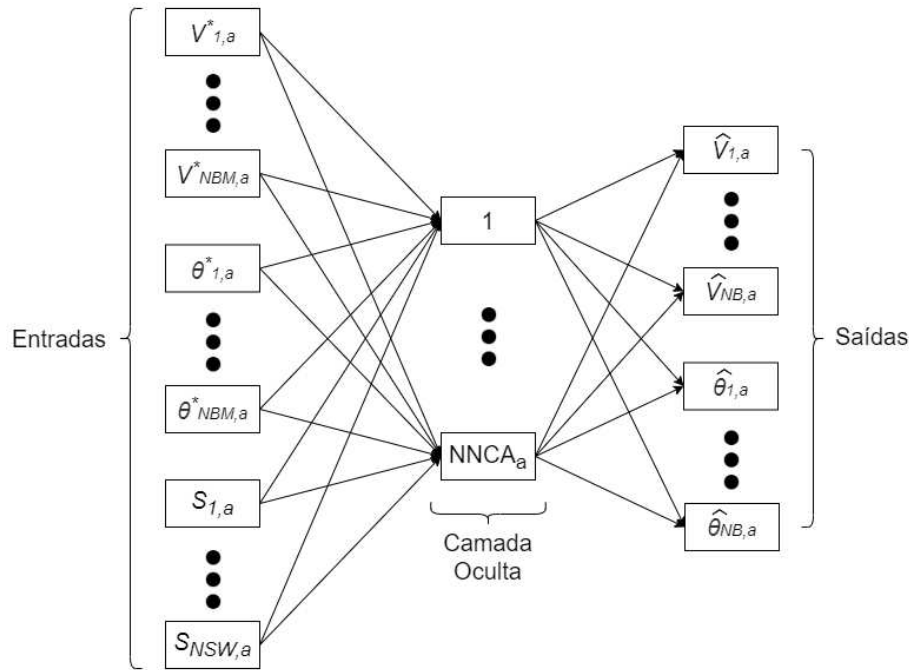
$$NE_a = NM_a + NSW_a \quad (3.4)$$

$$NS_a = 2 * NB_a \quad (3.5)$$

Uma representação visual de um exemplo de arquitetura das RNA propostas é apresentada pela Figura 8, na qual as entradas são representadas pelas medições elétricas disponíveis, os Módulos $V_{k,a}^*$ e Ângulos de Fase $\theta_{k,a}^*$ de tensão nas barras k monitoradas, aliadas aos estados das chaves monitoradas $S_{km,a}$ entre as barras k e m na área considerada. Importante notar que, caso a área contenha medições de corrente, essas medições também estarão consideradas como entradas da RNA. Do mesmo modo, para áreas que contenham apenas Medidores Inteligente, e forem desprovidas de medições de Ângulo de Fase de tensão, esses ângulos estarão ausentes da arquitetura da RNA da área em questão. As chaves consideradas como monitoradas por uma área a são todas aquelas contidas dentro da área, além das chaves correspondentes às linhas que conectadas a área a a alguma área

vizinha. Neste caso, a chave da linha que conecta as duas áreas é alimentada como entrada para as RNA de ambas as áreas, uma vez que a informação sobre seu estado concerne e influencia diretamente o funcionamento de ambos os estimadores locais. A partir das conexões dos $NNCA_a$ neurônios da camada oculta, são produzidas as saídas da RNA, os estados estimados de todas as barras da área a .

Figura 8 – Rede *MultiLayer Perceptron* para Estimação de Estados Multi-Área em SDEE



Fonte: Elaborado pelo autor (2022)

3.4.1 Sincronismo das Estimções Locais

Após a estimção ser realizada por cada um dos estimadores locais, os dados estimados por cada RNA são compartilhados junto ao operador central, encarregado de sincronizar as estimções locais e formar a estimção completa do SDEE. Para as barras únicas a cada área a , os estados estimados são unidos para formar a estimção completa, conforme as Equações 3.6 e 3.7.

$$\hat{V}_{sis} = \bigcup_{a=1}^{N_A} \hat{V}_{k,a} \quad (3.6)$$

$$\hat{\theta}_{sis} = \bigcup_{a=1}^{N_A} \hat{\theta}_{k,a} \quad (3.7)$$

Já para as barras de fronteira f , aquelas compartilhadas por mais de uma área, é necessária a atuação de um critério de decisão para tomar uma das estimções como mais adequada, a da área A_{sf} , e desconsiderar a outra, conforme a Equação 3.8.

$$\widehat{V}_f = \widehat{V}_{f,a}, \quad a = A_{sf} \quad (3.8)$$

O critério estabelecido neste trabalho é o cálculo do Erro de Estimação de Sincronismo $E_{sinc,a}$ de cada uma das áreas que compreendem a barra de fronteira f , a partir dos valores medidos, para determinação do menor erro, que configura a área A_{sf} escolhida. Como não é possível ter acesso aos dados reais dos estados durante a operação, o cálculo das métricas completas descritas na Seção 2.4.3 é inviável durante a operação em tempo real do Estimador, e a decisão deve ser tomada considerando apenas os erros que podem ser calculados a partir dos estados estimados das barras com medidores alocados. Dessa forma, a depender dos tipos de medidores instalados nas áreas, o critério pode ser aplicado a partir das diferentes formas:

- Cenário 1: Ambas as áreas contendo PMUs: O erro de estimação da área a é calculado a partir da soma normalizada dos erros de Módulo e Ângulo de Fase de tensão de todas as NM_a PMUs localizadas na área a :

$$E_{sinc,a} = \frac{\sqrt{\sum_{k=1}^{NM_a} (V_k^* - \widehat{V}_k)^2 + \sum_{k=1}^{NM_a} (\theta_k^* - \widehat{\theta}_k)^2}}{NM_a} \quad (3.9)$$

- Cenário 2: Ambas as áreas contendo MIs: O erro de estimação da área a é calculado a partir da soma normalizada dos erros do Módulo de tensão de todos os NM_a MIs localizados na área a :

$$E_{sinc,a} = \frac{\sqrt{\sum_{k=1}^{NM_a} (V_k^* - \widehat{V}_k)^2}}{NM_a} \quad (3.10)$$

- Cenário 3: Uma área contendo PMUs e outra contendo apenas MIs: Como uma das áreas não possui medição de Ângulo de Fase de tensão, o erro de estimação da área a é calculado a partir da soma normalizada apenas dos erros do Módulo de tensão de todos os NM_a MIs localizados na área a , desconsiderando o Ângulo de Fase da área que contém PMU para que o erro possa ser comparado com a área que contém apenas medição de Módulo de tensão com os MIs:

$$E_{sinc,a} = \frac{\sqrt{\sum_{k=1}^{NM_a} (V_k^* - \widehat{V}_k)^2}}{NM_a} \quad (3.11)$$

Para todos os cenários descritos acima, o estimador local calcula o seu Erro de Estimação de Sincronismo e o envia junto aos dados dos estados estimados para o operador central, de modo que este possa aplicar o critério de menor Erro de Estimação

de Sincronismo para tomar a estimação da área $A_{s,f}$ como mais apropriada para aquela amostra de estimação. Os estados estimados da barra de fronteira f pela RNA da área com maior $E_{sinc,a}$ são descartados do processo de sincronismo.

3.4.2 Rede Neural Centralizada

A fim de avaliar a qualidade de estimação da metodologia proposta de Estimação Multi-Área junto a métodos clássicos de estimação, este trabalho também utiliza uma RNA única para estimação centralizada dos SDEE frente aos mesmos cenários de carga e condições de alocação de medidores. A RNA Centralizada considera a operação dos mesmos SDEE utilizados para teste como se pertencessem a um mesmo operador. Todas as medições obtidas são processadas juntamente pelo operador central e a estimação é feita a partir de uma única RNA que recebe todas as medições e os estados das chaves do SDEE. Para a RNA Centralizada a mesma arquitetura *Multilayer Perceptron* e o mesmo algoritmo de treinamento *backpropagation* das RNA Multi-Área são utilizados. O número de neurônios da única camada oculta $NNCA_c$ é expresso pela Equação 3.12:

$$NNCA_c = \left(\frac{2}{3} * NE_c\right) + NS_c \quad (3.12)$$

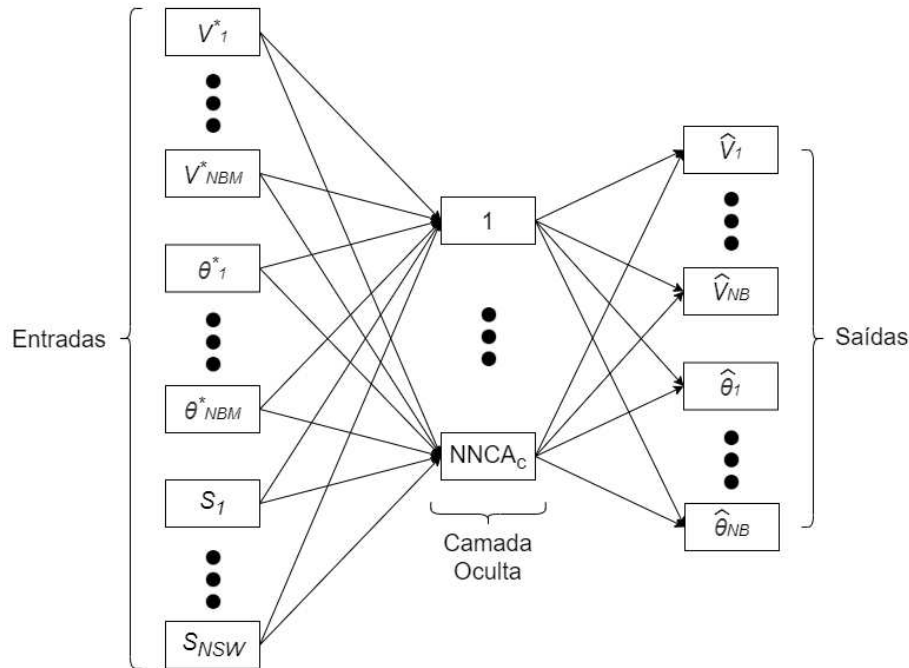
Onde NE_c representa o número de entradas da RNA Centralizada, igual a soma do número de variáveis elétricas medidas NM mais o número de estados das chaves NSW do sistema; e NS_c o número de saídas da RNA, o dobro do número de barras NB estimadas do sistema: Módulo e Ângulo de Fase de tensão. Ambos valores são obtidos conforme as Equações 3.13 e 3.14, respectivamente.

$$NE_c = NM + NSW \quad (3.13)$$

$$NS_c = 2 * NB \quad (3.14)$$

Um exemplo de arquitetura da RNA Centralizada pode ser visto na Figura 9, onde a mesma arquitetura das RNA Multi-Área é aplicada ao caso de um sistema sendo operado de forma única por uma RNA. Assim como para as RNA Multi-Área, as entradas da RNA Centralizada estão condicionadas aos tipos de medidores empregados no SDEE, podendo conter medições de Módulo de Corrente a partir de PMUs alocadas, e estão passivas a não ter medições de Ângulo de Fase de tensão para sistemas contendo apenas Medidores Inteligentes alocados. Nesses casos, a arquitetura da RNA Centralizada específica ao SDEE em questão é moldada, de forma a ter suas entradas representando cada uma das medições elétricas disponíveis, além dos estados das chaves S_{km} entre as barras do sistema.

Figura 9 – Rede *MultiLayer Perceptron* para Estimação de Estados Centralizada em SDEE



Fonte: Elaborado pelo autor (2022)

3.5 ERROS GROSSEIROS

O processo de aquisição das medições de um SDEE está sujeito à ocorrência de erros grosseiros, cuja magnitude ultrapassa os limites de erros esperados da precisão dos equipamentos de medição. As medições acometidas por erros grosseiro, se não detectadas e corrigidas, podem prejudicar a qualidade da estimação, tendendo o resultado a valores longe dos reais valores dos estados do sistema. Dessa forma, é necessária a utilização de alguma estratégia para detectar a ocorrência desses erros grosseiros. Como as RNA são treinadas com um número fixo de medições, usadas como suas entradas, é necessário que todas as amostras contenham todas as medições para alimentar a RNA. O simples descarte da medição com erro grosseiro não se apresenta como opção viável para operação de um Estimador via RNA, pois o número de entradas precisa ser o mesmo em todas as amostras. Logo, é necessário, também, o uso de alguma estratégia para correção das medições com erros grosseiros, para que a RNA seja capaz de estimar os estados da amostra em questão.

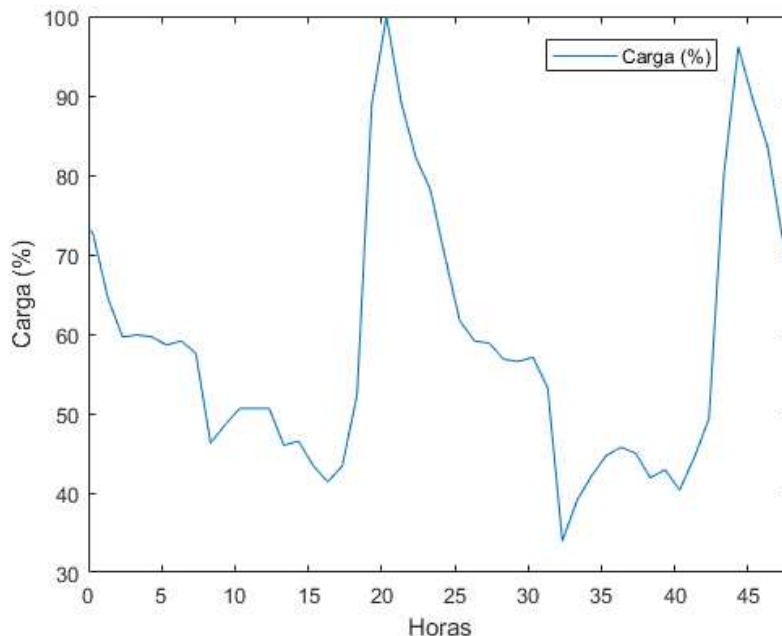
3.5.1 Detecção de Erros Grosseiros

A detecção de erros grosseiros é feita a partir do emprego do algoritmo *Z-Score* [39], descrito na Seção 2.5.2, às amostras de medição considerando a evolução temporal das mesmas. O algoritmo *Z-Score* realiza o cálculo do *score* de uma amostra de medição z , baseado em na média μ_z e desvio padrão σ_z das nz amostras anteriores da mesma medição, conforme a Equação 2.35 anteriormente descrita. O *score* obtido de cada amostra

é comparado com um limite Z_l previamente definido, de modo que este limite seja superior ao *score* obtido com as variações do valor medido observadas durante a operação normal do SDEE.

Para definição do limite Z_l são utilizadas curvas de carga típicas de Sistemas de Distribuição, com amostras obtidas de 10 em 10 minutos de operação. Uma curva de carga exemplo pode ser vista na Figura 10, onde o valor da carga demandada em um barramento, representado pela porcentagem da carga nominal, apresenta, durante 48 horas de operação, sua variação sendo amostrada a cada 10 minutos. A partir das amostras de carga durante as 48 horas de operação, esses percentuais são aplicados às potências nominais dos barramentos, e são criadas amostras de carga do SDEE. As amostras alimentam um Fluxo de Potência, que gera os valores reais dos estados do sistema para cada uma das amostras obtidas. Como a aplicação do *Z-Score* é feita em cima das medições, é necessário o cálculo do Fluxo de Potência das amostras de carga para que seja realizada análise do limite Z_l das medições. É possível, então, traçar um perfil das variáveis medidas nos barramentos do sistema, durante as 48 horas de operação consideradas. A Figura 11 mostra um exemplo do perfil do Módulo de Tensão de um barramento variando sob a operação da curva de carga da Figura 10.

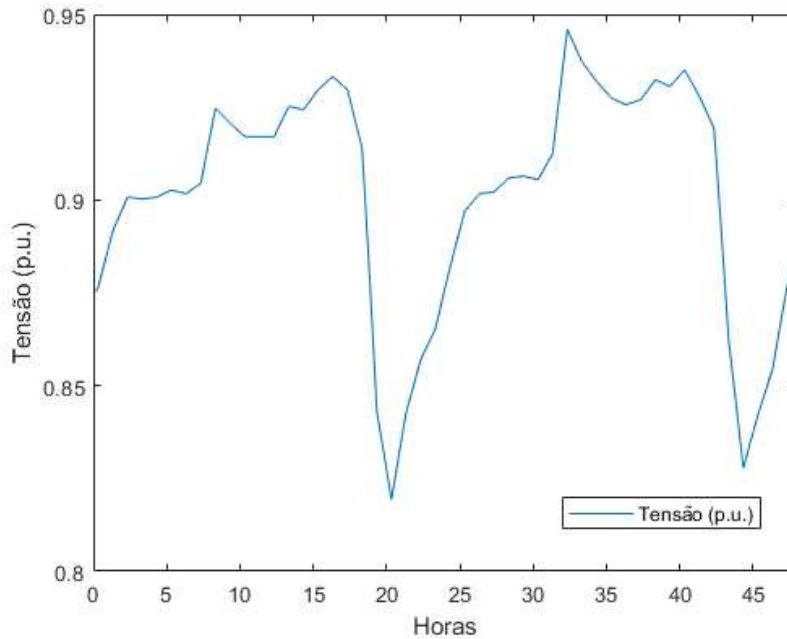
Figura 10 – Exemplo de Curva de Carga em SDEE



Fonte: Elaborado pelo autor (2022)

Este trabalho considera o número de amostras $n_z = 10$, ou seja, cada *score* z é obtido a partir do seu cálculo em relação às 10 amostras anteriores da mesma medição. Dessa forma, como a curva de carga utilizada considera amostras de 10 em 10 minutos de 48 horas de operação, são obtidas 288 amostras de carga. Para aplicação do *Z-Score* com

Figura 11 – Exemplo de Perfil de Tensão em SDEE



Fonte: Elaborado pelo autor (2022)

$nz = 10$, os *scores* podem ser calculados desde a amostra de número 11 até a última, de número 288, pois são necessárias 10 amostras anteriores para o cálculo de sua média e desvio padrão. Para as 278 amostras candidatas, então, é calculado o *score* em relação às 10 amostras anteriores dos estados de todas as barras do sistema, uma vez que qualquer barramento é candidato a receber a alocação de medidores. O maior *score* encontrado apresenta a maior variação observada durante as 48 horas de operação normal do SDEE. Esse valor é, então, acrescido de 20% para criar um margem de erro factível, e assim é determinado o limite Z_l , conforme a Equação 3.15.

$$Z_l = \max(Z) * 1,2 \quad (3.15)$$

A definição do limite Z_l é feita individualmente para cada sistema de teste, de modo que a avaliação do *score* das medições seja calibrada aos níveis de variação presente em cada sistema. Na Seção 4.3.5 os valores dos limites Z_l são determinados para cada um dos sistemas utilizados nos testes da metodologia.

3.5.2 Correção de Erros Grosseiros

A detecção de erros grosseiros é vital para evitar que medidas infectadas por erros de grande magnitude afetem negativamente o processo de Estimação de Estados. Entretanto, apenas a detecção não é suficiente para garantir a qualidade da estimação. Para estimadores baseados em RNA, o número de entradas, ou seja, de medições, precisa

ser constante durante a operação do estimador. Com isso, a medição infectada por erro grosseiro não pode ser apenas descartada, muito menos a amostra como um todo pode ser desaproveitada. É necessário um método para correção dos erros grosseiros, seja de forma direta, gerando uma nova pseudo-medida da própria medição infectada, ou indireta, utilizando outra técnica para estimar os estados da área afetada.

Este trabalho utiliza uma ferramenta indireta para correção dos erros grosseiros, ou seja, não são geradas pseudo-medidas da própria medição com erro grosseiro detectado. Como a metodologia proposta considera cenários de medição onde apenas uma barra é monitorada dentro de uma área, a geração de pseudo-medidas diretas pode ser comprometida caso a única medição disponível seja afetada por erro grosseiro.

A ferramenta de correção indireta compreende o uso de Redes Neurais *Backup* para estimação da área afetada por erros grosseiros. A RNA de uma área consiste em uma RNA previamente treinada, que considera como entradas não os dados de medição da área, mas os estados estimados da barra de fronteira que a área compartilha com sua área vizinha. Como todas as áreas de um SDEE possuem ao menos uma área vizinha, sempre haverá uma barra de fronteira que pode ter seus estados estimados pela área vizinha e que podem ser usados como pseudo-medidas para a RNB da área afetada.

3.5.2.1 Redes Neurais Backup

As Redes Neurais *Backup* utilizadas para estimar os estados da área cuja medição teve erro grosseiro detectado possuem a mesma arquitetura básica que as RNA para estimação local, a *MultiLayer Perceptron*, e são treinadas a partir do algoritmo de treinamento *backpropagation*. As entradas da RNB são os estados, Módulo e Ângulo de Fase, das barras de fronteira, estimados pelas áreas vizinhas à área com medição infectada, além dos estados da chave da própria área. As saídas da RNB são todos os estados das barras contidas na determinada área, assim como para uma RNA de estimação local. O número de neurônios da camada oculta $NNCA_b$ da RNB será, então, dado conforme a Equação 3.16:

$$NNCA_b = \left(\frac{2}{3} * NE_b\right) + NS_b \quad (3.16)$$

Onde NE_b é o número de entradas, dado pelo dobro do número de barras de fronteira NBF mais o número de chaves da área, e NS_b seu número de saídas, dado pelo dobro do número de barras da área:

$$NE_b = 2 * NBF + NSW \quad (3.17)$$

$$NS_b = 2 * NB \quad (3.18)$$

Para áreas com mais de uma barra de fronteira, seja com uma ou mais áreas vizinhas, são utilizados os estados de todas as barras de fronteira, de forma a gerar o máximo de pseudo-medidas possíveis. Como as RNB utilizam dados estimados das barras de fronteira como suas entradas, o seu treinamento não pode ser feito com os mesmos conjuntos de dados gerados para as RNA locais. É necessária a geração de uma nova base de dados, seguindo o mesmo algoritmo descrito na Seção **3.2.1**. Seguindo a alocação de medidores proposta ao sistema de teste em questão, os dados dos estados medidos são aplicados às RNA locais, para geração de uma base de dados de todos os estados estimados pelas RNA de cada área. A partir da base de dados estimados é possível realizar o treinamento das RNB. Para cada área, os dados estimados das barras de fronteiras advindos das áreas vizinhas são alimentados como entradas da RNB, junto aos dados dos seus próprios estados das chaves. As saídas da RNB, como descrito anteriormente, são os estados de todas as barras da área correspondente.

Tomando como princípio a privacidade de dados praticada em SDEE divididos em múltiplas áreas, a metodologia proposta considera tanto o treinamento quanto a operação das RNB como sendo realizado pelo operador central, de modo que as áreas não precisem comunicar entre si os dados dos estados estimados das barras de fronteira, apenas junto ao operador central, o que já é realizado durante a operação normal do Estimador de Estados.

Durante a operação do Estimador, ao passo que uma área detecta um erro grosseiro em suas medições, o evento é sinalizado para o operador central, que se torna responsável pela estimação dos estados desta área. O acionamento das RNB associadas à área em questão é feito pelo próprio operador central, que, de posse dos estados estimados das barras de fronteira, advindos das RNA locais das demais áreas, alimenta-os à RNB da área com erro grosseiro sinalizado. A estimação da área afetada é feita pelo operador central, e utilizada para o sincronismo das estimações locais, para formar a estimação do SDEE completo. O critério de decisão para escolher a estimação mais adequada para as barras de fronteira, descrito na Seção **3.4.1**, não é aplicado nos casos em que a barra de fronteira é utilizada como fonte de pseudo-medidas para a área vizinha. Nestes casos, a estimação feita pela RNB naturalmente carrega mais incertezas, por ter sido feita a partir de dados estimados, e não medidos. É utilizada de forma direta a estimação realizada pela RNA local em operação normal, e descartada a estimação da barra de fronteira feita pela RNB.

3.6 ERROS TOPOLÓGICOS

A aquisição dos dados topológicos de um SDEE compreende o monitoramento dos estados das chaves do sistema, que podem se encontrar abertas ou fechadas. A alteração dos estados dessas chaves é feita de forma programada para reconfigurar o sistema em diferentes topologias, e pode ocorrer durante a operação do SDEE. O monitoramento dos estados das chaves é vital para o funcionamento do Estimador de Estados, pois é a partir

deles que os métodos clássicos como o WLS conseguem realizar os cálculos matriciais e relacionar as medições aos estados calculados do sistema. As RNA também necessitam do monitoramento contínuo dos estados das chaves do sistema para realizar sua estimação com a devida precisão. Esse monitoramento, porém, está sujeito a ocorrência de erros nas informações pertinentes aos estados das chaves. Chaves abertas podem ter seu estado informado como fechado ao Estimador, assim como chaves fechadas podem ser informadas como abertas incorretamente. Esse tipo de erro grosseiro nos estados das chaves é chamado de erro topológico, e precisa ser identificado e corrigido antes do processo de EE para evitar que os erros sejam propagados ao Estimador.

O tratamento dos estados das chaves proposto neste trabalho não contempla duas etapas distintas de detecção de erro e posterior correção dos erros, e sim uma ferramenta única que detecta e corrige os erros em uma só etapa. Para isso, são utilizadas Redes Neurais Hopfield em cada área do SDEE.

3.6.1 Rede Neural Hopfield

As Redes Neurais Hopfield têm como função principal a reconstrução de informações previamente conhecidas durante seu processo de treinamento, a partir de amostras que podem ou não estar contaminadas com erro. Ou seja, as RNH, se utilizadas como processador topológico para corrigir eventuais erros nos estados das chaves, precisam ser acionadas em todas as amostras de estimação, de maneira prévia ao Estimador de Estados em si, para que possam corrigir os erros e entregar os estados corretos ao Estimador.

Para o tratamento via Rede Neural Hopfield, os estados das chaves são tratados de forma binária: +1 para chave fechada e -1 para chave aberta. As RNH são criadas a partir do comando *newhop* do Matlab, que requer que dados binários sejam tratados como +1 e -1, e não como +1 e 0.

A metodologia multi-área deste trabalho considera o uso de uma Rede Neural Hopfield para cada área do SDEE. São utilizadas como entradas de cada RNH os estados de todas as chaves contidas dentro de cada área, além dos estados das chaves que conectam a área considerada com áreas vizinhas. A consideração dessas chaves de fronteira entre áreas é vital para que topologias diferentes possam ser diferenciadas posteriormente pela RNA de Estimação local.

O treinamento das RNH é realizado apresentando à rede somente os padrões de entrada corretos. No caso da aplicação deste trabalho, são apresentados à rede os estados das chaves que compõe cada uma das topologias viáveis e consideradas durante a operação do SDEE. A Rede Neural Hopfield, ao ser alimentada com os padrões corretos de entrada durante seu treinamento, é capaz de memorizar esses padrões, e guardá-los para reconstrução durante a operação.

Durante a operação, as RNH são alimentadas com os estados das chaves monitoradas

em sua área, e o processo de reconstrução de informações é encarregado de comparar as entradas atuais com os padrões memorizados durante o treinamento. Para o caso de os estados das chaves estarem corretamente monitorados e alimentados à RNH, a rede compreende os padrões de entrada como sendo idêntico a um dos padrões corretos de seu treinamento, e não realiza nenhum ajuste nos estados das chaves para produzir a saída. Dessa forma, é possível garantir que dados corretos não serão indevidamente alterados pela Rede Neural Hopfield durante a operação do estimador, e possibilita o acionamento da rede sem necessidade de uma etapa prévia de detecção de erro topológico.

As saídas de uma Rede Neural Hopfield são as próprias entradas aplicadas à rede, sendo estas ajustadas, em caso de desacordo com os padrões previamente conhecidos no treinamento, ou mantidas, em caso de a entrada ser um dos padrões corretos conhecidos. Para o ajuste dos estados das chaves alimentadas à RNH, existe o parâmetro de *time steps*, que determina quantas iterações de ajuste dos pesos sinápticos serão realizadas até gerar a resposta final para uma amostra. Esse parâmetro, para as aplicações de correção de estados das chaves deste trabalho, foi fixado em 20 *time steps*, que se mostrou um número suficiente de iterações para corrigir os erros topológicos de todos os sistemas de testes utilizados. Os estados das chaves incorretas alteradas na saída de uma Rede Neural Hopfield muitas vezes não são alterados para os valores inteiros de +1 e -1 que representam os estados. É comum que as saídas, por imprecisões matemáticas do programa Matlab, sejam números muito próximos a esses valores, com diferenças nas casas decimais que representam a precisão de cálculo do programa. Para contornar eventuais problemas numéricos, então, é realizado o arredondamento dos valores de saída, para que sejam sempre +1 ou -1, conforme:

- $S'_g = +1$, se $S_g \geq 0$
- $S'_g = -1$, se $S_g < 0$

Onde S_g representa o estado de saída da chave S em um neurônio g da Rede Neural Hopfield, e S'_g o valor final arredondado do estado da chave, que segue para o Estimador de Estados.

3.7 ALGORITMO PROPOSTO

O algoritmo proposto neste trabalho consiste em um modelo de Estimação de Estados de SDEE a partir de Redes Neurais Artificiais, aliado a métodos de detecção de erros grosseiros e correção de erros topológicos. A algoritmo considera a divisão do SDEE em diferentes áreas, sendo cada área responsável por realizar sua própria detecção de erros grosseiros e sua estimacão. Os estados estimados por cada área são unidos pelo controlador central, responsável por criar a estimacão do SDEE completo, juntando os

estados estimados de cada área, e aplicando um critério de sincronismo para definir a estimação mais apropriada para as barras que contemplam uma fronteira entre diferentes barras.

O algoritmo proposto pode ser resumido pelo fluxograma da Figura 12 e pelos passos abaixo:

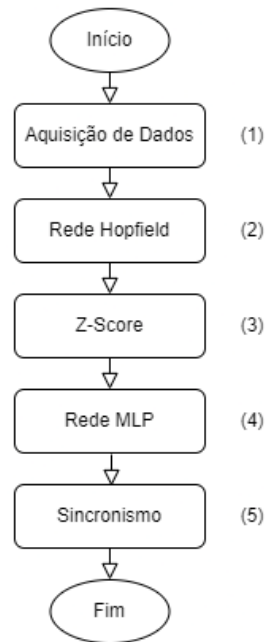
1. **Aquisição de dados:** Os estados das chaves e as medições elétricas de cada área são obtidos a partir do sistema de aquisição de dados;
2. **Análise de erros topológicos:** Os estados das chaves são alimentados às Redes Neurais Hopfield de cada área, a fim de corrigir erros topológicos presentes nos estados das chaves monitoradas;
3. **Detecção de erros grosseiros:** O algoritmo *Z-Score* é aplicado a cada medição elétrica de cada área, a fim de detectar erros grosseiros nas medições;
4. **Estimação Multi-Área:** As Redes *MLP* de cada área são alimentadas pelas medições elétricas e pelos estados das chaves para gerar a estimação dos estados da área. Caso alguma área tenha erro grosseiro detectado em alguma de suas medições elétricas, a RNA de estimação desta área não é acionada, e a estimação é feita pela Rede Neural *Backup* no nível seguinte de sincronismo;
5. **Sincronismo:** As estimações de todas as áreas são unidas para formar a estimação do SDEE completo. Em barras de fronteira entre duas áreas, é aplicado o critério de decisão para definir sua estimação mais adequada. Caso alguma área tenha erro grosseiro detectado em alguma de suas medições elétricas, a devida RNB é acionada para estimar os estados da área a partir das estimações da área vizinha.

Importante notar que os passos 1-4 são realizados a nível de estimação local de cada área, enquanto apenas o passo 5 de sincronismo é feito em nível centralizado de operação, no qual são reunidas todos os dados estimados pelos operadores de cada área. As Redes Neurais *Backup*, apesar de realizarem estimação por área, são controladas pelo operador central, pois é necessária a troca de dados estimados entre as áreas para que elas sejam capazes de estimar os estados a partir das pseudo-medidas geradas pelas áreas vizinhas. O tráfego de informações é simplificado ao se considerar apenas o envio de dados dos operadores locais para o operador central, que aciona as RNB em caso de erro grosseiro detectado por alguma das áreas.

3.8 CONCLUSÕES PARCIAIS

Neste capítulo, foi apresentado o estimador multi-área proposto para Sistemas de Distribuição de Energia Elétrica. A descrição da metodologia contempla desde a geração

Figura 12 – Fluxograma do Algoritmo Proposto



Fonte: Elaborado pelo autor (2022)

dos cenários de carga e o tratamento das medições consideradas, culminando nas Redes Neurais Artificiais utilizadas para estimação em área, e na forma como os estados das chaves são utilizados como fonte de informação acerca da topologia atual do SDEE.

Além disso, a metodologia proposta conta com a incorporação de técnicas já existentes na literatura, como o algoritmo *Z-Score* [39] e as Redes Neurais Hopfield [54] para detecção e correção de erros grosseiros, respectivamente, nas medições elétricas e no monitoramento dos estados das chaves do sistema.

4 RESULTADOS

As análises utilizadas para avaliar a metodologia de Estimação de Estados proposta são realizadas em três sistemas de teste, sendo eles o Sistema IEEE 33 barras [56], o Sistema IEEE 119 barras [52] e um sistema real brasileiro de 476 barras. Para cada um dos sistemas, diferentes topologias são consideradas para a geração de cenários, treinamento e teste das RNA de estimação. Os dados acerca das informações sobre as conexões entre as barras formadas por cada chave do sistema, as chaves abertas em cada topologia testada e a identificação das barras e chaves pertencentes a cada área estão presentes em [57]. Também estão lá dispostas as amostras das variáveis elétricas geradas em cada cenário para os dados de treinamento e teste das RNAs. Importante notar que este trabalho não apresenta uma metodologia de divisão dos sistemas em áreas. Logo, a divisão em áreas realizada é baseada em aspectos de conexão dos sistemas, e visa apenas simular uma possível divisão dos sistemas em diferentes áreas. Os dados relativos aos sistemas, e às suas respectivas topologias e áreas estão presentes na Seção 4.1.

4.1 SISTEMAS DE TESTE


4.1.1 Sistema IEEE 33 Barras

O Sistema IEEE 33 barras [56], composto por 33 barras e 37 linhas, pode ser visto na Figura 13. Todas as 37 linhas do sistema contém chaves manobráveis, ou seja, pode ser abertas ou fechadas. O sistema possui apenas um alimentador principal saindo da subestação. O sistema foi dividido em quatro áreas, como pode ser visto na Figura 14. Uma PMU é alocada na última barra de cada área, de modo a garantir que a RNA de cada área tenha medições para realizar a estimação. As barras com alocação das PMUs podem ser consultadas na Tabela 5. A Tabela 1 traz as informações acerca de quais são as barras, chaves e chaves de fronteira contidas em cada uma das quatro áreas do sistema.

Três diferentes topologias são consideradas para este sistema, estando as chaves abertas de cada uma delas descritas na Tabela 2. A topologia 1 representa a configuração original do sistema, enquanto as demais são topologias ótimas encontradas por [58], que minimizam as perdas elétricas no sistema. A Figura 15 traz a reconfiguração do sistema considerando a terceira topologia da Tabela 2. Nela, é possível notar, por exemplo, que a barra 32 já não está mais eletricamente conectada ao restante da área A_4 , como acontecia na topologia original do sistema, mas sim a partes da área A_3 . Entretanto, as medições provenientes do medidor alocado na barra 32 ainda são utilizadas para estimar os estados das barras da área A_4 , pois, durante o treinamento da RNA responsável pela estimação da área A_4 , as medições da barra 32 estão associadas aos estados das barras da A_4 , ainda que elas não estejam mais eletricamente conectadas em uma diferente topologia. Essa capacidade é obtida pois a topologia variante em questão foi considerada durante o

treinamento da RNA, que está habilitada a reconhecer os padrões entre medições e estados desse tipo de cenário.

Figura 13 – Sistema IEEE 33 barras



Fonte: Baran e Wu (1989)

Tabela 1 – Dados do Sistema 33 barras

Área	Barras	Chaves	Chaves de Fronteira
1	0, 1, 2, 22, 23, 24	$S_1, S_2, S_{22}, S_{23}, S_{24}$	S_{37}
2	1, 18, 19, 20, 21	$S_{18}, S_{19}, S_{20}, S_{21}$	S_{33}, S_{35}
3	2, 3, ... , 16, 17	$S_3, S_4, \dots, S_{16}, S_{17}$	$S_{33}, S_{34}, S_{35}, S_{36}$
4	5, 25, 26, ... , 31, 32	$S_{25}, S_{26}, \dots, S_{31}, S_{32}$	S_{36}, S_{37}


Tabela 2 – Topologias do Sistema 33 barras

Topologia	Chaves Abertas
1	$S_{33}, S_{34}, S_{35}, S_{36}, S_{37}$
2	$S_7, S_{10}, S_{14}, S_{32}, S_{37}$
3	$S_7, S_9, S_{14}, S_{32}, S_{37}$

4.1.2 Sistema IEEE 119 Barras

O Sistema IEEE 119 barras [52] contém 119 barras e 132 linhas, e todas as linhas possuem chaves manobráveis. O sistema pode ser visto na Figura 16 em sua forma original. A divisão do sistema é feita em três áreas, cada uma contemplando um dos três

Figura 14 – Áreas do Sistema IEEE 33 barras



Fonte: Baran e Wu (1989) - Modificado

alimentadores que saem da subestação, e esta divisão está representada na Figura 17. Novamente, uma PMU é alocada em cada uma das áreas do sistema, conforme consta na Tabela 5 contendo as barras com alocação de PMU em cada sistema. Cinco topologias são consideradas para o sistema de 119 barras, conforme a Tabela 3. A primeira consiste na configuração original, e as topologias 2-5 são topologias otimizadas para minimização de perdas, encontradas por [58].

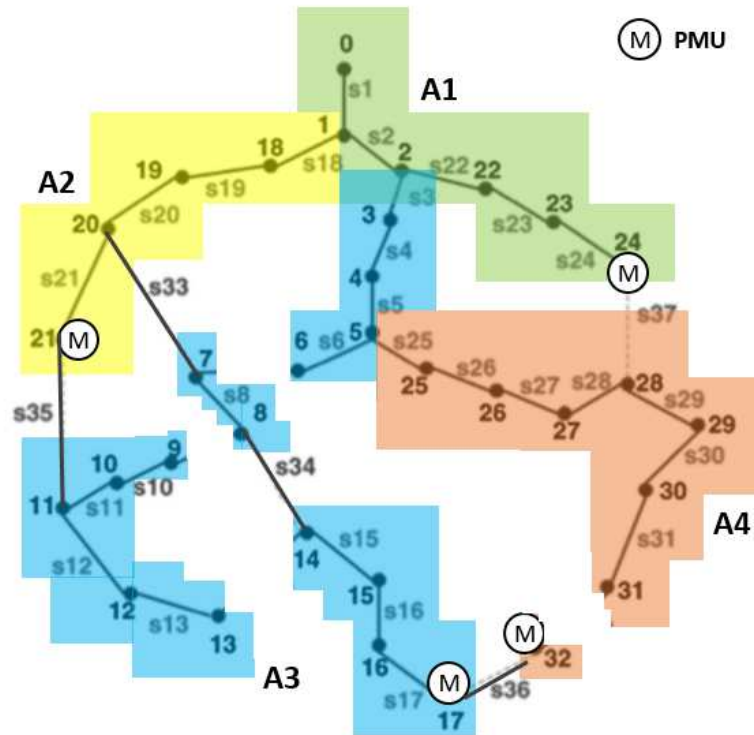
Tabela 3 – Topologias do Sistema 119 barras

Topologia	Chaves Abertas
1	$S_{118}, S_{119}, S_{120}, S_{121}, \dots, S_{129}, S_{130}, S_{131}, S_{132}$
2	$S_{23}, S_{26}, S_{34}, S_{39}, S_{42}, S_{51}, S_{58}, S_{71}, S_{74}, S_{95}, S_{98}, S_{109}, S_{122}, S_{129}, S_{130}$
3	$S_{23}, S_{25}, S_{34}, S_{39}, S_{42}, S_{50}, S_{58}, S_{71}, S_{74}, S_{95}, S_{97}, S_{109}, S_{121}, S_{129}, S_{130}$
4	$S_{23}, S_{25}, S_{34}, S_{39}, S_{42}, S_{50}, S_{58}, S_{70}, S_{73}, S_{76}, S_{95}, S_{109}, S_{121}, S_{129}, S_{130}$
5	$S_{23}, S_{25}, S_{34}, S_{39}, S_{42}, S_{50}, S_{61}, S_{71}, S_{73}, S_{76}, S_{82}, S_{109}, S_{121}, S_{125}, S_{130}$

4.1.3 Sistema Real Brasileiro de 476 Barras

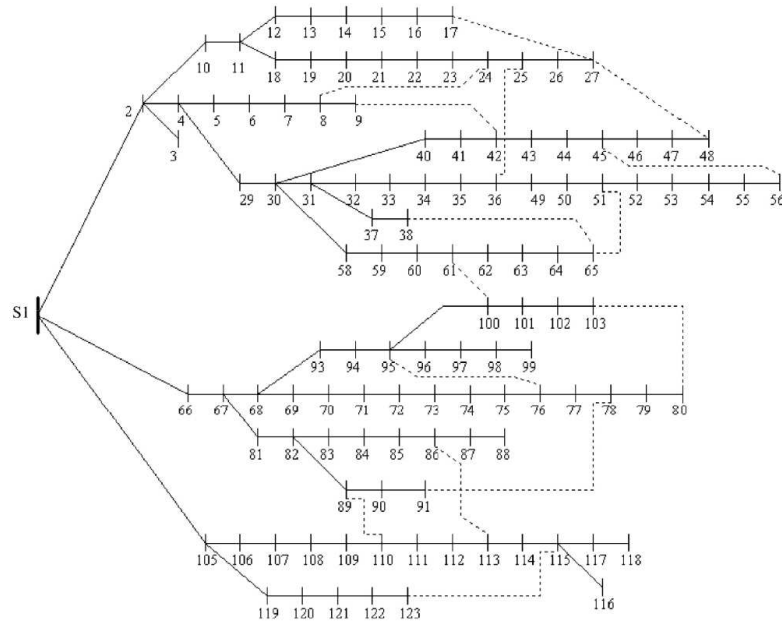
O sistema de 476 barras é um sistema real brasileiro, que é constituído de dois alimentadores saindo da subestação. O sistema contém 476 barras e 479 linhas, sendo apenas 98 das linhas contempladas por chaves manobráveis. Cada um dos alimentadores é

Figura 15 – Variação de topologia do Sistema IEEE 33 barras



Fonte: Baran e Wu (1989) - Modificado

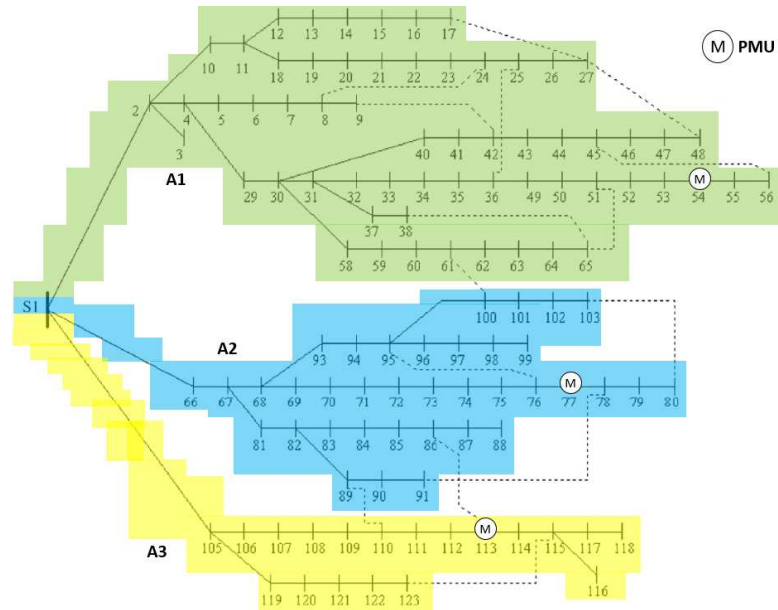
Figura 16 – Sistema IEEE 119 barras



Fonte: Zhang (2008)

dividido em três áreas, como é apresentado pelas Figuras 18 e 19. Três topologias diferentes são consideradas, e as chaves abertas de cada configuração podem ser consultadas na

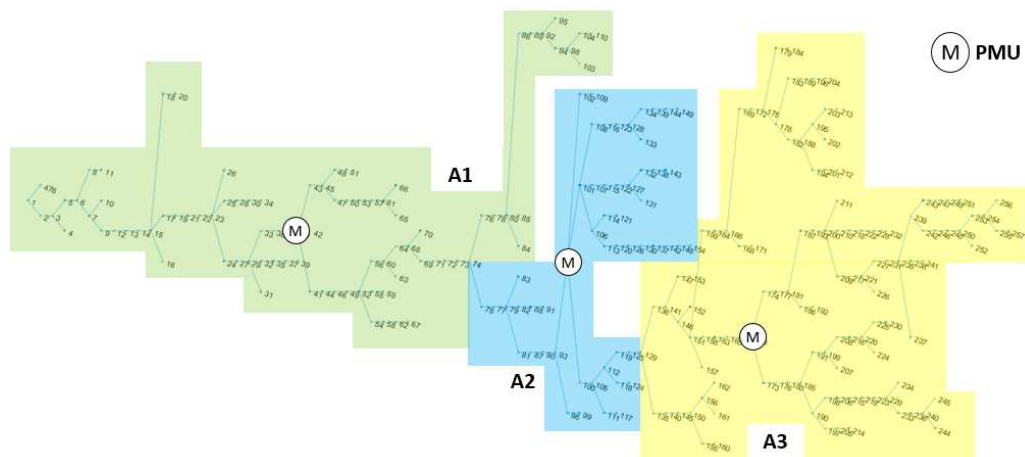
Figura 17 – Áreas do Sistema IEEE 119 barras



Fonte: Zhang (2008) - Modificado

Tabela 4. A primeira topologia representa a configuração original do sistema, e as demais são topologias otimizadas para minimizar perdas elétricas, encontradas por [58]. Uma PMU é alocada em cada área do sistema, e as barras de alocação estão presentes na Tabela 5.

Figura 18 – Áreas do Primeiro Alimentador do Sistema de 476 barras

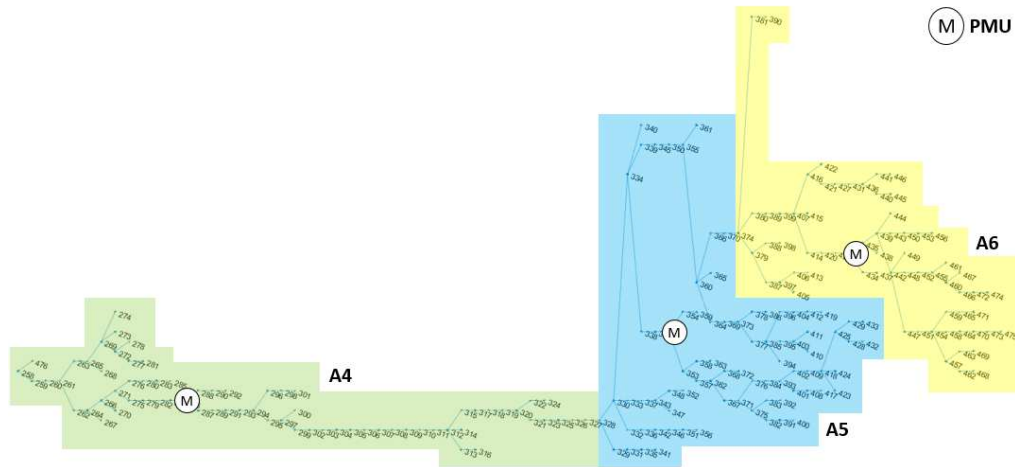


Fonte: Elaborado pelo Autor

4.2 ANÁLISES PROPOSTAS

A avaliação principal do Estimador de Estados proposto neste trabalho consiste em testes considerando as variações operacionais de estimação realizada por um estimador

Figura 19 – Áreas do Segundo Alimentador do Sistema de 476 barras



Fonte: Elaborado pelo Autor

Tabela 4 – Topologias do Sistema 476 barras

Topologia	Chaves Abertas
1	$S_{476}, S_{477}, S_{478}, S_{479}$
2	$S_{90}, S_{476}, S_{477}, S_{479}$
3	$S_{46}, S_{477}, S_{478}, S_{479}$

centralizado ou por múltiplos estimadores em áreas do sistema, além da possibilidade de reconfiguração do sistema a partir de variações topológicas dos sistemas de teste. Dessa forma, são propostas quatro análises iniciais, contemplando as variações operacionais descritas anteriormente:

- **Análise-1:** RNA centralizada para estimação de todas as barras do sistema, sem variações topológicas. As condições da análise permitem comparação direta com os algoritmos de estimação *WLS* [5] e *E-OPF* [14] da literatura;
- **Análise-2:** Estimação descentralizada a partir de RNA Multi-Área, sem variações topológicas;
- **Análise-3:** RNA centralizada para estimação de todas as barras do sistema, com variações topológicas;
- **Análise-4:** Estimação descentralizada a partir de RNA Multi-Área, com variações topológicas. Esta análise consiste no algoritmo proposto por este trabalho para realização da estimação de SDEE.

Este trabalho não inclui em sua metodologia uma técnica para alocação de medidores. Por se tratar de um trabalho de Estimação de Estados, os sistemas de teste são considerados já em operação, com os medidores previamente alocados, sendo um medidor

por área, de modo a garantir a observabilidade mínima de cada área. Para as quatro análises descritas anteriormente, a alocação prévia de medidores considerada é conforme consta na Tabela 5, sendo todos os medidores do tipo *PMU*, que realizam medições de Módulo e Ângulo de Fase de tensão.

Tabela 5 – Alocação de PMUs para os sistemas de teste

Sistema	Barras Medidas
33 barras	17, 21, 24, 32
119 barras	54, 77, 113
476 barras	38, 97, 170, 286, 349, 430

A fim de avaliar a eficácia da metodologia de estimação para casos em que o SDEE não conta com medições fasoriais em alguns pontos, no caso, com a presença de Medidores Inteligentes, que medem apenas Módulo de Tensão, outra análise posterior é proposta. Esta nova análise consiste na alocação de Medidores Inteligentes nos mesmos pontos onde haviam *PMUs*, conforme a Tabela 5. A avaliação é feita conforme a Análise-4, considerando estimação multi-área e variações topológicas.

O impacto de erros grosseiros de medição e de estados de chaves é outro aspecto avaliado mediante simulações de cenários contendo tais erros em medições aleatórias. Não obstante, a técnica de detecção de erros grosseiros de medições, via *Z-Score*, é aplicada aos cenários de teste, de modo a identificar cenários com erros grosseiros, e acionar a estimação via Redes Neurais *Backup*, a fim de evitar que a estimação seja realizada a partir de dados contaminados por erros de grande magnitude.

4.3 RESULTADOS

As simulações realizadas para gerar os resultados apresentados nesta seção foram feitas no programa *Matlab*, a partir de uma máquina Intel(R) Core(TM) i3-3110M, processador CPU 2.40GHz, com 8GB de RAM.

4.3.1 Análises Principais

As análises principais, contemplando Análise-1 até Análise-4, descritas na Seção 4.2, foram aplicadas aos três sistemas de teste considerados: sistema IEEE 33 barras, sistema IEEE 119 barras, e o sistema real brasileiro de 476 barras.

4.3.1.1 Tempo Computacional

A Análise-1, que considera estimação centralizada sem variações topológicas permite comparação direta com os algoritmos de estimação WLS e E-OPF. Portanto, para cada sistema, é preciso avaliar o tempo computacional requerido para se obter uma amostra de estimação desses sistemas, de modo que esse tempo possa ser comparado com o tempo de

amostra do estimador proposto. A Tabela 6 traz os tempos necessários para amostra de estimação dos dois estimadores citados acima em cada um dos três sistemas de teste, além de uma amostra da RNA já treinada proposta para a Análise-1. Importante notar que ambos os algoritmos iterativos WLS e E-OPF de estimação utilizados para comparação foram inicializados com *flat start*, ou seja, com módulos de tensão fixados em 1 p.u. e ângulos de fase de tensão fixados em 0 rad para todas as barras dos sistemas.

Tabela 6 – Tempo computacional de estimação

Sistema	WLS	E-OPF	RNA
33 barras	0,3704s	6,0255s	0,0907s
119 barras	0,8061s	17,1741s	0,1291s
476 barras	25,6540s	368,6809s	0,1301s

A partir destes resultados, é possível notar a vantagem de se utilizar RNA para estimação no que tange o tempo de resposta para uma amostra. A RNA pode entregar o resultado da estimação em tempo para operação em tempo real dos sistemas, enquanto os demais métodos requerem um tempo excessivo para sistemas de maior porte, o que pode inviabilizar seu uso para operação em tempo real.

Importante ressaltar que este tempo computacional não é o tempo esperado para amostra durante a operação de um estimador prático, pois tal estimador estaria alocado em uma máquina de capacidade superior a máquina utilizada nestas simulações. O intuito da apresentação desses tempos é puramente para comparação da velocidade de estimação entre os métodos encontrados na literatura, e o método proposto.

Considerando o treinamento das RNA propostas, que é efetuado previamente à operação do estimador, ou seja, não impacta no tempo de respostas das amostras, a Tabela 7 traz o tempo total de treinamento das RNA de cada uma das quatro análises principais para os sistemas de teste.

Tabela 7 – Tempo de Treinamento das RNA

Análise	33 barras	119 barras	476 barras
Análise-1	18,3681s	18,6495s	1686,1482s
Análise-2	34,5691s	29,4578s	436,4519s
Análise-3	151,8554s	794,5592s	2334,9721s
Análise-4	41,9447s	603,8790s	3681,8506s

A partir desses dados, é possível aferir que o tempo de treinamento das RNA tende a ser grande para sistemas de maior porte. Entretanto, este treinamento é feito previamente, como explicado anteriormente, e a sua duração não impacta o desempenho computacional das RNA durante a operação como estimadores.

4.3.1.2 Resultados das Análises

Os resultados para as quatro principais análises estão presentes nas Tabelas 8, 9 e 10, respectivamente para os sistemas IEEE 33 barras, IEEE 119 barras, e o sistema brasileiro de 476 barras. Para obtenção das métricas apresentadas nas tabelas, foram estimados todos os cenários de teste gerados para cada sistema, a partir das medições alocadas. Os estados estimados foram, então, comparados, após as etapas de sincronismo, com os valores reais dos estados, obtidos previamente a partir de Fluxos de Potência para cada um dos cenários de teste. A partir desses cenários, foi calculada a média \hat{x} e o desvio padrão σ das métricas EEE obtidas, de forma que se possa avaliar o comportamento médio do estimador, obtendo, também, uma medida de dispersão dos resultados encontrados.

Tabela 8 – Análises para o sistema IEEE 33 barras

Análises	EEE(%)			
	1	2	3	4
RNA (\hat{x})	3.4919	1.4935	3.9256	2.3092
RNA (σ)	0.3456	0.3240	0.5155	0.5548
WLS	2.6007	—	—	—
E-OPF	2.1742	—	—	—

Tabela 9 – Análises para o sistema IEEE 119 barras

Análises	EEE(%)			
	1	2	3	4
RNA (\hat{x})	2.2568	2.0716	3.1715	2.8925
RNA (σ)	0.3134	0.2858	0.8166	0.6472
WLS	5.2905	—	—	—
E-OPF	4.3505	—	—	—

Tabela 10 – Análises para o sistema de 476 barras

Análises	EEE(%)			
	1	2	3	4
RNA (\hat{x})	8.7918	7.1064	14.6035	8.6020
RNA (σ)	0.9173	0.7401	2.1389	0.2250
WLS	9.4379	—	—	—
E-OPF	8.4856	—	—	—

A partir dos resultados das Tabelas 8, 9 e 10, é possível aferir que a metodologia de estimação centralizada com a RNA da Análise-1 apresenta, em média, resultados compatíveis com aqueles obtidos utilizando os métodos *WLS* e *E-OPF*. O valor médio da métrica EEE para a RNA da Análise-1 foi levemente superior a dos outros métodos para os sistemas de 33 e de 476 barras, e foi consideravelmente inferior para o sistema

de 119 barras. Com resultados de estimação semelhantes aos dos métodos clássicos, além do rápido tempo de resposta, a viabilidade do uso de Redes Neurais para estimação de sistema de forma centralizada é demonstrada a partir dos resultados da Análise-1 para os três sistemas de teste considerados.

Tomando os resultados obtidos pela estimação centralizada via RNA da Análise-1, é possível comparar os resultados com o uso de RNA Multi-Área, cujos resultados estão apresentados na Análise-2. Para todos os sistemas de teste, as RNA Multi-Área da Análise-2 apresentaram menor valor médio da métrica EEE quando comparadas diretamente com os resultados da RNA Centralizada da Análise-1. A divisão do SDEE em áreas acarreta na criação de múltiplas RNA menores, cujo processamento numérico é mais simples do que o de uma única RNA Centralizada para todo o SDEE. Importante notar, também, que a estimação Multi-Área da Análise-2 gerou métricas EEE , em média, inferiores a ambos os métodos WLS e $E-OPF$. Esses resultados comprovam a validade de se realizar a estimação Multi-Área com RNA para sistemas com topologia única.

Para avaliar o efeito de variações topológicas nos sistemas de teste, a Análise-3 apresenta os resultados da RNA Centralizada, e a Análise-4 das RNA Multi-Área com diferentes topologias sendo consideradas, e com os estados das chaves sendo alimentados como entradas das RNA. Comparando diretamente a Análise-3 com a Análise-1, é possível perceber como a introdução de novas topologias tende a aumentar o erro de estimação da RNA Centralizada, uma vez que aumenta não apenas o número de cenários a serem mapeados durante o treinamento das RNA, mas também apresenta novos padrões de queda de tensão, aumentando a complexidade do problema. O mesmo ocorre para as RNA Multi-Área da Análise-4 em comparação com as da Análise-2.

Comparando, entretanto, o Estimador Multi-Área da Análise-4, com o Estimador Centralizado da Análise-3, é possível observar a melhor qualidade de estimação da metodologia Multi-Área quando os SDEE estão em uma operação passível de variações topológicas. Essa condição, que é muito comum em Sistemas de Distribuição, acarreta em uma maior complexidade no problema de estimação a ser enfrentado pelas RNA, e os resultados obtidos indicam que o uso de múltiplas RNA em áreas diferentes do SDEE gera resultados melhores na estimação do sistema.

4.3.2 Análise com Medidores Inteligentes

A avaliação da Estimação de Estados a partir de Medidores Inteligentes é realizada a partir da alocação de tais medidores nos mesmos barramentos onde estão alocadas as PMUs, conforme a Tabela 5. Esta análise visa avaliar a capacidade de estimação da metodologia proposta em sistemas que não contam com medições fasoriais, ou seja, a partir da medição de apenas Módulos de Tensão. Para efeitos de comparação direta, os testes com Medidores Inteligentes são realizando considerando a estimação multi-área

com variações topológicas, referente à Análise-4 deste trabalho. Dessa forma, a Tabela 11 traz os resultados de média \hat{x} e desvio padrão σ das métricas *EEE* de estimação para os três sistemas de teste, comparando os resultados da Análise-4, contendo medições via PMUs, com a estimação via Medidores Inteligentes. É possível avaliar, a partir dos valores da tabela, que a substituição de PMUs por MIs acarreta em um aumento nas métricas de estimação, o que é esperado, uma vez que os novos medidores testados não apenas entregam menos dados à RNA de estimação, mas também apresentam uma maior incerteza associada a precisão das medições.

É importante, entretanto, avaliar visualmente o que ocorre nas estimações, especialmente nas estimações de Ângulo de Fase de Tensão, pois este estado não é medido pelos MIs. Para isso, as Figuras 20 e 21 trazem, respectivamente, os Módulos e Ângulos de Fase de Tensão reais e estimados para um mesmo cenário considerando as RNA com medição via PMU e MIs para o Sistema IEEE 33 barras. É possível perceber que o uso dos MIs causa, de fato, um maior distanciamento dos valores estimados em relação aos valores reais, como sugerido pelo aumento da métrica *EEE*. Porém, a avaliação visual da estimação dos Ângulos de Fase de Tensão via MIs é de suma importância para validar a possibilidade de se utilizar a metodologia proposta ainda que não estejam disponíveis medições fasoriais, uma vez que a curva de Ângulos de Fase de Tensão estimados permanecem aderentes aos valores reais.

De forma análoga, as Figuras 22 e 23 mostram os estados estimados de um mesmo cenário com PMUs e MIs para o Sistema IEEE 119 barras, e as Figuras 24 e 25 o fazem para o Sistema 476 barras. É possível notar que o mesmo padrão ocorrido no Sistema IEEE 33 barras se mantém para os demais sistemas, pois há um maior distanciamento das curvas estimadas a partir de MIs em relação aos valores reais, quando as estimações são comparadas diretamente com as feitas a partir de PMUs, porém, novamente, as curvas de Ângulos de Fase de Tensão estimados se mantêm aderentes aos estados reais, ainda que não haja medição desses ângulos por parte dos Medidores Inteligentes.

Tabela 11 – Comparação de Estimação com Medidores Inteligentes

Medidores	Sistema		
	33 barras	119 barras	476 barras
MIs			
<i>EEE</i> (\hat{x})(%)	2,3954	3,4852	11,1204
<i>EEE</i> (σ)(%)	0,9205	0,8362	1,8103
PMUs	33 barras	119 barras	476 barras
<i>EEE</i> (\hat{x})(%)	2,3092	2,8925	8,6020
<i>EEE</i> (σ)(%)	0,5548	0,6472	0,2250




Figura 20 – Estimativa do Módulo de Tensão do Sistema 33 barras com Comparação entre Medidores.




Figura 21 – Estimativa do Ângulo de Tensão do Sistema 33 barras com Comparação entre Medidores

4.3.3 Análise de Mínima Tensão

Um fator chave para operação segura de SDEE é a análise de mínima tensão, isto é, manter o monitoramento atencioso sobre o barramento com a tensão mais baixa do sistema. A fim de obter uma observação deste fator com a metodologia de estimação




Figura 22 – Estimação do Módulo de Tensão do Sistema 119 barras com Comparação entre Medidores




Figura 23 – Estimação do Ângulo de Tensão do Sistema 119 barras com Comparação entre Medidores

proposta, foram realizados os cálculos de erro de estimação da menor tensão de cada sistema, em relação ao valor real do cenário obtido pelos Fluxos de Potência. A Tabela 12 mostra, para cada sistema de teste, os resultados para a amostra com menor tensão, o barramento onde ocorre, o valor real da tensão, e seu valor estimado, ambos valores de




Figura 24 – Estimação do Módulo de Tensão do Sistema 476 barras com Comparação entre Medidores




Figura 25 – Estimação do Ângulo de Tensão do Sistema 476 barras com Comparação entre Medidores

módulo em p.u.. O erro de estimação apresentado na tabela é o valor absoluto percentual do erro calculado a partir do valor real da tensão no barramento. A partir dos valores de erro percentual, é possível avaliar os erros como aceitáveis, a depender dos requisitos do operador. Os valores estimados considerados nesta análise são os obtidos a partir das

RNA de Estimação Multi-Área da Análise-4, que compreende a metodologia final proposta neste trabalho.

Tabela 12 – Resultados da Análise de Mínima Tensão

Sistema	Barra	Mínima Tensão (p.u.)		
		Real	Estimado	Erro (%)
33 barras	17	0,7781	0,7911	1,6678
119 barras	77	0,8466	0,8531	0,7691
476 barras	213	0,9352	0,9491	1,4863

4.3.4 Análise de Erros Topológicos

A ocorrência de erros topológicos durante a operação de um SDEE é considerada neste trabalho a partir de erros singulares de chaveamento, isto é, apenas uma chave monitorada apresentando erro no seu estado. Dada a baixa probabilidade da ocorrência desses erros, a eventual ocorrência de múltiplos erros simultâneos é descartada. Desta forma, um primeiro teste de acurácia das Redes Neurais Hopfield é realizado, a fim de avaliar quantos dos possíveis cenários de chaveamento com erro a RNH é capaz de recuperar corretamente. Cenários corretamente restaurados são considerados como sucessos, enquanto cenários nos quais as saídas da RNH não condiz com a real configuração das chaves no momento são considerados como falhas de atuação da Rede Neural Hopfield.

A Tabela 13 traz a taxa de sucesso percentual para cada sistema de teste, além do número casos testados, que representa o número de chaves manobráveis de cada sistema que tiveram seu estado alterado separadamente. Para os Sistemas IEEE 33 e 119 barras, todas as linhas contém chaves manobráveis, já para o Sistema de 476 barras, apenas 98 das 479 linhas do sistema apresentam chaves manobráveis. É possível avaliar que a Rede Neural Hopfield é capaz de recuperar a topologia correta na vasta maioria dos casos de erro de chaveamento. Além disso, é possível perceber que os sistemas de maior porte tendem a ter desempenho melhor na taxa de sucesso da correção topológica, o que é esperado, uma vez que redes maiores contém mais chaves, resultado num vetor de estados de chaves maior e que sofre menor impacto por um único estado incorreto.

Tabela 13 – Taxa de Sucesso de Correção de Erros Topológicos

Sistema	Taxa de Sucesso (%)	Casos Testados
33 barras	93,33	37
119 barras	98,68	132
476 barras	99,17	98

Para atestar a importância de se realizar a correção de eventuais erros topológicos, foram realizados testes com erros topológicos a partir dos mesmos cenários gerados e

aplicados às análises principais do trabalho. Duas novas condições foram aplicadas, gerando novos testes:

- **Teste-1:** Erro topológico singular em 100% das amostras de teste;
- **Teste-2:** Erro topológico singular em 10% das amostras de teste.

O valor de 100% das amostras infectadas visa demonstrar o real impacto dos erros topológicos sobre todas as amostras de teste e seu impacto nas métricas de estimação. Já o teste com 10% das amostras de teste contaminadas com erro topológico foi escolhido para retratar uma avaliação conservadora sobre a metodologia, por se tratar de um valor muito superior a probabilidade de ocorrência de um erro no monitoramento do estado de uma chave.

A Tabela 14 mostra os valores de média e desvio padrão da métrica *EEE* em cada teste, com e sem a aplicação da Rede Neural Hopfield para correção dos estados das chaves, além do resultado prévio da Análise-4 para comparação direta com um caso sem consideração de erros topológicos. É possível ver uma expressiva diferença entre as métricas do Teste-1, que considera erros topológicos em todas as amostras, em relação ao Teste-2, com erros em 10% das amostras, nos casos em que não há correção via RNH. Além disso, os resultados de ambos os testes quando há aplicação da RNH se aproximam das métricas obtidas na Análise-4, o que demonstra a eficácia do método para impedir que erros topológicos afetem diretamente o resultado das estimações durante a operação de um SDEE.

Uma representação visual da estimação dos estados do Sistema IEEE 33 barras com erro topológico é apresentada pela Figura 26. No caso apresentado, estão presentes os valores reais e estimados de Módulo de Tensão para todo o sistema, sendo os valores estimados obtidos em uma avaliação com erro topológico não corrigido pela Rede Neural Hopfield, e outra avaliação estimada com correção via Rede Neural Hopfield. O erro de chaveamento analisado é da chave S_9 . É possível avaliar o grande desvio entre os valores estimados sem correção via RNH em relação aos valores reais e estimados com correção. Importante notar que o impacto do erro topológico ocorre apenas nas barras contidas dentro da área $A3$, que contempla das barras 3 até a 17. Como a estimação é realizada separadamente entre áreas, o erro topológico da área $A3$ não afeta as estimações das barras das demais áreas do sistema, demonstrando outra vantagem de se realizar a Estimação de Estados Multi-Área.

4.3.5 Análise de Erros Grosseiros

A metodologia proposta neste trabalho considera o uso do algoritmo Z-Score [39] para realizar a detecção de erros grosseiros nas medições elétricas dos SDEE. Os erros

Tabela 14 – Comparação de Estimação com Erros Topológicos

Teste	Sistema		
Teste-1	33 barras	119 barras	476 barras
Sem Hopfield			
$EEE(\hat{x})(\%)$	4.7728	3.6332	13.3321
$EEE(\sigma)(\%)$	3.8995	2.2789	2.2628
Teste-1	33 barras	119 barras	476 barras
Com Hopfield			
$EEE(\hat{x})(\%)$	2.7599	3.2557	11.9154
$EEE(\sigma)(\%)$	2.1526	0.5750	2.2275
Teste-2	33 barras	119 barras	476 barras
Sem Hopfield			
$EEE(\hat{x})(\%)$	2.5776	3.1236	11.5203
$EEE(\sigma)(\%)$	2.0903	1.1146	2.1994
Teste-2	33 barras	119 barras	476 barras
Com Hopfield			
$EEE(\hat{x})(\%)$	2.4514	2.9859	10.3947
$EEE(\sigma)(\%)$	1.3044	0.5053	1.1729
Sem Erros (Análise-4)	33 barras	119 barras	476 barras
$EEE(\hat{x})(\%)$	2.3092	2.8925	8.6020
$EEE(\sigma)(\%)$	0.5548	0.6472	0.2250

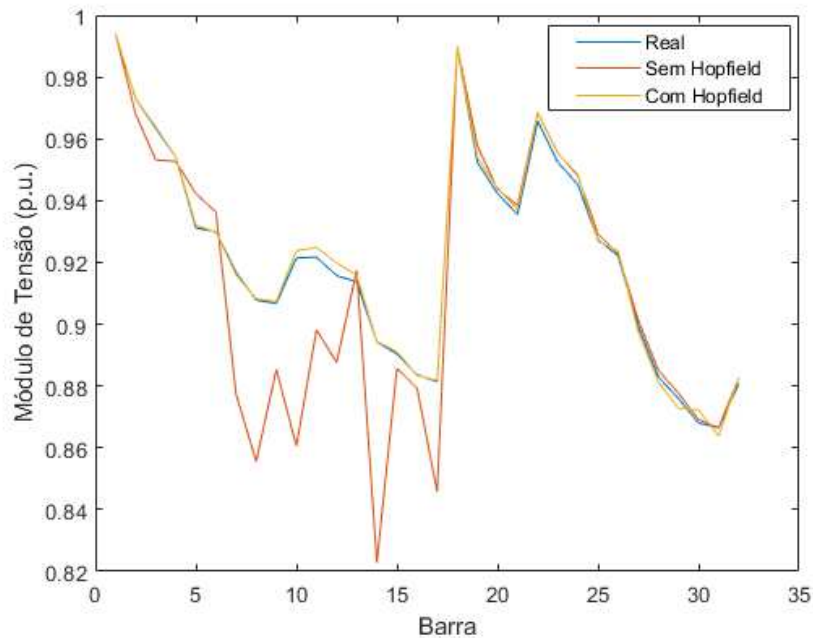


Figura 26 – Estimação do Sistema 33 barras com Erros Topológicos

grosseiros aqui tratados diferem dos erros topológicos por se tratarem de erros nas variáveis contínuas elétricas medidas, como Módulo e Ângulo de Fase de Tensão, enquanto os erros

topológicos ocorrem nas variáveis discretas de estado das chaves dos sistemas. Ao passo que um erro grosseiro é detectado em uma área, a estimação desta área não é realizada a partir de suas próprias medições, devido à grande incerteza sobre a precisão da medição indicada pelo Z-Score como erro grosseiro, e sim pela Rede Neural Backup previamente treinada. A RNB é responsável por estimar os estados da área afetada a partir de pseudomedidas formadas pelos estados estimados da barra de fronteira da área afetada com sua área vizinha, sendo esses estados estimados pela área vizinha.

A avaliação do esquema de detecção de erros grosseiros proposta é feita a partir de três casos para cada um dos três sistemas de teste, considerando seu funcionamento por 48 horas, a partir dos seguintes casos de erro grosseiro:

- Sistema IEEE 33 barras
 - **Caso-1:** Módulo de Tensão medido $V_{21}^* = 0$ na hora 13 para a barra 21;
 - **Caso-2:** Módulo de Tensão medido V_{21}^* com +50% de erro na hora 20 para a barra 21;
 - **Caso-3:** Módulo de Tensão medido V_{21}^* com -50% de erro na hora 32 para a barra 21;
- Sistema IEEE 119 barras
 - **Caso-1:** Módulo de Tensão medido $V_{54}^* = 0$ na hora 13 para a barra 54;
 - **Caso-2:** Módulo de Tensão medido V_{54}^* com +50% de erro na hora 20 para a barra 54;
 - **Caso-3:** Módulo de Tensão medido V_{54}^* com -50% de erro na hora 32 para a barra 54;
- Sistema Brasileiro de 476 barras
 - **Caso-1:** Módulo de Tensão medido $V_{38}^* = 0$ na hora 13 para a barra 38;
 - **Caso-2:** Módulo de Tensão medido V_{38}^* com +50% de erro na hora 20 para a barra 38;
 - **Caso-3:** Módulo de Tensão medido V_{38}^* com -50% de erro na hora 32 para a barra 38;

Para cada um dos sistemas, considerando a curva de carga presente na Figura 10 e as respectivas variações temporais de tensão em cada sistema, foram definidos os limites Z_l do algoritmo Z-Score que demarca a partir de qual *score* uma medição é identificada como erro grosseiro. Como definido na Seção 3.5.2, o limite Z_l é dado como 20% superior ao maior *score* obtido dentro das observações normais da curva de carga. A Tabela 15

Tabela 15 – Limites Z_l do algoritmo Z-Score para os sistemas de teste

Sistema	Maior <i>score</i>	Limite Z_l
33 barras	5,8468	7,0000
119 barras	4,6708	5,6000
476 barras	6,0368	7,2500

traz os valores do maior *score* observado e os respectivos limites arredondados para cada um dos sistemas de teste.

Os três casos de erros grosseiros descritos acima foram aplicados a cada um dos sistemas de teste, e os resultados podem ser observados a partir de duas figuras para cada sistema. A primeira dessas figuras traz, para o instante de tempo do erro do Caso-1, a estimação do Módulo de Tensão de todo o sistema, considerando a medição com erro grosseiro na área afetada, e a estimação considerando o uso da RNB para estimação com correção. Já a segunda mostra a estimação de um barramento não monitorado da área afetada pelos três erros grosseiros para as 48 horas de operação simuladas, de modo que os efeitos dos erros grosseiros podem ser observados na curva de estimação sem correção via RNB, e a mitigação de tais efeitos podem ser observados na curva dos estados estimados contendo a correção via RNB. Ambas as figuras contém os valores reais dos estados obtidos a partir de um Fluxo de Potência para comparação visual da acurácia das estimações.

Para o Sistema IEEE 33 barras, a Figura 27 demonstra os efeitos do erro grosseiro do Caso-1, que ocorrem somente nas barras de número 18, 19, 20 e 21, contidas na área afetada A_2 . A curva denominada “Sem Backup” representa os estados estimados pela RNA da área A_2 alimentada pela medida com erro grosseiro, enquanto a curva “Com Backup” demonstra os estados estimados com a Rede Neural Backup para a área A_2 , que é acionada pelo operador central a partir da estimação da barra 1 pela RNA da área A_1 , que representa a fronteira entre as áreas em questão. A Figura 28 traz o Módulo de Tensão da barra 19 do Sistema 33 barras durante as 48 horas de operação, considerando sua estimação a cada intervalo de 10 minutos. Na figura, é possível notar os três pontos de ocorrência dos erros grosseiros definidos, e a influência dos erros grosseiros na estimação do Módulo de Tensão do barramento na curva “Sem Backup”, que muito se distanciam do valor real do estado. Já a curva “Com Backup” aponta a estimação do barramento via RNB a partir das pseudo-medidas provenientes da estimação da área vizinha A_1 , e seus estados estão visivelmente mais próximos dos valores reais para os pontos de ocorrência dos erros grosseiros. Importante notar que, para os demais pontos sem ocorrência e detecção de erros grosseiros, a curva “Sem Backup” não apresenta valores definidos, uma vez que a RNB não foi acionada nesses instantes de tempo.

O Sistema IEEE 119 barras tem sua estimação durante ocorrência do erro grosseiro do Caso-1 apresentada pela Figura 29. Nela, é possível observar o grande desvio dos Módulos de Tensão na curva “Sem Backup” para as barras de número 1 até 65, que

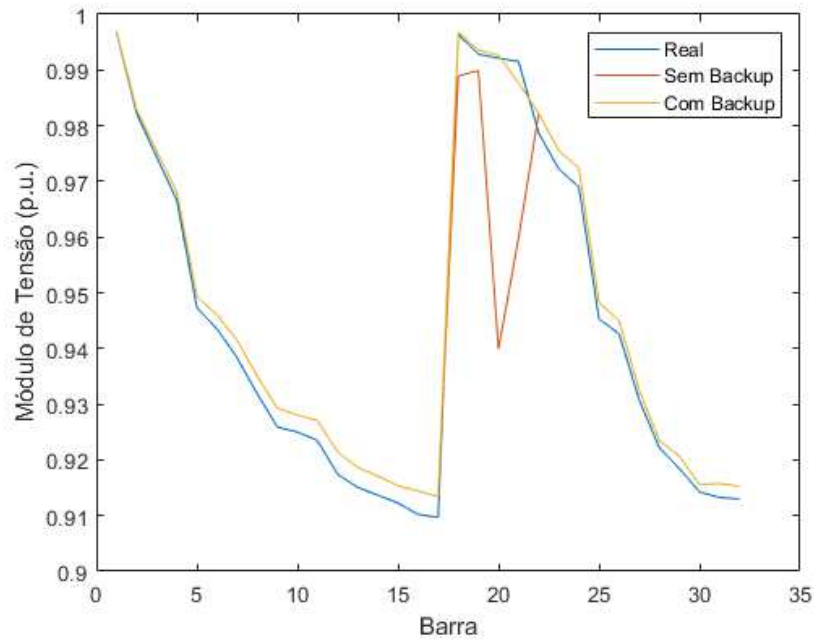


Figura 27 – Estimação do Sistema 33 barras com Erro Grosseiro e Correção via RNB




Figura 28 – Estimação de 48 horas da Barra 19 do Sistema 33 barras com Erros Grosseiros e Correção via RNB

compreendem a área afetada A_1 . A curva “Com Backup” se apresenta consideravelmente mais aderente à curva dos estados reais para as barras da área afetada. Já a Figura 30 mostra o comportamento do Módulo de Tensão da barra 65, presente na área A_1 afetada pelos três erros grosseiros. É possível verificar o grande erro de estimação nos momentos de ocorrência dos três casos de erros propostos na curva “Sem Backup”, assim como é

visível a proximidade dos Módulos de Tensão estimados “Com Backup” para esses mesmos instantes de tempo.

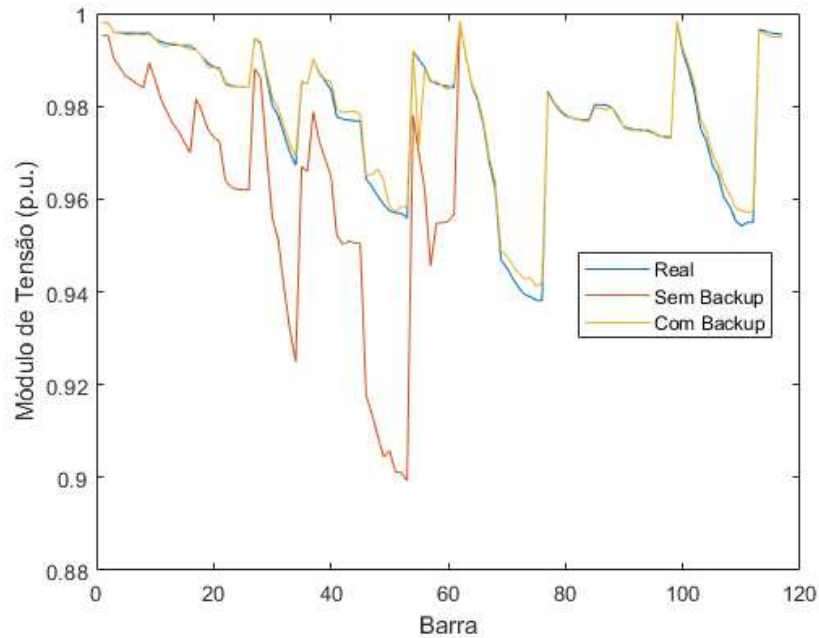


Figura 29 – Estimação do Sistema 119 barras com Erro Grosseiro e Correção via RNB




Figura 30 – Estimação de 48 horas da Barra 65 do Sistema 119 barras com Erros Grosseiros e Correção via RNB

Para o Sistema 476 barras, a Figura 31 mostra a estimação durante ocorrência do erro grosseiros do Caso-1, que ocorre na medição presente na área A_1 . É possível

avaliar, a partir da curva “Sem Backup” comportamento do Módulo de Tensão estimado se distanciando do valor real, ao passo que a curva “Com Backup” mantém-se mais próxima dos valores reais. A Figura 32 traz a evolução temporal do Módulo de Tensão da barra 104, pertencente à área afetada A_1 . Novamente, é possível perceber como a estimação “Sem Backup” se afasta dos valores reais durante a ocorrência dos erros grosseiros em questão, enquanto a estimação “Com Backup” registra valores mais próximos dos reais durante esses instantes.

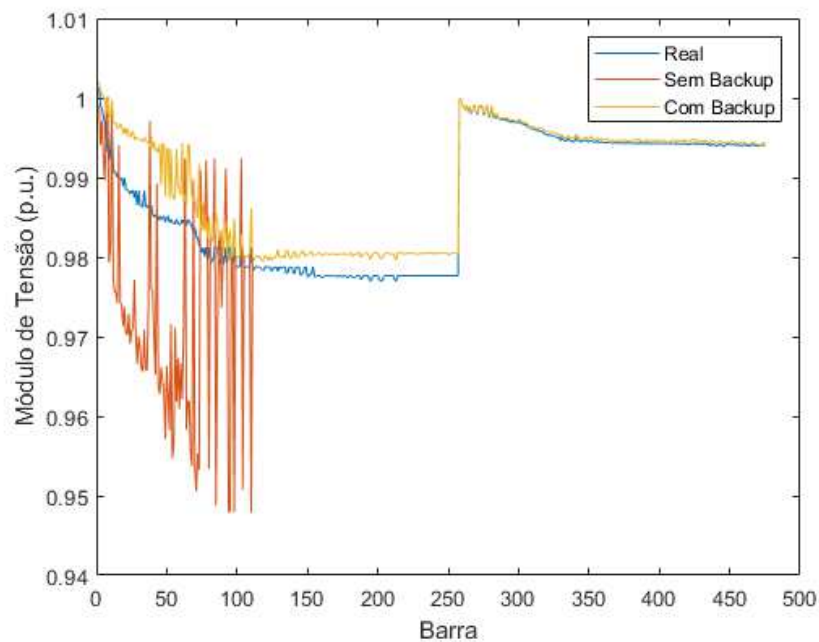


Figura 31 – Estimação do Sistema 476 barras com Erro Grosseiro e Correção via RNB

4.4 CONCLUSÕES PARCIAIS

Este capítulo apresentou testes para a metodologia proposta em três diferentes SDEE. Os testes realizados demonstraram a capacidade do estimador multi-área composto de Redes Neurais Artificiais de atuar com precisão similar aos estimadores centralizados da literatura, assim como aos estimadores formados por RNA de estimação centralizada. Os erros de estimação são pequenos e não comprometem as análises de desempenho do sistema. Os testes realizados demonstram, também, a rapidez nas estimações feitas com RNA, em comparação com métodos encontrados na literatura. A utilização de diferentes tipos de equipamentos de medição aponta a capacidade de estimação para sistemas que não contam com medições fasoriais.

Adicionalmente, a metodologia também se mostrou eficaz na detecção e correção de erros grosseiros. As taxas de sucesso de correção de erros topológicos se aproximam de 100%, e testes considerando a não detecção demonstram que a interferência do erro

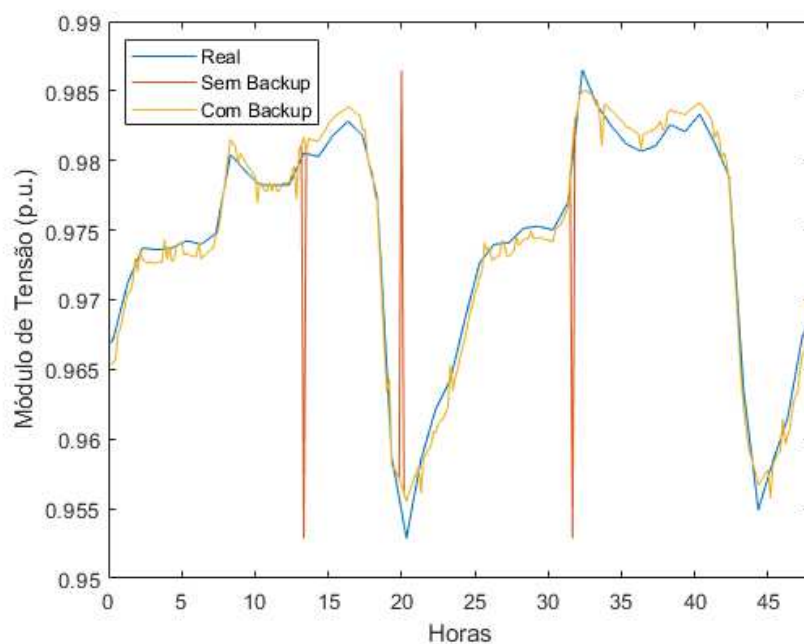


Figura 32 – Estimação de 48 horas da Barra 104 do Sistema 476 barras com Erros Grosseiros e Correção via RNB

topológico ocorre apenas na área afetada, não prejudicando a estimação do restante do sistema. A detecção de erros grosseiros nas medições elétricas também apresentou-se de forma satisfatória, com a devida correção das estimações a partir das Redes Neurais *Backup* acionadas em caso de detecção de erro grosseiro em alguma variável elétrica medida.

5 CONCLUSÃO

Este capítulo tem o intuito de apresentar as conclusões finais acerca da metodologia proposta e os resultados atingidos com sua aplicação aos sistemas de teste utilizados. Também são apresentadas neste capítulo algumas propostas de trabalhos futuros a partir da metodologia empregada.

5.1 CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo principal o desenvolvimento de um modelo de Estimação de Estados, a partir do uso de Redes Neurais Artificiais, para Sistemas de Distribuição de Energia Elétrica, considerando sua divisão em áreas. O trabalho teve o objetivo principal alcançado, ao passo que a metodologia proposta foi capaz de realizar a Estimação de Estados dos sistemas de teste utilizados, com alta velocidade de resposta às amostras de medição, viabilizando seu emprego no monitoramento em tempo real de SDEE.

A utilização de quatro modelos de estimação com RNA foi capaz de demonstrar, primeiro, a capacidade de estimação das RNA para estimação centralizada, comparando diretamente o resultado das métricas obtidas com métodos clássicos encontrados na literatura, e demonstrando a compatibilidade entre o emprego de RNA e o dos métodos clássicos. O modelo da segunda análise principal proposta demonstrou, não apenas a capacidade de estimação do emprego de RNA em áreas, mas a melhora nos resultados das métricas com o uso dessas redes menores e simplificadas, em comparação com a RNA centralizada para todo o sistema. Não obstante, a terceira análise demonstrou como as RNA centralizadas são eficazes para realizar estimação dos sistemas com variações topológicas, sendo alimentadas com os estados das chaves do sistema além das medições elétricas. Por fim, a quarta análise, que compreende a metodologia final proposta, obteve sucesso ao demonstrar que as RNA em área também são capazes de realizar estimação sob variações topológicas, e o fazem com maior precisão do que a RNA centralizada.

Um outro aspecto avaliado dentro deste trabalho foi a capacidade do estimador proposto de operar em sistemas que contam com apenas Medidores Inteligentes alocados. Tal ocorrência, comum em SDEE, acarreta na falta de medições de Ângulo de Fase de Tensão. Entretanto, as RNA se mostraram capazes de realizar a estimação desses ângulos a partir apenas dos Módulos de Tensão medidos pelos MIs.

Além disso, foram realizados testes para detectar a precisão das estimações sobre os barramentos de menor tensão dos sistemas, um fator chave para a operação segura de SDEE. Os testes demonstraram a capacidade da metodologia proposta de estimar os Módulos de Tensão no barramento em que ocorre menor valor de tensão dos três sistemas de teste com erro percentual baixo.

A ocorrência de erros topológicos foi outro aspecto abordado neste trabalho, sendo a metodologia proposta dotada de artifício para correção de tais erros. A metodologia contou com utilização de Redes Neurais Hopfield para processamento dos dados obtidos dos estados das chaves do sistema, de modo que esses estados fossem avaliados pelas RNH de cada área do SDEE para corrigir eventuais erros topológicos que pudessem gerar um vetor de estados das chaves correspondente a uma topologia inviável ou impraticada no SDEE. Os testes realizados mostraram que as RNH foram capazes de corrigir mais de 90% dos erros singulares de topologia possíveis para todos os sistemas de teste. Ademais, testes contendo amostras contaminadas com erros topológicos foram realizados a fim de demonstrar o impacto de tais erros caso sejam indetectados nas estimações. Os resultados mostraram não apenas o aumento na métrica de estimação para os casos com amostras infectadas, mas também foram demonstradas curvas dos estados estimados com e sem correção pelas Redes Neurais Hopfield, de modo que houvesse uma percepção visual de como os erros topológicos desviam os estados dos respectivos valores reais, e como essa influência ocorre apenas nas barras contidas na área onde ocorre o erro, corroborando com a maior robustez da Estimação de Estados Multi-Áreas.

Outro aspecto importante abordado foi a detecção e correção de erros grosseiros de medição. O emprego do algoritmo Z-Score se mostrou eficaz para detecção de erros grosseiros durante a operação dos sistemas de teste, considerando a avaliação pelo algoritmo Z-Score em intervalos de tempo de medição de dez minutos. As Redes Neurais *Backup* propostas para estimação a partir de pseudo-medidas se mostraram eficazes ao realizar as estimações por meio dos estados estimados das barras de fronteira, obtidos das áreas vizinhas, pelo operador central. Novamente, curvas de estados reais e estimados foram utilizadas para evidenciar a importância da detecção dos erros grosseiros, e da estimação via RNB, ao passo que estimações realizadas pelas RNB se mostraram consideravelmente mais aderentes aos valores reais do que as estimações feitas com amostras infectadas por erros grosseiros.

A metodologia proposta, porém, enfrenta alguns desafios para aplicação prática em SDEE. A utilização de RNA para estimação de estados requer a simulação prévia das condições operativas que o sistema pode enfrentar, de modo que essas condições estejam incluídas nos cenários de carga utilizados para treinamento da RNA. Os SDEE, entretanto, apresentam diversas particularidades em sua operação que podem culminar em uma criação de conjuntos de cenários de natureza combinatória e, eventualmente, proibitiva. Como exemplo, a desconexão de carga em alguma barra do sistema pode gerar inúmeras combinações de desconexões a serem contempladas durante a geração de cenários. Outra situação é a variação da tensão no barramento da Subestação, que forma um novo perfil de tensão em todo o sistema, novamente gerando diversas opções de cenários a serem contemplados durante o treinamento. Esses obstáculos apontam a necessidade de futuras contribuições que venham a aprimorar a aplicação de RNA para estimação de estados,

considerando, também, a ocorrência de cenários de operação de natureza combinatória e de difícil inclusão nos cenários de teste. A associação com métodos clássicos de estimação frente a tais cenários pode apresentar uma abordagem mais robusta para estimação de estados de SDEE com apoio de Redes Neurais Artificiais.

Por fim, os testes realizados demonstraram a capacidade que o Estimador de Estados Multi-Área proposta detém de operar sob aspectos e particularidades importantes dos Sistemas de Distribuição de Energia Elétrica. A operação contínua dos SDEE pode ser auxiliada por Estimadores Locais com RNA aptas a perceber diferentes padrões de chaveamento, operando com respostas rápidas às amostras de medições. Não obstante, a maior robustez a erros grosseiros de medição e erros topológicos foi obtida pela utilização de etapas de detecção e correção prévias à estimação.

5.2 PROPOSTAS DE TRABALHOS FUTUROS

O aprimoramento do Estimador de Estados Multi-Área proposto neste trabalho pode ser alcançado seguindo algumas linhas de pesquisa futuras, entre elas:

- Consideração dos Sistemas de Distribuição como trifásicos desequilibrados;
- Consideração de casos com diferentes níveis de regulação de tensão na Subestação dos sistemas;
- Aplicação de técnicas de alocação de medidores em estudos de planejamento de Sistemas de Distribuição;
- Associação da metodologia proposta com outros métodos clássicos de estimação a fim de otimizar as vantagens alcançadas junto aos desafios ainda presentes para o problema de estimação de estados de SDEE com Redes Neurais Artificiais;
- Análise do desempenho da metodologia com o aumento do número de topologias consideradas durante o treinamento das RNA;
- Cálculo de perdas elétricas a partir dos estados estimados do SDEE;
- Desenvolvimento de Estimador de Estados Dinâmico com Redes Neurais Recorrentes do tipo *Long Short Term Memory*;
- Implementação de *Extreme Machine Learning* para retreinamento a partir de novos dados.

REFERÊNCIAS

- 1 WAHEED, Rida; SARWAR, Sahar; WEI, Chen. The survey of economic growth, energy consumption and carbon emission. *Energy Reports*, v. 5, p. 1103-1115, 2019.
- 2 FERREIRA, Mónica Filipa Moreira. Consumo de Energia e Crescimento Económico: Evidência em período longo para um painel de países europeus. 2013. Tese de Doutorado. Universidade da Beira Interior (Portugal).
- 3 CARVALLO, Andres; COOPER, John. The advanced smart grid: Edge power driving sustainability. Artech House, 2015.
- 4 WOOD, Allen J.; WOLLENBERG, Bruce F.; SHEBLÉ, Gerald B. Power generation, operation, and control. John Wiley and Sons, 2013.
- 5 SCHWEPPE, Fred C.; WILDES, J. Power system static-state estimation, Part I: Exact model. *IEEE Transactions on Power Apparatus and systems*, n. 1, p. 120-125, 1970.
- 6 IRVING, M. R.; OWEN, R. C.; STERLING, M. J. H. Power-system state estimation using linear programming. In: *Proceedings of the Institution of Electrical Engineers. IET Digital Library*, 1978. p. 879-885.
- 7 GARCIA, t A.; MONTICELLI, A.; ABREU, P. Fast decoupled state estimation and bad data processing. *IEEE Transactions on Power apparatus and Systems*, n. 5, p. 1645-1652, 1979.
- 8 ROYTELMAN, I.; SHAHIDEHPOUR, S. M. State estimation for electric power distribution systems in quasi real-time conditions. *IEEE Transactions on Power Delivery*, v. 8, n. 4, p. 2009-2015, 1993.
- 9 BARAN, Mesut E.; KELLEY, Arthur W. State estimation for real-time monitoring of distribution systems. *IEEE Transactions on Power systems*, v. 9, n. 3, p. 1601-1609, 1994.
- 10 LU, C. N.; TENG, J. H.; LIU, W.-HE. Distribution system state estimation. *IEEE Transactions on Power systems*, v. 10, n. 1, p. 229-240, 1995.
- 11 LI, Ke. State estimation for power distribution system and measurement impacts. *IEEE Transactions on Power Systems*, v. 11, n. 2, p. 911-916, 1996.
- 12 CLEMENTS, Kevin A.; COSTA, A. Simões. Topology error identification using normalized Lagrange multipliers. *IEEE Transactions on power systems*, v. 13, n. 2, p. 347-353, 1998.
- 13 PEREIRA, Ingrid S. 2015. Estimaco de estados em redes de distribuico de energia eltrica baseada em medio es fasoriais. Universidade Federal de Juiz de Fora.
- 14 DUQUE, Felipe G. et al. State estimator for electrical distribution systems based on an optimization model. *Electric Power Systems Research*, v. 152, p. 122-129, 2017.
- 15 VAN CUTSEM, Th; HORWARD, Jean-Luc; RIBBENS-PAVELLA, M. A two-level static state estimator for electric power systems. *IEEE transactions on power apparatus and systems*, n. 8, p. 3722-3732, 1981.

- 16 GÓMEZ-EXPÓSITO, Antonio et al. A taxonomy of multi-area state estimation methods. *Electric Power Systems Research*, v. 81, n. 4, p. 1060-1069, 2011.
- 17 DENG, Youman; HE, Ying; ZHANG, Boming. A branch-estimation-based state estimation method for radial distribution systems. *IEEE Transactions on power delivery*, v. 17, n. 4, p. 1057-1062, 2002.
- 18 KORRES, George N. A distributed multiarea state estimation. *IEEE Transactions on Power Systems*, v. 26, n. 1, p. 73-84, 2010.
- 19 ASHOK, Aditya; GOVINDARASU, Manimaran. Cyber attacks on power system state estimation through topology errors. In: 2012 IEEE Power and Energy Society General Meeting. IEEE, 2012. p. 1-8.
- 20 WENG, Yang; LIAO, Yizheng; RAJAGOPAL, Ram. Distributed energy resources topology identification via graphical modeling. *IEEE Transactions on Power Systems*, v. 32, n. 4, p. 2682-2694, 2016.
- 21 MIRANDA, Vladimiro et al. Reconstructing missing data in state estimation with autoencoders. *IEEE Transactions on power systems*, v. 27, n. 2, p. 604-611, 2011.
- 22 ALBUQUERQUE, Joao S.; BIEGLER, Lorenz T. Data reconciliation and gross-error detection for dynamic systems. *AICHE journal*, v. 42, n. 10, p. 2841-2856, 1996.
- 23 BRAUNSTEIN, Sérgio Halpern et al. Bad data analysis in distribution state estimation considering load models. In: 2015 IEEE Power and Energy Society General Meeting. IEEE, 2015. p. 1-5.
- 24 ANGIONI, Andrea et al. Real-time monitoring of distribution system based on state estimation. *IEEE Transactions on Instrumentation and Measurement*, v. 65, n. 10, p. 2234-2243, 2016.
- 25 BRETAS, A. S. et al. Multiple gross errors detection, identification and correction in three-phase distribution systems WLS state estimation: A per-phase measurement error approach. *Electric Power Systems Research*, v. 151, p. 174-185, 2017.
- 26 ASHRAF, Syed Mohammad et al. Voltage stability monitoring of power systems using reduced network and artificial neural network. *International Journal of Electrical Power and Energy Systems*, v. 87, p. 43-51, 2017.
- 27 ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, v. 65, n. 6, p. 386, 1958.
- 28 BERNIERI, Andrea et al. Neural networks and pseudo-measurements for real-time monitoring of distribution systems. *IEEE transactions on instrumentation and measurement*, v. 45, n. 2, p. 645-650, 1996.
- 29 RAMESH, L. et al. Distributed state estimation technique for active distribution networks. In: 2007 42nd International Universities Power Engineering Conference. IEEE, 2007. p. 861-866.
- 30 MANITSAS, Efthymios et al. Distribution system state estimation using an artificial neural network approach for pseudo measurement modeling. *IEEE Transactions on power systems*, v. 27, n. 4, p. 1888-1896, 2012.

- 31 ABDEL-NASSER, Mohamed; MAHMOUD, Karar; KASHEF, Heba. A novel smart grid state estimation method based on neural networks. *IJIMAI*, v. 5, n. 1, p. 92-100, 2018.
- 32 MENKE, Jan-Hendrik; BORNHORST, Nils; BRAUN, Martin. Distribution system monitoring for smart power grids with distributed generation using artificial neural networks. *International Journal of Electrical Power & Energy Systems*, v. 113, p. 472-480, 2019.
- 33 AHMAD, Fiaz; TARIQ, Muhammad; FAROOQ, Ajmal. A novel ANN-based distribution network state estimator. *International Journal of Electrical Power & Energy Systems*, v. 107, p. 200-212, 2019.
- 34 TIAN, Guanyu et al. Neural-network-based Power System State Estimation with Extended Observability. *Journal of Modern Power Systems and Clean Energy*, v. 9, n. 5, p. 1043-1053, 2021.
- 35 ZAMZAM, Ahmed Samir; SIDIROPOULOS, Nicholas D. Physics-aware neural networks for distribution system state estimation. *IEEE Transactions on Power Systems*, v. 35, n. 6, p. 4347-4356, 2020.
- 36 TRAN, Minh-Quan et al. Multi-area distribution system state estimation using decentralized physics-aware neural networks. *Energies*, v. 14, n. 11, p. 3025, 2021.
- 37 WANG, Changgang; AN, Jun; MU, Gang. Power System Network Topology Identification Based on Knowledge Graph and Graph Neural Network. *Frontiers in Energy Research*, v. 8, p. 613331, 2021.
- 38 FÜLLHASE, Sonja; HERES, Jo; SHAPOVALOVA, Y. Testing the n-1 principle with graph neural networks. 2020.
- 39 SHIFFLER, Ronald E. Maximum Z scores and outliers. *The American Statistician*, v. 42, n. 1, p. 79-80, 1988.
- 40 Regras e Procedimentos de Distribuição (Prodist), 2021. Disponível em: <https://www.gov.br/aneel/pt-br/centrais-de-conteudos/procedimentos-regulatorios/prodist>
- 41 Open Smart Grid, Interoperability and Standards, 2008. Disponível em: <http://osgug.ucaiug.org/>
- 42 CLEMENTS, K. A. A multi-area approach to state estimation in power system networks. In: *IEEE PES Summer Meeting*, 1972. 1972.
- 43 KOBAYASHI, H.; NARITA, S.; HAMMAM, M. S. A. A. Model coordination method applied to power system control and estimation problems. In: *4th IFAC/IFIP International Conference on Digital Computer Applications to Process Control*. Springer, Berlin, Heidelberg, 1974. p. 114-128.
- 44 ZHAO, Liang; ABUR, Ali. Multi area state estimation using synchronized phasor measurements. *IEEE Transactions on Power Systems*, v. 20, n. 2, p. 611-617, 2005.
- 45 HAYKIN, Simon. *Redes neurais: princípios e prática*. Bookman Editora, 2001.

- 46 WIELAND, Alexis; LEIGHTON, Russell. Geometric analysis of neural network capabilities. 1987.
- 47 ABUR, Ali; EXPOSITO, Antonio Gomez. Power system state estimation: theory and implementation. CRC press, 2004.
- 48 MILBRADT, Rafael Gressler et al. Novos métodos de estimação de estado multi-área com potencial aplicação em redes elétricas inteligentes. 2015. Tese de Doutorado. Universidade Federal de Santa Maria.
- 49 MONTICELLI, Alcir José. Fluxo de Carga em Redes de Energia Elétrica. São Paulo: Edgard Blucher, 1983.
- 50 TECCHIO, Pedro PV; BENEDITO, Raphael AS; ALBERTO, Luís FC. The behavior of WLS state estimator near the maximum loadability point of power systems. In: IEEE PES General Meeting. IEEE, 2010. p. 1-6.
- 51 PHADKE, Arun G. Synchronized phasor measurements in power systems. IEEE Computer Applications in power, v. 6, n. 2, p. 10-15, 1993.
- 52 MARTIN, K. E. et al. Exploring the IEEE standard C37. 118–2005 synchrophasors for power systems. IEEE transactions on power delivery, v. 23, n. 4, p. 1805-1811, 2008.
- 53 WU, Jianzhong; HE, Yan; JENKINS, Nick. A robust state estimator for medium voltage distribution networks. IEEE Transactions on Power Systems, v. 28, n. 2, p. 1008-1016, 2012.
- 54 HOPFIELD, John J. Neural networks and physical systems with emergent collective computational abilities. Proceedings of the national academy of sciences, v. 79, n. 8, p. 2554-2558, 1982.
- 55 KUMAR, DM Vinod et al. Topology processing and static state estimation using artificial neural networks. IEE Proceedings-Generation, Transmission and Distribution, v. 143, n. 1, p. 99-105, 1996.
- 56 BARAN, Mesut E.; WU, Felix F. Network reconfiguration in distribution systems for loss reduction and load balancing. IEEE Power Engineering Review, v. 9, n. 4, p. 101-102, 1989.
- 57 SCHUABB, Thales (2023). Metadata - Estimação de Estados Multi-Área de Sistemas de Distribuição de Energia Elétrica com Suporte de Redes Neurais Artificiais Considerando Variações Topológicas e Erros Grosseiros, Mendeley Data, V1, doi: 10.17632/4r3t8cg3gm.1.
- 58 DE OLIVEIRA, Leonardo Willer. Reconfiguração e alocação ótima de capacitores em sistemas de distribuição. Rio de Janeiro: Tese de Doutorado, Universidade Federal do Rio de Janeiro, 2009.