



APLICAÇÃO DE REDES NEURAIS NA PROTEÇÃO DE SISTEMAS DE
DISTRIBUIÇÃO ATIVOS

Fábio Casale Padovani Neto

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica.

Orientadores: Tatiana Mariano Lessa de Assis
Vitor Hugo Ferreira

Rio de Janeiro
Março de 2019

APLICAÇÃO DE REDES NEURAIIS NA PROTEÇÃO DE SISTEMAS DE
DISTRIBUIÇÃO ATIVOS

Fábio Casale Padovani Neto

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE)
DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM
CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

Prof. Tatiana Mariano Lessa de Assis, D.Sc.

Prof. Vitor Hugo Ferreira, D.Sc.

Prof. Luiz Pereira Calôba, Dr.Ing.

Prof. Julio Cesar Stacchini de Souza, D. Sc.

RIO DE JANEIRO, RJ – BRASIL

MARÇO DE 2019

Padovani Neto, Fábio Casale

Aplicação de Redes Neurais na Proteção de Sistemas de Distribuição Ativos / Fábio Casale Padovani Neto – Rio de Janeiro: UFRJ/COPPE, 2019.

XIII, 139 p. il.; 29,7 cm

Orientadores: Tatiana Mariano Lessa de Assis

Vitor Hugo Ferreira

Dissertação (Mestrado) – UFRJ/ COPPE/ Programa de Engenharia Elétrica, 2019.

Referências Bibliográficas: p. 126-132.

1. Geração Distribuída 2. Redes de Distribuição 3. Proteção. 4. Redes Neurais Artificiais. I. Assis, Tatiana Mariano Lessa de *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

AGRADECIMENTOS

Agradeço a Deus, sem Ele nada disso seria possível.

Agradeço aos meus pais, Fábio e Rita (*in memoriam*) e ao meu irmão Davi. Seja pelos valores, educação, carinho, por tudo ao longo de minha vida. Foi imprescindível o apoio de vocês para eu conseguir chegar até aqui.

Agradeço à minha namorada Kelly, pelos momentos de amor, companheirismo, suporte e incentivo durante essa minha – nossa – caminhada.

Agradeço aos meus orientadores, Professora Tatiana Mariano Lessa de Assis e Professor Vitor Hugo Ferreira, pela oportunidade dada, pelos ensinamentos, incentivos e experiências compartilhadas. Agradeço por acreditarem em mim.

Agradeço aos professores da COPPE/PEE e da UFRJ, os quais contribuíram para a minha formação.

Agradeço aos amigos de longa data, do LASPOT e do mestrado pela amizade e apoio.

Agradeço à Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, CAPES, pelo suporte financeiro.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

APLICAÇÃO DE REDES NEURAIIS NA PROTEÇÃO DE SISTEMAS DE DISTRIBUIÇÃO ATIVOS

Fábio Casale Padovani Neto

Março/2019

Orientadores: Tatiana Mariano Lessa de Assis

Vitor Hugo Ferreira

Programa: Engenharia Elétrica

As redes de distribuição convencionais têm natureza radial, caracterizadas pelo fluxo unidirecional de energia, partindo da subestação até os consumidores finais. A crescente inserção de geração distribuída provoca uma série de impactos positivos e negativos e representa um novo desafio na forma de operar e proteger essas redes. Um dos impactos significativos ocorre na proteção de sobrecorrente nos alimentadores de distribuição. O gerador distribuído pode provocar atraso na atuação ou mesmo a dessensibilização dos relés. O seu efeito na proteção dependerá de seu tamanho, tipo e local de instalação. Este trabalho apresenta o desenvolvimento de um esquema de proteção para redes de distribuição ativas baseado em redes neurais artificiais. Tal esquema sugere o uso de três estágios de Redes Neurais do tipo *feedforward* para auxiliar na proteção de alimentadores de distribuição ativos. O primeiro é capaz de detectar a presença do defeito no sistema. O segundo indica em qual alimentador ocorre o defeito e o último é apto a localizar precisamente a falta ao longo do alimentador de distribuição. Os resultados obtidos demonstram que o esquema proposto é satisfatório como solução aos problemas identificados.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

NEURAL NETWORK-BASED PROTECTION SCHEME OF ACTIVE DISTRIBUTION SYSTEMS

Fábio Casale Padovani Neto

March/2019

Advisors: Tatiana Mariano Lessa de Assis

Vitor Hugo Ferreira

Department: Electrical Engineering

Conventional power distribution systems are radials in nature, characterized by the unidirectional flow of energy, starting from the substation to the final consumers. The increase of distributed generation causes several impacts in the distribution systems and it represents a new challenge in the way of operating and protecting these networks. One of the significant impacts occurs on overcurrent protection in distribution feeders. The distributed generator can cause delay in the protection or even desensitizing the relays. Its effect on protection will depend on size, type and place of installation. This work presents the development of a protection scheme for active distribution systems based on artificial neural networks. This scheme suggests the use of three stages of feedforward artificial neural networks to assist in the protection of active distribution feeders. The first one is able to detect the fault on the system. The second indicates in which feeder the fault occurred and the last one is able to precisely locate the fault along the faulty line. Results show that the proposed scheme is satisfactory as a solution to the identified problems.

SUMÁRIO

LISTA DE FIGURAS.....	IX
LISTA DE TABELAS.....	XI
CAPÍTULO 1 INTRODUÇÃO	1
1.1 MOTIVAÇÃO	1
1.2 OBJETIVO	3
1.3 REVISÃO BIBLIOGRÁFICA	3
1.4 ESTRUTURA DO TRABALHO.....	5
CAPÍTULO 2 IMPACTOS DA GERAÇÃO DISTRIBUÍDA EM REDES DE DISTRIBUIÇÃO	7
2.1 INTRODUÇÃO	7
2.2 ALTERAÇÃO DOS NÍVEIS DE CURTO-CIRCUITO.....	8
2.3 ALTERAÇÃO DO PERFIL DE TENSÃO	9
2.4 LIMITE TÉRMICO.....	10
2.5 REDISTRIBUIÇÃO DOS FLUXOS DE POTÊNCIA	10
2.6 ILHAMENTO	11
2.7 FALHA NOS SISTEMAS DE PROTEÇÃO EXISTENTES	12
CAPÍTULO 3 PROTEÇÃO DE REDES DE DISTRIBUIÇÃO	14
3.1 INTRODUÇÃO	14
3.2 PROTEÇÃO CONVENCIONAL.....	16
3.2.1 Principais Componentes	17
3.3 PROTEÇÃO DE REDES ATIVAS	24
3.3.1 Impactos da GD no Sistema de Proteção.....	25
3.3.2 Estratégias de Solução.....	33
CAPÍTULO 4 REDES NEURAIS ARTIFICIAIS.....	40
4.1 INTRODUÇÃO	40
4.2 NEURÔNIO ARTIFICIAL	42
4.2.1 Funções de Ativação	43
4.3 TREINAMENTO	47
4.4 ARQUITETURAS	49
4.4.1 <i>Feedforward</i>	49

4.4.2	Recorrentes.....	56
4.5	MÉTRICAS DE AVALIAÇÃO DE DESEMPENHO.....	57
CAPÍTULO 5 METODOLOGIA PROPOSTA.....		59
5.1	INTRODUÇÃO.....	59
5.2	PRIMEIRO ESTÁGIO DA RNA.....	62
5.3	SEGUNDO ESTÁGIO DA RNA.....	65
5.4	TERCEIRO ESTÁGIO DA RNA.....	67
CAPÍTULO 6 ESTUDO DE CASO.....		74
6.1	INTRODUÇÃO.....	74
6.2	SISTEMA TESTE.....	75
6.2.1	Ajuste da Proteção dos Alimentadores.....	76
6.3	INSERÇÃO DA GERAÇÃO DISTRIBUÍDA.....	81
6.3.1	Caso 1.....	83
6.3.2	Caso 2.....	84
6.3.3	Caso 3.....	85
6.3.4	Comparação dos Casos.....	86
6.4	SIMULAÇÕES.....	87
6.4.1	Cenário 1.....	88
6.4.2	Cenário 2.....	106
6.4.3	Comparação dos Cenários.....	121
CAPÍTULO 7 CONCLUSÕES.....		123
7.1	TRABALHOS FUTUROS.....	125
REFERÊNCIAS BIBLIOGRÁFICAS.....		126
ANEXO A CÓDIGO DO MATLAB.....		133

LISTA DE FIGURAS

FIGURA 1: ESQUEMA CONVENCIONAL DE PROTEÇÃO DE ALIMENTADORES AÉREOS DE DISTRIBUIÇÃO	16
FIGURA 2: CURVAS PARA RELÉS DE SOBRECORRENTE DE TEMPO INVERSO [28]	19
FIGURA 3: FAIXA PARA LIMITE MÍNIMO DO AJUSTE DO RELÉ DE SOBRECORRENTE DE NEUTRO	21
FIGURA 4: CURVA DE DESEMPENHO DO RELÉ 50/51	21
FIGURA 5: ZONAS DE ATUAÇÃO DO RELÉ 50/51	22
FIGURA 6: FORMA DE CONEXÃO DO ACESSANTE À REDE DE DISTRIBUIÇÃO [33]	26
FIGURA 7: IMPACTO NO AJUSTE DO RELÉ DE SOBRECORRENTE.....	27
FIGURA 8: EFEITO DA GD NA ATUAÇÃO DO RELÉ DE SOBRECORRENTE DE TEMPO INVERSO.....	28
FIGURA 9: IMPACTO NA ESTRATÉGIA POUPA-FUSÍVEL.....	29
FIGURA 10: IMPACTO NOS DISPAROS FALSOS DOS RELÉS.....	30
FIGURA 11: IMPACTO NA PROTEÇÃO DE DISTÂNCIA	32
FIGURA 12: TIPOS DE LIGAÇÕES DE TRANSFORMADORES DE INTERCONEXÃO	32
FIGURA 13: METODOLOGIAS PARA PROTEÇÃO DE REDES DE DISTRIBUIÇÃO ATIVAS.....	34
FIGURA 14: ESQUEMA BÁSICO DE UM ALGORITMO GENÉTICO	37
FIGURA 15: PRINCIPAIS PROPRIEDADES DAS REDES NEURAIS ARTIFICIAIS	41
FIGURA 16: MODELO DE UM NEURÔNIO ARTIFICIAL ADAPTADO DE [51]	42
FIGURA 17: FUNÇÃO DEGRAU	43
FIGURA 18: FUNÇÃO DEGRAU BIPOLAR	44
FIGURA 19: FUNÇÃO RAMPA SIMÉTRICA	44
FIGURA 20: FUNÇÃO LOGÍSTICA	45
FIGURA 21: FUNÇÃO TANGENTE HIPERBÓLICA.....	45
FIGURA 22: FUNÇÃO GAUSSIANA	46
FIGURA 23: FUNÇÃO LINEAR	46
FIGURA 24: REDE <i>FEEDFORWARD</i> DE CAMADA ÚNICA	50
FIGURA 25: REDE <i>FEEDFORWARD</i> DE CAMADAS MÚLTIPLAS	50
FIGURA 26: REDE <i>PERCEPTRON</i> MULTICAMADAS.....	51
FIGURA 27: DIAGRAMA DE IMPLEMENTAÇÃO DAS REDES PMC	55
FIGURA 28: REDES DE FUNÇÃO DE BASE RADIAL.....	56
FIGURA 29: REDE RECORRENTE	57
FIGURA 30: MATRIZ CONFUSÃO GENÉRICA	58
FIGURA 31: FLUXOGRAMA DE OPERAÇÃO DA ESTRATÉGIA DE SOLUÇÃO PROPOSTA.....	60
FIGURA 32: DIAGRAMA UNIFILAR DO SISTEMA DE DISTRIBUIÇÃO DE 14 BARRAS	61
FIGURA 33: COMPOSIÇÃO DOS DADOS DE ENTRADA-SAÍDA PARA TREINO DO 1ºESTÁGIO DA RNA	63
FIGURA 34: CORRENTES E DEFEITO PARA PRIMEIRO ESTÁGIO DA RNA.....	64
FIGURA 35: CORRENTES E DEFEITOS PARA SEGUNDO ESTÁGIO DA RNA	66
FIGURA 36: COMPOSIÇÃO DOS DADOS DE ENTRADA-SAÍDA PARA TREINO DO 2ºESTÁGIO DA RNA	67
FIGURA 37: MAPEAMENTO ENTRADAS-SAÍDAS PARA TREINAMENTO DO TERCEIRO ESTÁGIO DA RNA.....	68
FIGURA 38: DEFEITOS APLICADOS PARA TREINAMENTO DA RNAAL1	69

FIGURA 39: COMPOSIÇÃO DOS DADOS DE ENTRADA-SAÍDA PARA TREINO RNAAL1	69
FIGURA 40: DEFEITOS APLICADOS PARA TREINAMENTO DA RNAAL2.....	70
FIGURA 41: COMPOSIÇÃO DOS DADOS DE ENTRADA-SAÍDA PARA TREINO RNAAL2	71
FIGURA 42: DEFEITOS APLICADOS PARA TREINAMENTO DA RNAAL3.....	72
FIGURA 43: COMPOSIÇÃO DOS DADOS DE ENTRADA-SAÍDA PARA TREINO RNAAL3	72
FIGURA 44: CORRENTES DO TRECHO 2-3 PARA DEFEITO MONOFÁSICO NA FASE A NA BARRA 6	80
FIGURA 45: DIAGRAMA UNIFILAR COM GD1.....	82
FIGURA 46: CORRENTE NO TRECHO 2-3 PARA DEFEITO TRIFÁSICO NA BARRA 6 PARA CASO 1	83
FIGURA 47: CORRENTES PARA DEFEITO MONOFÁSICO NA FASE A NA BARRA 6 PARA CASO 1	84
FIGURA 48: CORRENTES PARA DEFEITO TRIFÁSICO NA BARRA 6 PARA CASO 2	84
FIGURA 49: CORRENTES PARA DEFEITO MONOFÁSICO NA FASE A NA BARRA 6 PARA CASO 2.....	85
FIGURA 50: CORRENTES NO TRECHO 2-3 PARA DEFEITO TRIFÁSICO NA BARRA 6 PARA CASO 3	86
FIGURA 51: CORRENTES PARA DEFEITO MONOFÁSICO NA FASE A NA BARRA 6 PARA CASO 3.....	86
FIGURA 52: EVOLUÇÃO DOS ERROS NO TREINAMENTO DO 1º ESTÁGIO DA RNA PARA CENÁRIO 1.....	90
FIGURA 53: MATRIZ CONFUSÃO DO PRIMEIRO ESTÁGIO DA RNA PARA O CENÁRIO 1	90
FIGURA 54: PONTOS DE DEFEITO PARA TESTE DA RNA DO PRIMEIRO ESTÁGIO PARA CENÁRIO 1.....	91
FIGURA 55: EVOLUÇÃO DOS ERROS NO TREINAMENTO DO 2º ESTÁGIO DA RNA PARA CENÁRIO 1.....	94
FIGURA 56: MATRIZ CONFUSÃO DO SEGUNDO ESTÁGIO DA RNA PARA O CENÁRIO 1	95
FIGURA 57: PONTOS DE DEFEITO PARA TESTE DA RNA DO SEGUNDO ESTÁGIO PARA CENÁRIO 1.....	96
FIGURA 58: EVOLUÇÃO DOS ERROS NO TREINAMENTO DA RNAAL1 PARA CENÁRIO 1	99
FIGURA 59: PONTOS DE DEFEITO PARA TESTE DA RNAAL1 PARA CENÁRIO 1	99
FIGURA 60: EVOLUÇÃO DOS ERROS NO TREINAMENTO DA RNAAL2 PARA CENÁRIO 1	102
FIGURA 61: PONTOS DE DEFEITO PARA TESTE DA RNAAL2 PARA CENÁRIO 1	102
FIGURA 62: EVOLUÇÃO DOS ERROS NO TREINAMENTO DA RNAAL3 PARA CENÁRIO 1	105
FIGURA 63: PONTOS DE DEFEITO PARA TESTE DA RNAAL3 PARA CENÁRIO 1	106
FIGURA 64: DIAGRAMA UNIFILAR DO CENÁRIO 2	107
FIGURA 65: EVOLUÇÃO DOS ERROS NO TREINAMENTO DO 1º ESTÁGIO DA RNA PARA CENÁRIO 2.....	108
FIGURA 66: MATRIZ CONFUSÃO DO PRIMEIRO ESTÁGIO DA RNA PARA O CENÁRIO 2	109
FIGURA 67: EVOLUÇÃO DOS ERROS NO TREINAMENTO DO 2º ESTÁGIO DA RNA PARA CENÁRIO 2.....	112
FIGURA 68: MATRIZ CONFUSÃO DO SEGUNDO ESTÁGIO DA RNA PARA O CENÁRIO 2	112
FIGURA 69: EVOLUÇÃO DOS ERROS NO TREINAMENTO DA RNAAL1 PARA CENÁRIO 2	115
FIGURA 70: EVOLUÇÃO DOS ERROS NO TREINAMENTO DA RNAAL2 PARA CENÁRIO 2	118
FIGURA 71: EVOLUÇÃO DOS ERROS NO TREINAMENTO DA RNAAL3 PARA CENÁRIO 2	121

LISTA DE TABELAS

TABELA 1: PONTOS DE CONEXÃO EM TENSÃO NOMINAL SUPERIOR A 1kV E INFERIOR A 69kV [20].....	9
TABELA 2: FUNÇÕES DOS RELÉS DE PROTEÇÃO	15
TABELA 3: CONSTANTES PARA AS CURVAS DO RELÉ DE TEMPO INVERSO [28].....	18
TABELA 4: PROTEÇÕES MÍNIMAS EM FUNÇÃO DA POTÊNCIA INSTALADA [32].....	25
TABELA 5: RESPOSTAS ESPERADAS DO PRIMEIRO ESTÁGIO DA RNA.....	62
TABELA 6: DIVISÃO DOS DADOS DE TREINAMENTO.....	64
TABELA 7: RESPOSTAS ESPERADAS DO SEGUNDO ESTÁGIO DA RNA.....	65
TABELA 8: RESPOSTAS ESPERADAS DA RNAAL1 PARA LOCALIZAÇÃO DO DEFEITO	68
TABELA 9: RESPOSTAS ESPERADAS DA RNAAL2 PARA LOCALIZAÇÃO DO DEFEITO	70
TABELA 10: RESPOSTAS ESPERADAS DA RNAAL3 PARA LOCALIZAÇÃO DO DEFEITO	71
TABELA 11: DADOS DO TRANSFORMADOR DA SUBESTAÇÃO	75
TABELA 12: DADOS DAS CARGAS	76
TABELA 13: DADOS DOS BANCOS DE CAPACITORES	76
TABELA 14: DADOS DOS RAMAIS DOS ALIMENTADORES	77
TABELA 15: CORRENTES DE CARGA PESADA	77
TABELA 16: LIMITES MÍNIMOS PARA AJUSTE DOS RELÉS DE SOBRECORRENTE DE FASE.....	78
TABELA 17: CORRENTE DE DEFEITO MÍNIMA NO FINAL DO TRECHO E LIMITE MÁXIMO.....	78
TABELA 18: FAIXAS DE AJUSTE DOS RELÉS DE SOBRECORRENTE DE FASE.....	78
TABELA 19: AJUSTES DEFINIDOS PARA OS RELÉS DE SOBRECORRENTE DE FASE.....	79
TABELA 20: LIMITES MÍNIMOS PARA AJUSTE DOS RELÉS DE SOBRECORRENTE DE NEUTRO.....	79
TABELA 21: CORRENTE DE DEFEITO MONOFÁSICO NO FINAL DO TRECHO E LIMITE MÁXIMO	80
TABELA 22: FAIXAS DE AJUSTE DOS RELÉS DE SOBRECORRENTE DE NEUTRO.....	80
TABELA 23: AJUSTES DEFINIDOS PARA OS RELÉS DE SOBRECORRENTE DE NEUTRO.....	81
TABELA 24: PARÂMETROS DAS MÁQUINAS	82
TABELA 25: CASOS DE IMPACTO NA PROTEÇÃO DO ALIMENTADOR.....	83
TABELA 26: COMPARAÇÃO DOS TEMPOS DE ATUAÇÃO DA PROTEÇÃO PARA CASOS ESTUDADOS	87
TABELA 27: CENÁRIOS ESTUDADOS	88
TABELA 28: TOPOLOGIA ESCOLHIDA DO PRIMEIRO ESTÁGIO DA RNA PARA O CENÁRIO 1	89
TABELA 29: RESULTADOS DOS TESTES DO 1º ESTÁGIO DA RNA PARA OUTROS PONTOS DE DEFEITO NO CENÁRIO 1	92
TABELA 30: EFICÁCIAS DO 2º ESTÁGIO DA RNA COM ALGORITMO DE REGULARIZAÇÃO BAYESIANA PARA O CENÁRIO 1	92
TABELA 31: EFICÁCIAS DO 2º ESTÁGIO DA RNA COM ALGORITMO LEVENBERG MARQUARDT PARA O CENÁRIO 1	93
TABELA 32: EFICÁCIAS DO 2º ESTÁGIO DA RNA COM ALGORITMO GRADIENTE CONJUGADO ESCALONADO PARA O CENÁRIO 1	93
TABELA 33: TOPOLOGIA ESCOLHIDA DO SEGUNDO ESTÁGIO DA RNA PARA O CENÁRIO 1	94

TABELA 34: RESULTADOS DOS TESTES DO 2º ESTÁGIO DA RNA PARA OUTROS PONTOS DE DEFEITO NO CENÁRIO 1	96
TABELA 35: COEFICIENTES DE CORRELAÇÃO DA RNAAL1 COM ALGORITMO REGULARIZAÇÃO BAYESIANA PARA O CENÁRIO 1	97
TABELA 36: COEFICIENTES DE CORRELAÇÃO DA RNAAL1 COM ALGORITMO LEVENBERG-MARQUARDT PARA O CENÁRIO 1	97
TABELA 37: COEFICIENTES DE CORRELAÇÃO DA RNAAL1 COM ALGORITMO GRADIENTE CONJUGADO ESCALONADO PARA O CENÁRIO 1.....	98
TABELA 38: TOPOLOGIA ESCOLHIDA DA RNAAL1 PARA O CENÁRIO 1	98
TABELA 39: RESULTADOS DOS TESTES DA RNAAL1 PARA OUTROS PONTOS DE DEFEITO NO CENÁRIO 1 ...	99
TABELA 40: COEFICIENTES DE CORRELAÇÃO DA RNAAL2 COM ALGORITMO REGULARIZAÇÃO BAYESIANA PARA O CENÁRIO 1	100
TABELA 41: COEFICIENTES DE CORRELAÇÃO DA RNAAL2 COM ALGORITMO LEVENBERG-MARQUARDT PARA O CENÁRIO 1	101
TABELA 42: COEFICIENTES DE CORRELAÇÃO DA RNAAL2 COM ALGORITMO GRADIENTE CONJUGADO ESCALONADO PARA O CENÁRIO 1.....	101
TABELA 43: TOPOLOGIA ESCOLHIDA DA RNAAL2 PARA O CENÁRIO 1	102
TABELA 44: RESULTADOS DOS TESTES DA RNAAL2 PARA OUTROS PONTOS DE DEFEITO NO CENÁRIO 1 .	103
TABELA 45: COEFICIENTES DE CORRELAÇÃO DA RNAAL3 COM ALGORITMO REGULARIZAÇÃO BAYESIANA PARA O CENÁRIO 1	104
TABELA 46: COEFICIENTES DE CORRELAÇÃO DA RNAAL3 COM ALGORITMO LEVENBERG-MARQUARDT PARA O CENÁRIO 1	104
TABELA 47: COEFICIENTES DE CORRELAÇÃO DA RNAAL3 COM ALGORITMO GRADIENTE CONJUGADO ESCALONADO PARA O CENÁRIO 1.....	105
TABELA 48: TOPOLOGIA ESCOLHIDA DA RNAAL3 PARA O CENÁRIO 1	105
TABELA 49: RESULTADOS DOS TESTES DA RNAAL3 PARA OUTROS PONTOS DE DEFEITO NO CENÁRIO 1 .	106
TABELA 50: COMPARAÇÃO DO Nº DE ENTRADAS DAS RNAs PARA OS CENÁRIOS ESTUDADOS	107
TABELA 51: TOPOLOGIA ESCOLHIDA DO PRIMEIRO ESTÁGIO DA RNA PARA O CENÁRIO 2.....	108
TABELA 52: RESULTADOS DOS TESTES DO 1º ESTÁGIO DA RNA PARA OUTROS PONTOS DE DEFEITO NO CENÁRIO 2.....	109
TABELA 53: EFICÁCIAS DO 2º ESTÁGIO DA RNA COM ALGORITMO REGULARIZAÇÃO BAYESIANA PARA O CENÁRIO 2.....	110
TABELA 54: EFICÁCIAS DO 2º ESTÁGIO DA RNA COM LEVENBERG-MARQUARDT PARA O CENÁRIO 2	110
TABELA 55: EFICÁCIAS DO 2º ESTÁGIO DA RNA COM ALGORITMO GRADIENTE CONJUGADO ESCALONADO PARA O CENÁRIO 2	111
TABELA 56: TOPOLOGIA ESCOLHIDA DO SEGUNDO ESTÁGIO DA RNA PARA O CENÁRIO 2.....	111
TABELA 57: RESULTADOS DOS TESTES DO 2º ESTÁGIO DA RNA PARA OUTROS PONTOS DE DEFEITO NO CENÁRIO 2.....	113
TABELA 58: COEFICIENTES DE CORRELAÇÃO DA RNAAL1 COM ALGORITMO REGULARIZAÇÃO BAYESIANA PARA O CENÁRIO 2	113

TABELA 59: COEFICIENTES DE CORRELAÇÃO DA RNAAL1 COM ALGORITMO LEVENBERG-MARQUARDT PARA O CENÁRIO 2	114
TABELA 60: COEFICIENTES DE CORRELAÇÃO DA RNAAL1 COM ALGORITMO GRADIENTE CONJUGADO ESCALONADO PARA O CENÁRIO 2.....	114
TABELA 61: TOPOLOGIA ESCOLHIDA DA RNAAL1 PARA O CENÁRIO 2	115
TABELA 62: RESULTADOS DOS TESTES DA RNAAL1 PARA OUTROS PONTOS DE DEFEITO NO CENÁRIO 2 .	115
TABELA 63: COEFICIENTES DE CORRELAÇÃO DA RNAAL2 COM ALGORITMO REGULARIZAÇÃO BAYESIANA PARA O CENÁRIO 2	116
TABELA 64: COEFICIENTES DE CORRELAÇÃO DA RNAAL2 COM ALGORITMO LEVENBERG-MARQUARDT PARA O CENÁRIO 2	117
TABELA 65: COEFICIENTES DE CORRELAÇÃO DA RNAAL2 COM ALGORITMO GRADIENTE CONJUGADO ESCALONADO PARA O CENÁRIO 2.....	117
TABELA 66: TOPOLOGIA ESCOLHIDA DA RNAAL2 PARA O CENÁRIO 2	118
TABELA 67: RESULTADOS DOS TESTES DA RNAAL2 PARA OUTROS PONTOS DE DEFEITO NO CENÁRIO 2 .	118
TABELA 68: COEFICIENTES DE CORRELAÇÃO DA RNAAL3 COM ALGORITMO DE REGULARIZAÇÃO BAYESIANA PARA O CENÁRIO 2.....	119
TABELA 69: COEFICIENTES DE CORRELAÇÃO DA RNAAL3 COM ALGORITMO LEVENBERG-MARQUARDT PARA O CENÁRIO 2	120
TABELA 70: COEFICIENTES DE CORRELAÇÃO DA RNAAL3 COM ALGORITMO GRADIENTE CONJUGADO ESCALONADO PARA O CENÁRIO 2.....	120
TABELA 71: TOPOLOGIA ESCOLHIDA DA RNAAL3 PARA O CENÁRIO 2	121
TABELA 72: RESULTADOS DOS TESTES DA RNAAL3 PARA OUTROS PONTOS DE DEFEITO NO CENÁRIO 2 .	121
TABELA 73: COMPARAÇÃO DOS ERROS MÉDIOS DOS CENÁRIOS 1 E 2	122

CAPÍTULO 1

INTRODUÇÃO

1.1 Motivação

O termo geração distribuída (GD) é atribuído a pequenas e médias unidades geradoras conectadas diretamente à rede de distribuição de energia [1]. A crescente inserção desse tipo de geração pode apresentar vantagens ao sistema e ao consumidor, como redução de perdas e melhora no controle de tensão. Entretanto, a massiva penetração da GD pode trazer impactos significativos no planejamento da operação de redes de distribuição.

Um dos pontos sensíveis à inserção da GD é a resposta dos sistemas de proteção. Essa mudança de paradigma representa um novo desafio na forma tradicional de proteger o sistema e eliminar as falhas. Desde a sua concepção até a compra de equipamentos, os esquemas de proteção são elaborados a partir de estudos de fluxo de potência e curto-circuito, os quais podem ser influenciados pela conexão das GDs. Assim, é preciso reavaliar todo o projeto do sistema de proteção, simulando as diversas condições operativas desse novo sistema.

É a partir disso que surgiu a principal motivação deste trabalho: analisar situações nas redes de distribuição em que a proteção do alimentador existente falhe ou atue indevidamente devido à presença de geração distribuída e buscar uma solução para este problema.

Dentre as diversas soluções apresentadas pela literatura, o uso de redes neurais artificiais (RNAs) se mostrou como uma alternativa interessante. Determinados tipos de defeitos na presença de GDs podem simplesmente não serem detectados pelos relés de sobrecorrente de tempo definido dos alimentadores, ou mesmo serem eliminados em um

intervalo de tempo muito longo pelos relés de tempo inverso. Dessa forma, a proposta desse trabalho tem foco na inserção das RNAs para a detecção de faltas no sistema, atuando como uma proteção redundante da proteção principal, entretanto, de tecnologia distinta.

A saída encontrada priorizou o aproveitamento da infraestrutura local da rede, sem a necessidade de altos investimentos financeiros e nem de esquemas avançados de proteção, como os que são encontrados em redes de transmissão de energia.

Outro aspecto determinante para a escolha das RNAs é a possibilidade de localização dos defeitos. Na prática, a detecção e a localização de faltas em sistemas de distribuição são possíveis pelas concessionárias de energia por métodos de força bruta ou indicações físicas [2], tais como: queima de fusíveis ou dispositivos indicadores de faltas; queda de condutores; reclamação de consumidores; e, finalmente, inspeções visuais ao longo dos alimentadores. Tais alternativas podem elevar em muito o tempo de restabelecimento do sistema.

Além disso, nota-se uma dificuldade de aplicação dos métodos tradicionais de localização de falta existentes para redes de transmissão de energia em sistemas de distribuição [3]. Propostas como ondas viajantes ou uso de relés de distância apresentam dificuldades de aplicabilidade pelas características intrínsecas das redes de distribuição, como o uso de seções de rede com condutores de diferentes bitolas e o desconhecimento da impedância exata dos alimentadores. A própria presença das GDs também aumenta a complexidade do problema, assim como os diferentes níveis de carregamento do sistema, que influenciam diretamente nas correntes e tensões pré-falta.

A escolha de um método de localização de falta ocorre de acordo com a disponibilidade de equipamentos de medição e controle na rede. Quanto maior for o volume de informações disponíveis na rede, mais precisos serão os resultados. Entretanto, nem sempre a rede conta com infraestrutura suficiente para possibilitar o monitoramento de diversos pontos na rede.

Dessa forma, as lacunas existentes dos métodos tradicionais podem ser superadas através da utilização das RNAs. Permite-se assim a localização de defeitos unicamente por meio do monitoramento das correntes injetadas pelas GDs e pela subestação na rede.

Além disso, as RNAs contribuem para uma melhora nos índices de confiabilidade tais como o de duração equivalente de interrupção por unidade consumidora (DEC) [4], à medida que permitem uma maior agilidade para as equipes de reparo das concessionárias de distribuição de energia. Tais equipes são capazes de acessar o ponto da falta com maior rapidez e assim restabelecer o funcionamento da rede.

1.2 Objetivo

O objetivo deste trabalho é propor um método de proteção redundante para redes de distribuição ativas de energia baseadas em redes neurais artificiais. O método deve ser capaz de detectar e localizar defeitos em redes com inserção de geração distribuída.

O emprego das redes neurais artificiais busca solucionar casos de mau funcionamento ou não-operação da proteção existente devido à presença das GDs. São utilizadas redes de arquitetura *feedforward* do tipo *Perceptron* Multicamadas (PMC). A topologia e desempenho dessas redes são otimizadas de acordo com a configuração do sistema estudado, sendo específica para cada caso.

1.3 Revisão Bibliográfica

Estudos sobre a proteção de redes ativas de distribuição de energia são vastos na literatura, acompanhando a crescente inserção de geração distribuída nesses sistemas. Nesta seção, são apresentadas algumas das estratégias adotadas a respeito desse assunto.

Em [5], BRAHMA et al. propõem um esquema de proteção adaptativa para redes de distribuição com geração distribuída. Separado em duas etapas (*offline* e *online*), o método proposto monitora continuamente os fasores de correntes de todas as fontes do sistema (GDs e subestação). De maneira *offline*, são realizadas análises de fluxo de potência e de curto-circuito para toda a rede. O sistema de distribuição é dividido em zonas, sendo cada uma caracterizada pelo balanceamento de sua carga instalada e a potência da GD. Através do cálculo da contribuição da corrente de falta de cada unidade de GD, o ajuste do relé é parametrizado para acionar o disjuntor de cada zona do sistema de forma *online*, isolando o defeito.

Em [6], REZAEI et al. desenvolvem esquemas de proteção baseados em RNAs *perceptron* multicamadas para identificação do local do defeito em redes de distribuição. A solução inclui também o uso das correntes das fontes e estudos *offline* e *online*, com a divisão do sistema em zonas. No estudo *offline* a rede neural é treinada através dos dados de injeção de correntes das fontes e da subestação, para que seja capaz de identificar a falta, classificá-la e localizá-la. A fase *online* é caracterizada pela ocorrência da falta e atuação da rede neural. É apresentada também a possibilidade de recomposição do sistema para defeitos temporários.

Em [7], ZAYANDEHROODI et al. elaboram um método de proteção automática para redes de distribuição com geração distribuída utilizando redes neurais de base radial (RBF). O processo consiste em três passos. No primeiro, ocorre a formação de banco de dados, com informações de estudos de fluxo de potência e curto-circuito do sistema e divisão do sistema em zonas. O segundo passo inicia-se pela identificação do tipo de falta baseada na normalização da corrente. Em seguida, a RNA é responsável pela detecção do trecho faltoso, identificação da distância da falta para cada fonte e determinação de qual disjuntor deve ser aberto. Por fim, o terceiro passo estabelece um método para restauração do sistema.

Em [8], SUNG et al. apresentam um sistema de proteção adaptativa para assegurar a coordenação e a correta operação de relés de sobrecorrente de tempo inverso em redes de distribuição na presença de GDs. Para isso, é proposto o monitoramento constante do sistema, adaptando os ajustes de acordo com as suas variações. São consideradas GDs compostas por máquinas síncronas.

Em [9], ANANDA et al. introduzem o uso da abordagem multiagente na proteção de redes de distribuição ativas baseada em um banco de dados distribuído. Esses sistemas multiagentes são usados para distribuir o algoritmo de proteção adaptativa em agentes e reduzir o tempo de operação de todo sistema de proteção.

Em [10], KUMAR et al. propõem um esquema de proteção adaptativo que combina vantagens do uso da lógica *fuzzy* e das redes neurais artificiais. Um relé *fuzzy* adaptativo é desenvolvido, composto por um módulo de lógica *fuzzy* e outro módulo de aprendizado de uma rede neural. Esses módulos combinados são capazes de decidir as

configurações ótimas de proteção do relé correspondentes às mudanças na rede de distribuição pela presença da GD.

Em [11], CHAKOR et al. analisam o impacto das GDs na coordenação dos relés de sobrecorrente em alimentadores de distribuição. A solução proposta visa otimizar os ajustes das curvas de operação dos relés de sobrecorrente de tempo inverso dos alimentadores através do uso de algoritmos genéticos.

Em [12], NIKOLAIDIS et al. desenvolvem um esquema de proteção baseado em relés de distância para redes de distribuição ativas. São analisados os parâmetros que influenciam no desempenho da proteção de distância em redes de distribuição. A coordenação entre os relés de distância e a proteção existente também é explorada.

Em [13], PETITE et al. apresentam um esquema baseado em redes neurais artificiais para localização de defeitos monofásicos em sistemas de distribuição com geração distribuída. São utilizados dois tipos de RNAs. O primeiro tem a capacidade de detectar em qual parte do sistema de distribuição o defeito ocorreu, e o segundo é capaz de precisar o local exato da falta. A metodologia proposta é viável a partir do uso das tensões das barras ao longo dos alimentadores de distribuição de energia.

O presente trabalho aproveitará conceitos dos métodos elaborados por [6], [7] e [13] ao utilizar as redes neurais artificiais como solução do problema. Também serão utilizados dados das correntes elétricas das fontes do sistema para treinamento e entrada das RNAs. Entretanto, a metodologia proposta buscará aproveitar a estrutura de monitoramento já disponível no sistema de distribuição, sem necessitar de medição fasorial em tempo real.

1.4 Estrutura do Trabalho

O trabalho está estruturado da seguinte forma:

O Capítulo 2 apresenta os principais impactos da inserção da geração distribuída em redes de distribuição de energia. São retratados os benefícios e malefícios dessa prática, bem como os desafios e possíveis soluções para se adequar ao novo cenário de operação dessas redes.

No Capítulo 3, tem-se um detalhamento de como é feita a proteção em redes de distribuição de energia. São descritos os principais equipamentos utilizados. O enfoque também passa pelas estratégias de solução tomadas para redes de distribuição ativas, as quais possuem geradores distribuídos conectados.

No Capítulo 4, os principais conceitos relacionados a redes neurais artificiais são discutidos. São descritos aspectos básicos de um neurônio artificial, os algoritmos de aprendizado mais comuns e as principais arquiteturas empregadas.

O Capítulo 5 apresenta a estratégia de solução dada ao problema e os resultados obtidos através de simulações. São apresentados os impactos da inserção da geração distribuída na proteção sobrecorrente de alimentadores de uma rede de distribuição e a solução baseada em RNAs para detecção e localização de defeitos é desenvolvida.

Finalmente, o Capítulo 6 é composto pelas principais conclusões deste trabalho e sugestões para desenvolvimentos de trabalhos futuros.

CAPÍTULO 2

IMPACTOS DA GERAÇÃO DISTRIBUÍDA EM REDES DE DISTRIBUIÇÃO

2.1 Introdução

Neste capítulo, serão apresentados os principais impactos da inserção de geração distribuída em redes de distribuição de energia.

Historicamente, os sistemas elétricos foram concebidos com a utilização de grandes fontes de geração localizadas longe dos centros urbanos e um sistema de transmissão responsável pela transferência da energia produzida até as subestações de distribuição. As próprias redes de distribuição radiais foram projetadas para operar com sentido único de fluxo de energia, partindo das subestações até chegar aos consumidores.

Segundo [14], uma série de influências combinadas levaram ao interesse do desenvolvimento da geração mais próxima do consumidor final. Destaca-se o fator ambiental como principal estímulo, evidenciado pelo suporte à geração renovável, tais como as usinas eólicas, as pequenas centrais hidrelétricas, o uso massivo de painéis fotovoltaicos e a geração a partir da biomassa.

Outros fatores também podem ser citados, como a busca pelo aumento da confiabilidade no fornecimento de energia que motivou o acréscimo do número de unidades geradoras de pequeno e médio porte conectadas diretamente na rede de

distribuição. Tem-se do mesmo modo os benefícios que a diversificação de fontes de geração de energia trazem ao sistema. Para países com escassez de recursos, novas fontes de geração são bem-vindas e reduzem a dependência com relação aos combustíveis fósseis.

Uma vez inserida no sistema, a GD pode trazer diferentes impactos, manifestados de forma positiva ou negativa, dependendo das características dos geradores inseridos e das condições de operação da rede. Inicialmente, a presença das GDs sugere uma possibilidade de expansão e melhor operação das redes de distribuição, uma vez que a energia é disponibilizada mais próximo da carga. Entretanto, em alguns casos caracterizados por uma elevada injeção de potência da GD, pode ocorrer um fluxo reverso no alimentador, uma piora do controle de tensão e provocar um aumento das perdas [15].

À medida que o nível de injeção de potência aumenta, superando em muitos casos a demanda das cargas instaladas nos alimentadores em que estão conectadas, uma nova filosofia de operação deve ser adotada. Nas próximas seções serão exemplificados os principais impactos da geração distribuída em redes de distribuição.

2.2 Alteração dos Níveis de Curto-Circuito

Os níveis de curto-circuito se alteram com a entrada de unidades de geração distribuída no sistema. Um aumento mais significativo pode ser observado na presença de GDs baseadas em máquinas síncronas, as quais têm uma contribuição maior para os defeitos no sistema. No caso de geradores conectados via conversores eletrônicos, como é o caso da geração solar fotovoltaica, a contribuição para o curto-circuito depende do controle adotado. Em geral, como os conversores operam com controle de corrente, essa contribuição não é significativa [16].

Dessa forma, deve ser realizada uma análise dos novos níveis de falta do sistema de forma que os seus impactos sejam minimizados. Equipamentos de proteção como disjuntores e seus relés associados devem operar agora para novos níveis de curto-circuito, sem que a coordenação, sensibilidade, confiabilidade, seletividade e velocidade sejam afetadas [17].

2.3 Alteração do Perfil de Tensão

Outro impacto significativo da geração distribuída nas redes de distribuição é a possível alteração no perfil de tensão do sistema. Nas redes de distribuição, tanto os níveis de potência ativa como reativa injetados podem ter influência direta no perfil de tensão resultante. Isso se deve ao fato do baixo valor da relação X/R nessas redes, provocando assim um acoplamento maior entre tensão e a injeção da potência ativa nos pontos de conexão [18]. A conexão da GD representa, em geral, uma elevação da tensão no ponto de acoplamento, impactando no perfil de tensão de todo o alimentador. Esse impacto pode causar danos não só aos equipamentos da rede da concessionária de distribuição, mas também nos consumidores finais da energia.

Ademais, as alterações no perfil de tensão não são causadas apenas pela injeção de potência no sistema. A inserção da GD pode levar a descoordenações entre banco de capacitores, reguladores de tensão do alimentador e/ou do gerador, fato que pode resultar em sobretensões e/ou subtensões no sistema [19]. O impacto no perfil é diferente de acordo com o ponto de conexão da GD ao longo do alimentador, considerando a distância do mesmo para a subestação.

Os Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) [20] padronizam aspectos técnicos referentes ao bom funcionamento de sistemas de distribuição de energia. Em seu Módulo 8 – Qualidade de Energia Elétrica, é detalhada a faixa de classificação de tensões de regime permanente. Para sistemas com tensão entre 1kV e 69kV, a magnitude de tensão é classificada de acordo com a Tabela 1. Tais valores são válidos para o sistema de distribuição estudado neste trabalho.

Tabela 1: Pontos de conexão em tensão nominal superior a 1kV e inferior a 69kV [20]

Tensão de Atendimento (TA)	Faixa de Variação da Tensão de Leitura (TL) em Relação à Tensão de Referência (TR)
Adequada	$0,93TR \leq TL \leq 1,05TR$
Precária	$0,90TR \leq TL \leq 0,93TR$
Crítica	$TL < 0,9TR$ ou $TL > 1,05TR$

2.4 Limite Térmico

Dependendo da injeção de potência da GD, estudos prévios por parte da concessionária de distribuição são necessários para permitir a conexão segura, tanto para a rede como para o próprio gerador distribuído. Esses estudos são fundamentais para a análise do perfil de tensão do sistema e também para outro aspecto da rede: o limite térmico dos cabos dos alimentadores.

Determinar o quão seguro é o nível de penetração da geração distribuída em um determinado ponto do alimentador de distribuição pode ser um problema complexo, exigindo uma análise antecipada. Cada tipo de cabo empregado no alimentador possui um limite térmico de operação, o qual está ligado diretamente a sua capacidade máxima de condução de corrente. A inserção de GDs aumenta a injeção de potência no sistema, podendo sim ultrapassar o limite térmico dos cabos.

Em algumas situações, torna-se necessário o recondutoramento de trechos da rede de distribuição para permitir a conexão de novos geradores. Esse recondutoramento prevê a substituição dos cabos existentes por outros de maior bitola, aumentando a sua capacidade de transferência de energia.

A referência [18] apresenta uma metodologia expedita para a avaliação da máxima potência ativa líquida que pode ser injetada por uma GD, descontada a carga no ponto de conexão. O método proposto garante o atendimento aos limites da capacidade de condução de corrente dos cabos do alimentador e aos limites de tensão máximo e mínimo no ponto de conexão.

2.5 Redistribuição dos Fluxos de Potência

O fluxo unidirecional de energia partindo da subestação para atender os consumidores pode ser alterado com a inserção da GD no sistema. O fluxo agora não se dá necessariamente nesse sentido convencional. O nível de perdas do sistema também é alterado, aumentando ou diminuindo de acordo com as características da GD e de sua instalação.

Dependendo do nível de injeção, a GD pode não só suprir toda a demanda do alimentador em que está instalada como também provocar um fluxo inverso de energia, partindo das cargas em direção à subestação. Se a potência de saída do gerador distribuído for menor que a carga a jusante do seu ponto de conexão, a presença das unidades geradoras leva a uma redução do fluxo de potência entre o seu ponto de conexão e a subestação, sem impactar as cargas a jusante de sua instalação.

2.6 Ilhamento

A presença da geração distribuída no sistema pode levar ao surgimento de microrredes – o chamado fenômeno do ilhamento. O termo microrrede é utilizado para caracterizar redes autônomas capazes de operar sem a necessidade do suprimento de energia direto por parte da concessionária. A operação nesse tipo de rede deve estar de acordo com critérios de desempenho e qualidade, e para isso são necessários equipamentos que agreguem automação e comunicação de dados em tempo real [21].

A operação ilhada pode ocorrer de duas formas distintas: intencional ou não-intencional. O ilhamento intencional deve ser realizado quando for tecnicamente e financeiramente viável, seja para a concessionária da rede de distribuição como para o proprietário da unidade de geração distribuída. Esse tipo de fenômeno pode ocorrer por eventos pré-determinados, em que existe um interesse para que o sistema opere ilhado, ou então por um defeito no sistema. Para isso, é imprescindível que o mesmo tenha uma flexibilidade para operar de forma isolada ou interligada.

No caso de ilhamentos não-intencionais, o sistema não é planejado para operar desconectado da rede da concessionária. Assim, de acordo com a norma internacional [22], para esses casos são exigidos não só a detecção do ilhamento, como também que o gerador distribuído seja desconectado do sistema em no máximo 2 segundos. Essa exigência se dá pois, se a rede não é planejada para operar de forma ilhada, um ilhamento não-intencional pode levar a níveis de tensão e frequência a valores fora dos limites aceitáveis. Além disso, o sistema de aterramento também pode ser inadequado devido à presença dos geradores distribuídos e existe a preocupação em relação à segurança do corpo técnico de manutenção da empresa, visto que trechos da rede podem se manter energizados. Assim, é fundamental que haja a detecção rápida do ilhamento. Existem

diferentes técnicas para essa detecção e a escolha de qual optar depende de sua viabilidade técnica e econômica para cada caso. Pode-se citar técnicas remotas, caracterizadas pela existência de algum tipo de comunicação com a concessionária, dispositivos de proteção e o gerador distribuído, e as técnicas locais, baseadas na medição de grandezas elétricas como tensão e corrente disponíveis no local de instalação da GD [23].

2.7 Falha nos Sistemas de Proteção Existentes

Em sua maioria, as redes de distribuição possuem característica radial, sendo protegidas por relés de sobrecorrente de fase e de neutro. Eventualmente pode-se ter religadores fusíveis, equipamentos comuns utilizados para proteção de ramais de distribuição.

Esse tipo de proteção convencional pode se tornar defasada com o novo cenário projetado para as redes de distribuição. A partir da inserção da GD no sistema, fatores como fluxo de potência, níveis de tensão e curto-circuito são alterados, impactando diretamente na proteção existente [24]. Nos casos em que existe uma elevação considerável dos níveis de curto-circuito no sistema, pode ser necessário alterar os ajustes dos relés para se adequar à nova condição.

Outro aspecto agravante é a característica estocástica de alguns geradores distribuídos, não garantindo assim uma injeção constante de potência no local de conexão. De acordo com [14], esse desafio também está ligado à proteção da interligação do gerador com a rede e na sua capacidade de coordenação com as proteções já existentes, tanto em estado permanente como também sob condição de falta.

A inserção da GD pode provocar falhas nas proteções existentes à medida que as mesmas podem ser dessensibilizadas na ocorrência de um defeito no sistema. Ademais, é possível também uma operação indevida do sistema de proteção, desligando desnecessariamente parte da rede de distribuição. Esquemas de coordenação entre equipamentos de proteção, como entre fusíveis e religadores, podem não mais atuar corretamente [25].

De modo geral, o grau de impacto da GD no sistema de proteção varia de acordo com uma série de fatores. A análise deve ser feita caso a caso e é específica para cada nova configuração do sistema. No Capítulo 3 serão apresentadas as características principais da proteção convencional de redes de distribuição e também serão detalhados alguns aspectos importantes da inserção da geração distribuída que afetam o sistema de proteção.

CAPÍTULO 3

PROTEÇÃO DE REDES DE DISTRIBUIÇÃO

3.1 Introdução

Este capítulo apresenta conceitos e os principais componentes da proteção de redes de distribuição de energia. Os sistemas de distribuição são responsáveis pela transferência da energia do sistema geração e transmissão para o consumidor final. Dessa forma, a confiabilidade do sistema está fortemente ligada ao desempenho de sua proteção e sua capacidade de isolar e/ou eliminar defeitos [25].

Os esquemas de proteção utilizados são basicamente comandados por relés [26]. Esses equipamentos são os principais protagonistas do sistema e devem ser capazes de identificar, localizar, isolar um defeito ou remover uma condição anormal. Entende-se por anormalidade algo que provoque desligamentos forçados no sistema. Por exemplo, a retirada de operação de algum componente, seja devido a uma situação de emergência ou ação indevida, causada por uma pessoa ou por uma falha em algum equipamento.

Basicamente, o relé atua como um sensor. Ao receber uma ou mais grandezas elétricas, o mesmo as compara com valores pré-ajustados. Havendo uma anomalia, por exemplo, um curto-circuito, o relé é sensibilizado e opera enviando um sinal para a abertura de um disjuntor. Dessa forma, o trecho defeituoso é desconectado do sistema.

Embora a função de sobrecorrente seja a mais difundida em sistemas de proteção de redes de distribuição, o dispositivo pode assumir também uma série de outras funções. A Tabela 2 exemplifica algumas das mais utilizadas.

Tabela 2: Funções dos Relés de Proteção

Código	Função
21	Distância
25	Verificação de sincronismo
27	Subtensão
32	Direcional de potência
50	Sobrecorrente instantâneo
51	Sobrecorrente temporizado
59	Sobretensão
67	Direcional de sobrecorrente
79	Religamento
81	Frequência (sub ou sobre)
87	Proteção diferencial

Os princípios construtivos e de funcionamento dos relés evoluíram ao longo do tempo, mas a filosofia de proteção se mantém essencialmente a mesma. A fim de se manter a qualidade no fornecimento de energia elétrica, os sistemas de proteção devem atender aos seguintes princípios básicos:

- **Confiabilidade** – O sistema deve atuar corretamente quando solicitado, e conjuntamente, não deve atuar desnecessariamente quando não é esperado que opere;
- **Sensibilidade** – É a capacidade do sistema de proteção de identificar uma anormalidade no sistema, dentro dos parâmetros de projeto;
- **Seletividade** – O sistema deve ser capaz de isolar apenas o trecho defeituoso, mantendo em operação o restante da rede;
- **Velocidade** – O sistema de proteção deve ser rápido na eliminação de um defeito a fim de reduzir os danos causados pelo mesmo.

A seguir, são detalhados alguns conceitos da proteção convencional de redes de distribuição de energia.

3.2 Proteção Convencional

As proteções das redes de transmissão e distribuição possuem filosofias bem distintas entre si. Na transmissão, a proteção atua buscando evitar blecautes de grandes proporções, mantendo o sistema operando e garantindo sua estabilidade. Em geral, os esquemas de proteção observados nas redes de transmissão são mais sofisticados, visto que normalmente grandes blocos de potência são transferidos e configurações altamente malhadas são utilizadas.

Já em redes de distribuição o cenário é diferente. O principal objetivo é manter a continuidade, melhorando os índices de confiabilidade da rede. A topologia da rede em sua maioria radial permite o uso de proteções mais simples, com fluxo unidirecional de energia e baseadas em relés de sobrecorrente sem a característica direcional. Em geral busca-se otimizar a continuidade do serviço para o número máximo de consumidores através de um custo mínimo [27].

A Figura 1 apresenta um esquema convencional utilizado para proteção de alimentadores aéreos de distribuição de energia. No início de cada alimentador, tem-se disjuntores com relés associados. Normalmente são utilizadas as funções de sobrecorrente de fase e de neutro, tempo definido e tempo inverso.

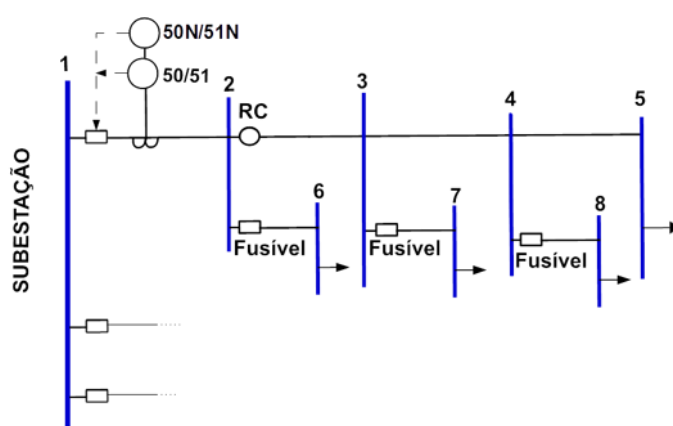


Figura 1: Esquema convencional de proteção de alimentadores aéreos de distribuição

Ao longo do alimentador, pode-se utilizar religadores automáticos (RC) visando melhorar os índices de continuidade do sistema. Os ramais dos alimentadores são protegidos por fusíveis em função do menor custo. Ademais, é preciso que haja uma coordenação entre os dispositivos para um correto funcionamento do esquema de proteção.

O objetivo da coordenação é permitir que dois ou mais dispositivos de proteção dispostos em série atuem em uma sequência de operação pré-estabelecida. Exemplos utilizados são da coordenação entre religadores e fusíveis e entre religadores e seccionadores, outros equipamentos comumente utilizados para proteção de sistemas de distribuição.

3.2.1 Principais Componentes

A seguir, são detalhados sucintamente alguns dos principais componentes utilizados na proteção das redes de distribuição.

3.2.1.1 Relés de Sobrecorrente

Os relés são responsáveis por eliminar defeitos de forma mais rápida e eficiente possível, de maneira a não somente reduzir o impacto no sistema como no próprio componente. Um mesmo relé é capaz de realizar uma ou mais funções de proteção dependendo da tecnologia do mesmo.

Para as redes de distribuição, as funções mais utilizadas são as de sobrecorrente de fase (função 50/51) e de neutro (função 50N/51N). Pode-se ainda dividir a função de sobrecorrente da seguinte forma: quando emprega um tempo definido de operação (50/50N) ou quando utiliza uma curva de tempo inverso (51/51N).

O relé de sobrecorrente de tempo definido necessita basicamente de duas grandezas para sua operação: o valor de *pick-up* e a sua temporização. O valor de *pick-up* é o valor mínimo para o qual o relé é sensibilizado, ou seja, o valor de corrente a partir do qual o relé está apto a operar ou emitir um alarme.

Já a temporização é o tempo mínimo que a grandeza monitorada deve permanecer acima do valor de *pick-up* para que o relé opere. Em relés ditos instantâneos, o valor da temporização é nulo, ou seja, não há temporização intencional.

Por outro lado, o funcionamento do relé de sobrecorrente de tempo inverso é um pouco mais complexo, visto que seu tempo de operação não é fixo. A curva de operação dos relés de tempo inverso é estabelecida, por exemplo, pela norma [28] e é apresentada pela expressão (3.1):

$$t = \frac{A}{(M^p - 1)} + B \quad (3.1)$$

Os valores das constantes *A*, *B* e *p* são apresentados na Tabela 3, de acordo com a característica da curva de operação do relé – moderada, muito inversa e extremamente inversa. *M* é o múltiplo do valor de *pick-up*, dado pela relação entre a corrente medida pelo relé durante o defeito e seu valor de ajuste. A Figura 2 ilustra o comportamento de cada característica presente na Tabela 3. Note-se que, nas três características, o tempo de atuação é reduzido à medida que a corrente observada aumenta.

Tabela 3: Constantes para as curvas do relé de tempo inverso [28]

Característica	A	B	P
Moderadamente Inversa	0,0515	0,1140	0,02
Muito Inversa	19,61	0,491	2
Extremamente Inversa	28,2	0,1217	2

Qualquer uma das três curvas pode ser ajustada de forma proporcional ao longo do eixo de tempo por meio de um parâmetro adicional, denominado alavanca, multiplicador ou dial de tempo. Desse modo, quanto maior for o valor do dial de tempo maior será o tempo para a atuação do relé. Logo, para realizar o ajuste do relé de sobrecorrente de tempo inverso, são necessários os seguintes parâmetros: valor de *pick-up*, tipo de curva inversa e dial de tempo.

Considerando a proteção de um alimentador de distribuição, a referência [26] sugere uma forma de realizar o correto dimensionamento de um relé de sobrecorrente de

fase de tempo inverso para garantir uma segura e adequada operação do mesmo, de acordo com (3.2):

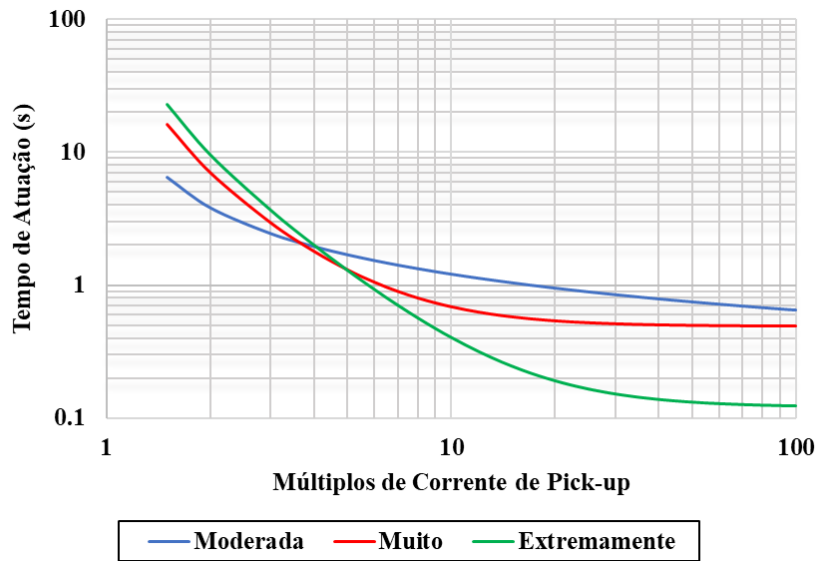


Figura 2: Curvas para relés de sobrecorrente de tempo inverso [28]

$$(1,4 \text{ a } 1,5) * I_{nom \text{ de carga}} \leq I_{ajuste \text{ do relé}} \leq \frac{I_{CC \text{ min final alimentador protegido}}}{a} \quad (3.2)$$

Sendo:

$$\begin{cases} a=1,5 \text{ (relés eletromecânicos)} \\ a=1,1 \text{ (relés digitais)} \end{cases}$$

O limite mínimo da inequação (3.2) estabelece as flutuações de carga rotineiras do sistema que o relé deve suportar sem operar. É proposta uma folga de 40% a 50% a mais da corrente nominal em condições de carga pesada, correspondente a uma margem no valor máximo de consumo do sistema.

Já o limite máximo estipula a mínima corrente de defeito no alimentador protegido para a qual o relé deve atuar com absoluta garantia. O parâmetro a consiste em uma margem para garantir que a menor corrente de curto-circuito seja no pior caso apenas 1,5 ou 1,1 vezes o limiar de operação do relé. Os valores assumidos para o parâmetro a dependem do tipo de relé que é utilizado (eletromecânico ou digital).

A referência [26] indica ainda que a corrente mínima no final do alimentador protegido deverá ser obtida na operação em carga leve do sistema. Visando a sensibilidade nos relés de fase, é estabelecido que a menor corrente de defeito é a bifásica, obtida por (3.3):

$$I_{CC2\phi} \leq \frac{\sqrt{3}}{2} I_{CC3\phi} \quad (3.3)$$

Os termos $I_{CC2\phi}$ e $I_{CC3\phi}$ correspondem às correntes de defeito bifásico e trifásico no final do alimentador protegido, respectivamente. Dessa forma, o relé possui sensibilidade para detectar todas as possíveis correntes de defeito no alimentador.

Para relés de sobrecorrente de neutro, os ajustes obedecem à expressão (3.4):

$$(0,10 \text{ a } 0,45) * I_{nom \text{ de carga}} \leq I_{ajuste \text{ relé}} \leq \frac{I_{CC \ 1\phi-T \text{ final alimentador protegido}}}{a} \quad (3.4)$$

Sendo:

$$\begin{cases} a=1,5 \text{ (relés eletromecânicos)} \\ a=1,1 \text{ (relés digitais)} \end{cases}$$

Os relés de neutro são sensíveis apenas às correntes de sequência zero do sistema e representam um avanço no sistema de proteção, permitindo detectar pequenos curtos-circuitos envolvendo a terra.

O limite superior da inequação (3.4) é calculado a partir da corrente de defeito monofásica no final do alimentador protegido, $I_{CC \ 1\phi-T \text{ final alimentador protegido}}$, dividido pelo parâmetro a . Novamente, esse parâmetro indica uma margem para garantir que no pior caso a menor corrente de curto-circuito seja apenas 1,5 ou 1,1 vezes o limiar de operação do relé.

O limite inferior é estabelecido a partir de uma porcentagem da corrente nominal da carga. O valor deve ser escolhido considerando a faixa apresentada na Figura 3. Para sistemas de distribuição, é esperado um desequilíbrio maior no sistema, dando-se uma maior margem no ajuste de relé de neutro (45% da corrente nominal).




Figura 3: Faixa para limite mínimo do ajuste do relé de sobrecorrente de neutro

Em alguns relés, é possível também ajustar um valor para o elemento instantâneo, isto é, a partir de um dado valor de corrente (expresso por M), a proteção passa atuar instantaneamente e não mais de acordo com a sua característica inversa [29]. Esse tipo de relé é denominado relé de sobrecorrente temporizado com elemento instantâneo, conhecido como função 50/51. É um dispositivo temporizado que incorpora em seu circuito uma unidade instantânea. O desempenho da atuação do relé 50/51 em função do tempo e do parâmetro M é ilustrado na Figura 4. O parâmetro A indicado se refere ao ajuste do elemento temporizado.

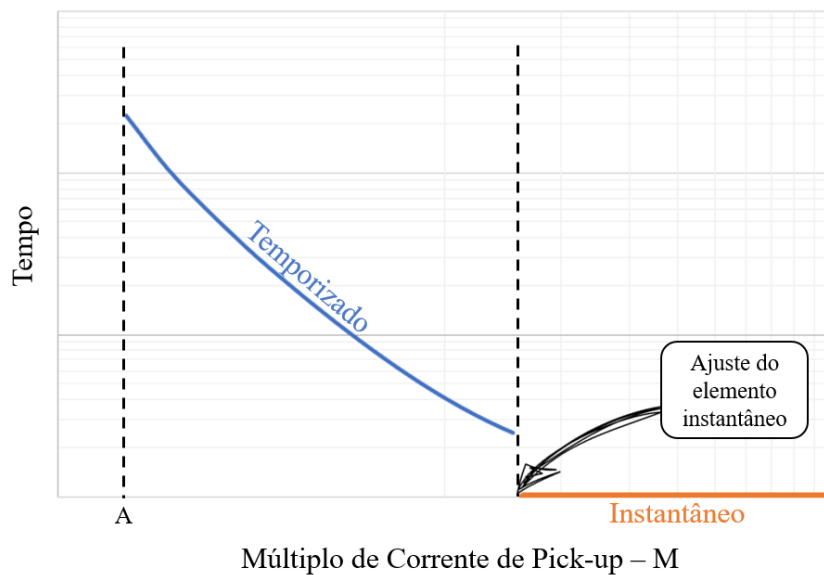


Figura 4: Curva de desempenho do relé 50/51

Conseqüentemente, o valor da corrente de curto-circuito determinará qual função atuará – 50 ou 51. Habitualmente, para alimentadores de distribuição ajusta-se a corrente do elemento instantâneo para um defeito trifásico a 85% da linha protegida [26]. Dessa

forma, qualquer defeito que ocorrer no trecho compreendido entre o relé 50/51 e o ponto a 85% da linha provocará a atuação da unidade instantânea. A Figura 5 ilustra esse ajuste.




Figura 5: Zonas de atuação do relé 50/51

3.2.1.2 Religadores Automáticos

Religadores automáticos são elementos presentes ao longo dos alimentadores de distribuição, seja nas derivações ou no tronco, responsáveis pela proteção dos diversos trechos do mesmo. Esses equipamentos podem ser ajustados com as mesmas funções de proteção dos relés presentes na subestação. Sua utilização se tornou mais difundida devido às desvantagens do uso de fusíveis.

Os religadores podem ser considerados como uma junção entre a função de proteção de um relé com a capacidade de interrupção de corrente de um disjuntor. Quando um defeito é detectado, os contatos do religador são abertos, seguindo a característica de tempo ajustada. Após um intervalo pré-determinado de tempo, seus contatos são fechados. Caso a falta seja de natureza transitória, o sistema é automaticamente restabelecido, reduzindo o intervalo de interrupção.

Entretanto, se a falta ainda estiver presente o sistema, o ciclo de atuação do religador é repetido. O mesmo se repete por um número pré-determinado de vezes. Se ainda assim o defeito não for eliminado, o religador fica definitivamente aberto e o trecho defeituoso do sistema é isolado.

3.2.1.3 Chaves Fusíveis

Chaves fusíveis são comumente utilizadas na proteção de redes de distribuição urbanas e rurais, devido aos seus preços reduzidos e seu desempenho satisfatório para o nível de proteção que se deseja [17].

Esses tipos de chaves são utilizadas para proteção de ramais secundários de alimentadores, transformadores de distribuição e ramais de entrada de consumidores. Sua atuação se dá uma única vez, pois após a sua operação o fusível interno da chave se rompe, sendo assim necessária a sua substituição para que o equipamento retorne à condição normal.

Um parâmetro importante para especificação dos fusíveis é a máxima corrente que pode ser interrompida. O tempo de fusão do elemento fusível depende da intensidade da corrente que passa pelo mesmo e de detalhes construtivos do dispositivo, como o tipo de material que o constitui.

Cada fusível tem sua curva de operação tempo x corrente específica para valores de corrente mínima de fusão e tempo total de interrupção. Tais curvas são semelhantes às curvas dos relés de sobrecorrente de tempo inverso.

Apesar de seus benefícios, as chaves fusíveis podem provocar situações indesejadas para a concessionária de distribuição. O fusível não é capaz de diferenciar se o defeito é de natureza transitória ou permanente. Com isso, a sua queima ocorre para qualquer falta transitória, levando a um tempo maior de restabelecimento do sistema.

A fim de se contornar esse problema, um esquema adotado é a estratégia poupa-fusível. Esse tipo de estratégia é comum principalmente em áreas rurais de difícil acesso, e aproveita-se do fato que cerca de 90% dos defeitos em linhas de distribuição aéreas são de natureza transitória [26]. A coordenação dos equipamentos do alimentador é feita de tal forma que o religador atue antes do fusível para defeitos no ramal protegido pelo mesmo, evitando a queima desnecessária do fusível para defeitos transitórios.

3.2.1.4 Seccionalizadores Automáticos

Os seccionalizadores automáticos possuem a capacidade de detectar se a corrente passante foi maior que um valor pré-ajustado. São destinados a verificar sobrecorrente com posterior falta de tensão. Contudo, esses equipamentos não são capazes de interromper a circulação de corrente. Portanto, para que esse equipamento isole um defeito é necessário um equipamento a montante com capacidade de interrupção de corrente, como por exemplo um religador.

Durante condições de falta no sistema, o seccionalizador contabiliza os números de operações do religador. Após um número pré-determinado de aberturas do mesmo, o seccionalizador abre o circuito e isola o defeito definitivamente. Dessa forma, é permitido o isolamento de um trecho do alimentador de distribuição. Como o seccionalizador não possui curvas características tempo x corrente, não é necessário considerar a temporização entre o mesmo e o religador [17].

3.3 Proteção de Redes Ativas

Sistemas de distribuição de energia que contam com a presença de geradores distribuídos são comumente denominados de redes de distribuição ativas [30]. A inserção das GDs provoca uma série de mudanças no sistema, incluindo os esquemas de proteção tradicionais.

Diversas metodologias são propostas visando garantir um bom funcionamento dessas redes. As estratégias adotadas não se restringem apenas à adaptação dos ajustes dos relés da concessionária para o novo ponto de operação do sistema. Deve-se também analisar o esquema de proteção utilizado para o gerador distribuído e também as características dos equipamentos de interconexão da GD com a rede.

O estudo da proteção das GDs deve levar em consideração várias características técnicas dos geradores e de sua conexão com o sistema [31]. Para garantir a eficácia da proteção do sistema elétrico e a qualidade do fornecimento de energia aos consumidores em geral, são estabelecidos requisitos mínimos para o acesso de autoprodutores ou produtores independentes de microgeração e minigeração distribuídas aos sistemas de distribuição de média e baixa tensão das concessionárias.

Os critérios de proteção variam de acordo com cada empresa, mas em geral o PRODIST é utilizado como premissa sobre o assunto. A Tabela 4 ilustra as proteções mínimas necessárias para o ponto de conexão de centrais geradores, presentes no Módulo 3 do PRODIST [32]. Um esquema de proteção simplificado de geradores distribuídos que não utilizam inversores em alimentadores de distribuição é proposto pela Figura 6 [33].

Tabela 4: Proteções mínimas em função da potência instalada [32]

Equipamento	Potência Instalada		
	< 10 kW	10 kW a 500 kW	> 500 kW
Elemento de desconexão	Sim	Sim	Sim
Elemento de interrupção	Sim	Sim	Sim
Transformador de acoplamento	Não	Sim	Sim
Proteção de sub e sobretensão	Sim	Sim	Sim
Proteção de sub e sobrefrequência	Sim	Sim	Sim
Proteção contra desequilíbrio de corrente	Não	Não	Sim
Proteção contra desbalanço de tensão	Não	Não	Sim
Sobrecorrente direcional	Não	Não	Sim
Sobrecorrente com restrição de tensão	Não	Não	Sim

3.3.1 Impactos da GD no Sistema de Proteção

Uma vez inserido no sistema de distribuição, o gerador distribuído pode provocar uma série de impactos na proteção existente dos alimentadores. O tipo de ligação do transformador de interconexão também pode influenciar. Nas seções seguintes são detalhados alguns pontos importantes sobre a proteção de distribuição considerando a presença de GDs.

3.3.1.1 Ajuste dos Relés de Sobrecorrente

A Figura 7 ilustra a diferença da corrente detectada pelo relé R1 quando ocorre um defeito no final de um alimentador radial, na situação sem e com GD. A corrente que circula pelo relé de sobrecorrente do alimentador no cenário sem geração distribuída

I_{RI_semGD} pode ser calculada por (3.5), considerando a tensão pré-falta igual a 1,0pu. A impedância do alimentador de distribuição é dada por $Z_{alimentador}$.

$$I_{RI_semGD} = \frac{I}{Z_{alimentador}} \quad (3.5)$$

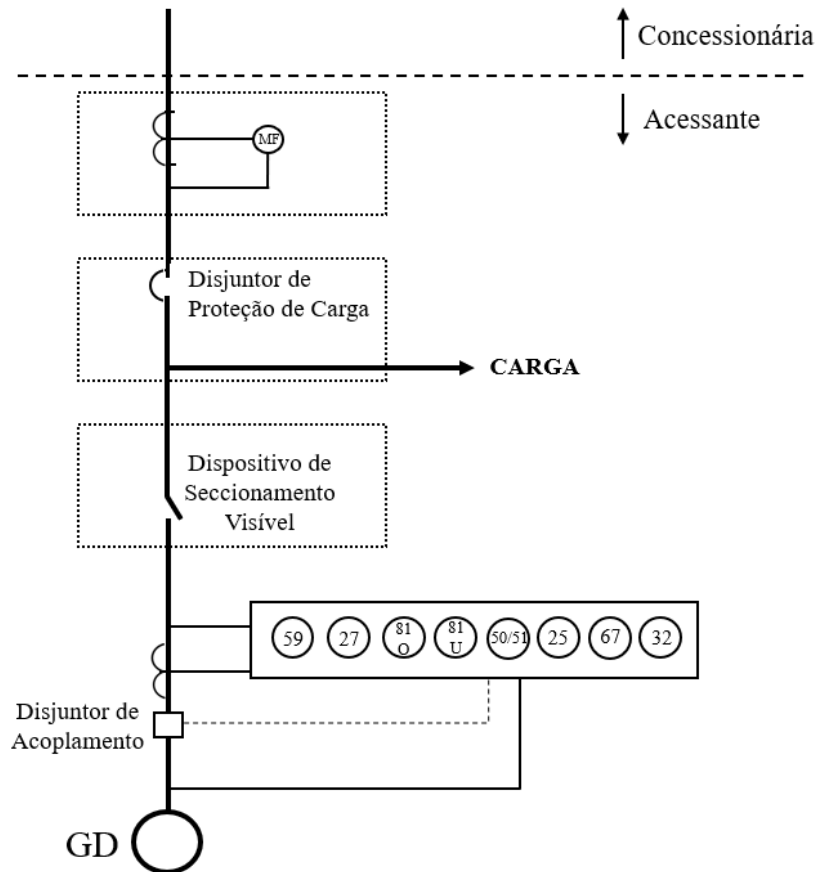


Figura 6: Forma de conexão do acessante à rede de distribuição [33]

Após a conexão da GD, a corrente detectada pelo relé é calculada por (3.6):

$$I_{RI_comGD} = \frac{I}{Z_a} \left(1 - \frac{Z_b}{Z_b + \frac{Z_a Z_g}{Z_a + Z_g}} \right) \quad (3.6)$$

sendo:

I_{RI_comGD} : Corrente detectada pelo relé de sobrecorrente do alimentador com GD no sistema

- Z_a : Impedância do alimentador no trecho entre a subestação e o ponto de conexão da GD
- Z_b : Impedância do alimentador no trecho do ponto de conexão da GD até o seu final
- Z_g : Impedância total da GD e do trecho de conexão da mesma com o alimentador

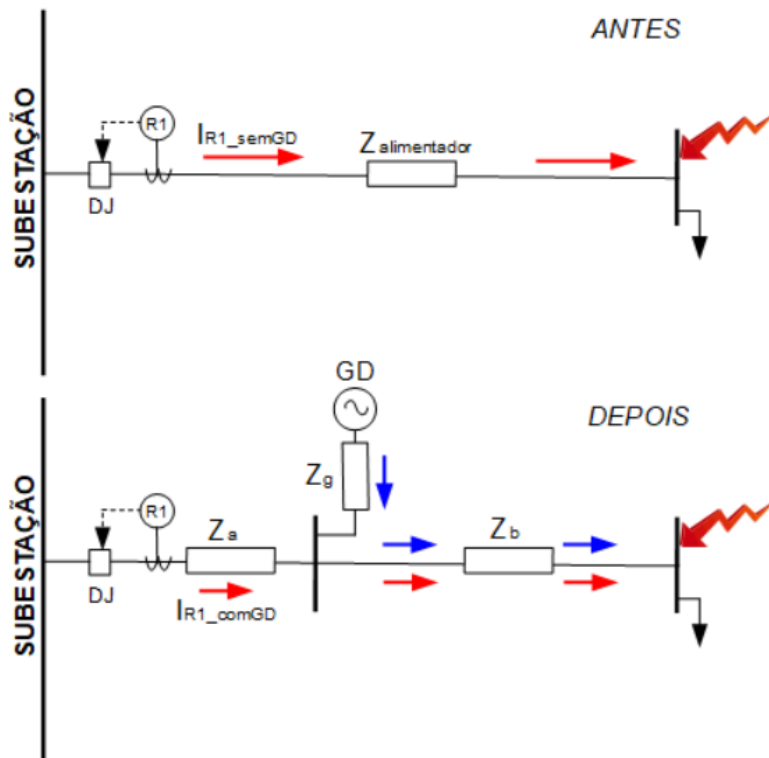


Figura 7: Impacto no ajuste do relé de sobrecorrente

Comparando (3.5) e (3.6), observa-se uma diminuição no nível de corrente detectado pelo relé de sobrecorrente R1, uma vez que a GD também contribui para o defeito. Essa redução é ainda mais acentuada quando o gerador é composto por máquinas síncronas, podendo retardar a atuação do relé ou até mesmo levar à sua dessensibilização.

A Figura 8 ilustra o efeito da GD no tempo de atuação do relé de sobrecorrente de tempo inverso. A partir da inserção da geração distribuída no sistema, o múltiplo de

corrente de *pick-up* é reduzido de M_{semGD} para M_{comGD} . Consequentemente, o tempo de eliminação do defeito é aumentado, passando de t_{semGD} para t_{comGD} .

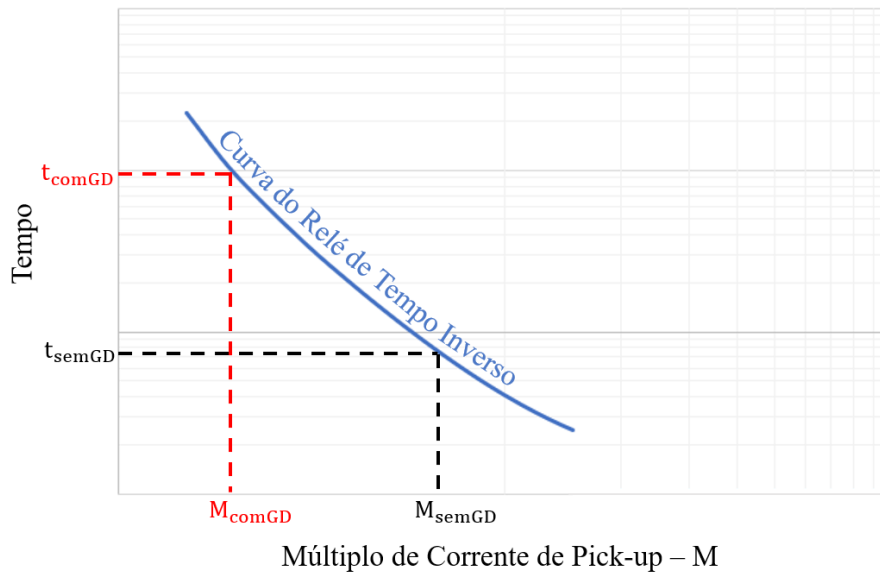


Figura 8: Efeito da GD na atuação do relé de sobrecorrente de tempo inverso

3.3.1.2 Religamento Automático

O religamento automático é uma ação habitual em alimentadores radiais de distribuição [34]. Essa prática tem como objetivo aumentar a confiabilidade da rede, melhorando os índices de continuidade do sistema. Após a detecção do defeito, o religador automático é programado para restabelecer automaticamente a energia da rede elétrica. Considerando uma falta temporária, o equipamento tem sua função concluída com sucesso.

O processo de eliminação das faltas temporárias é realizado inicialmente com a abertura da fonte de alimentação durante um intervalo curto de tempo, permitindo assim a extinção do arco elétrico. Com o seu desaparecimento, é possível realizar o restabelecimento do sistema. Entretanto, a presença de geração distribuída pode prejudicar a eficiência desse procedimento. Há o risco das GDs continuarem a contribuir para o defeito, levando à manutenção do arco elétrico. Resulta-se assim em um religamento malsucedido acompanhado de um desligamento permanente.

Ademais, outra complicação devido à inserção da GD é o religamento fora de fase [35] entre a parte ilhada e o restante da rede. Isso pode provocar significativos transientes de corrente, tensão ou torque causando danos consideráveis no gerador e também aos componentes de rede.

3.3.1.3 Estratégia Poupa-Fusível

Outro fenômeno observado em redes de distribuição é o impacto da GD na estratégia poupa-fusível. A Figura 9 apresenta as situações sem e com presença de GD no sistema, para um defeito no final do ramal protegido pelo fusível. Note-se que, sem a GD, as correntes que circulam pelo religador e pelos fusíveis são iguais. Com a atuação rápida do religador, evita-se a queima desnecessária do dispositivo para qualquer tipo de defeito da rede e a necessidade da sua substituição pela equipe de reparo da concessionária.

Entretanto, com a inserção da GD do sistema no final do alimentador, a corrente que circula pelo fusível no defeito é maior do que a corrente que circula pelo religador. Assim, dependendo dos ajustes praticados, o fusível pode queimar antes da atuação do religador e inviabilizar o religamento total do sistema.

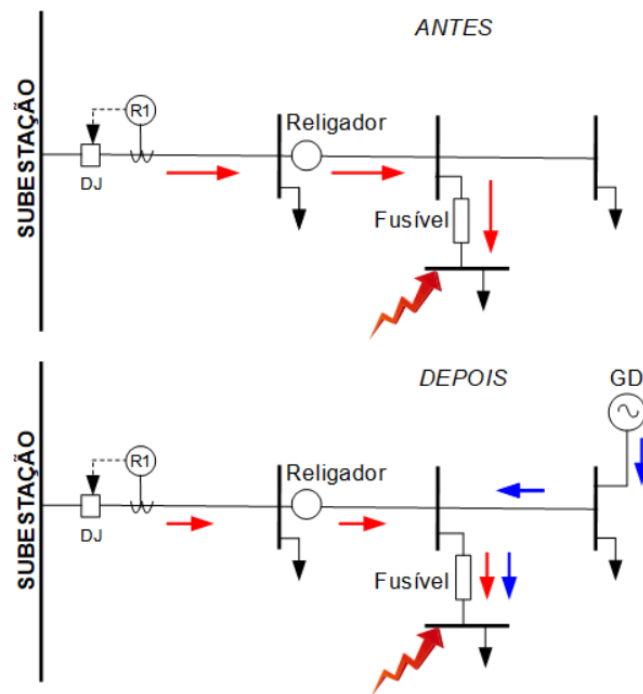


Figura 9: Impacto na estratégia poupa-fusível

3.3.1.4 Disparos Falsos

Disparos falsos – false tripping – devido à reversão do fluxo em redes de distribuição é outro fenômeno que pode ser causado pela inserção de GDs [36]. A Figura 10 ilustra um sistema de distribuição composto por dois alimentadores. No Alimentador 2 está inserido um gerador distribuído.

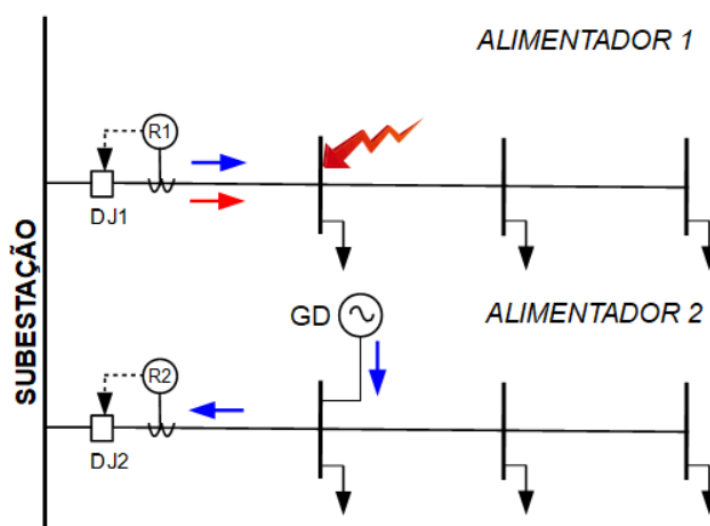


Figura 10: Impacto nos disparos falsos dos relés

Considerando a ocorrência de um defeito ao longo do Alimentador 1, tanto a subestação como a GD localizada no alimentador adjacente contribuem para a falta. Os dois relés que protegem cada um de seus alimentadores em que estão instalados podem ser sensibilizados pelo defeito. Neste caso, ambos os alimentadores são desconectados da subestação, apesar do defeito ter ocorrido em apenas um deles.

Para evitar esse problema, torna-se necessária a inclusão da função de direcionalidade nos relés dos alimentadores originalmente radiais. A adoção de novas funções já faz parte da mudança de paradigma na forma de se proteger o sistema de distribuição, em que antes era considerado o fluxo unidirecional da energia.

3.3.1.5 Proteção de Distância

Historicamente, o uso da proteção de distância em redes de distribuição não é tão comum como o da função de sobrecorrente. Isso se deve ao fato da necessidade de utilizar

transformadores de corrente (TC) e também de potencial (TP) para esse tipo de proteção. Entretanto, com a redução do custo ao longo do tempo, o emprego dessa tecnologia passou a ser mais viável, sendo mais difundido em sistemas de subtransmissão de energia [37].

A proteção de distância também pode ser afetada pela presença da GD no sistema. A Figura 11 apresenta duas situações distintas, caracterizando o efeito de fonte intermediária – *infeed* – no alimentador de distribuição de energia.

Inicialmente, sem a presença de GD do sistema, a impedância detectada pelo relé de distância é dada pela expressão (3.7):

$$Z_{RI_semGD} = Z_{alimentador} = Z_a + Z_b \quad (3.7)$$

Após a inserção da GD no alimentador, o relé passa a detectar outro valor de impedância, devido à injeção de corrente por parte da geração distribuída. O novo valor pode ser calculado pela equação (3.8).

$$Z_{RI_comGD} = Z_a + Z_b \left(1 + \frac{I_{GD}}{I_{al}} \right) \quad (3.8)$$

Comparando (3.7) e (3.8), observa-se que o novo valor detectado pelo relé após a inserção da geração distribuída é maior do que o anterior. Para o relé, o defeito ocorre em um ponto mais distante do que onde realmente acontece. Essa mudança na impedância pode resultar numa ação retardada, ou simplesmente na falta de atuação da proteção de distância.

3.3.1.6 Conexões do Transformador de Interconexão

Além da especificação da proteção, é fundamental para o acesso do gerador distribuído a definição do tipo de ligação do transformador de interconexão. O tipo escolhido influencia na rede da concessionária, especialmente nas condições de curto-circuito. Dessa forma, pode ter impacto direto nos ajustes da proteção [31].

Universalmente, não existe uma ligação considerada como a melhor. Cada uma delas apresenta fatores positivos e negativos e sua escolha varia de acordo com a

concessionária de distribuição de energia. A Figura 12 apresenta os tipos de ligação mais utilizados pelas concessionárias, agrupados de acordo com suas semelhanças nos impactos e vantagens de suas escolhas.

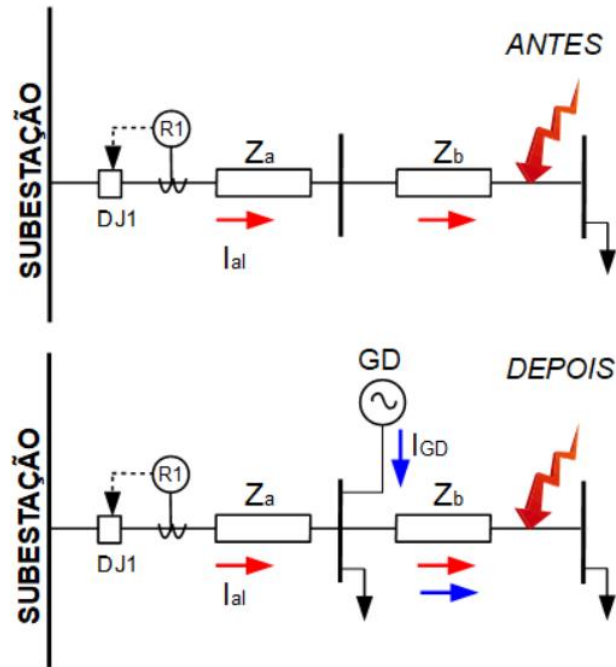


Figura 11: Impacto na proteção de distância

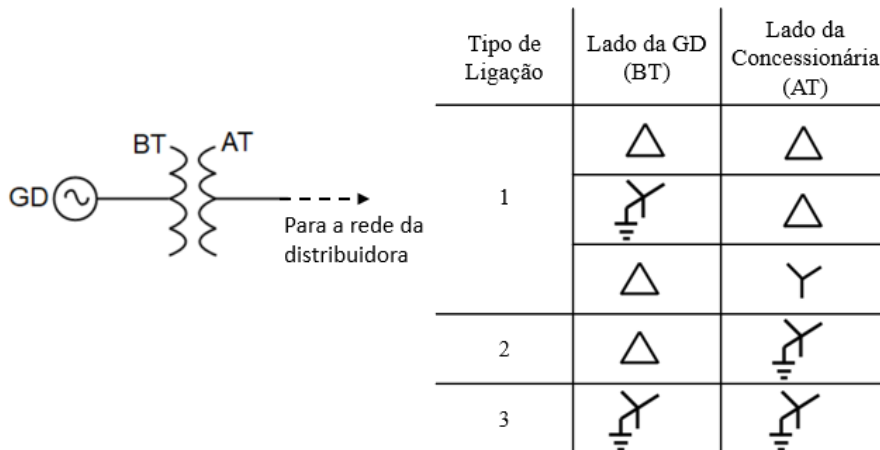


Figura 12: Tipos de ligações de transformadores de interconexão

O Tipo 1 é caracterizado pelo lado de alta tensão do transformador conectado em delta ou estrela não-aterrado. Essa ligação não interfere na circulação de corrente de

sequência zero do alimentador da concessionária, não impactando a proteção de terra da distribuidora para defeitos fase-terra.

Por outro lado, caso ocorra um defeito monofásico que provoque abertura do disjuntor da subestação e a GD fique isolada, as fases sãs apresentarão sobretensão [38]. O gerador distribuído continuará contribuindo para o defeito mesmo após a abertura do disjuntor. Além disso, as ligações do Tipo 1 não proporcionam um aterramento eficaz para a concessionária, podendo causar problemas para a detecção de faltas monofásicas no alimentador.

O Tipo 2 é a forma de interconexão mais difundida pelas concessionárias de energia [39]. Os esquemas de proteção são consolidados, tanto por parte dos fabricantes como para a distribuidora. O lado da GD do transformador de interconexão é conectado em delta, e o lado da concessionária, por sua vez, em estrela aterrado.

As vantagens observadas pela sua utilização são o isolamento da proteção de neutro da subestação para defeitos monofásicos do lado da GD, filtragem de harmônicos de sequência zero e a garantia de aterramento da rede de distribuição.

Entretanto, a inserção da geração distribuída pode levar à dessensibilização da proteção de terra do alimentador, visto que a presença da mesma oferece um caminho alternativo para a corrente de sequência zero para defeitos monofásicos no alimentador.

A característica do Tipo 3 é o uso da ligação estrela aterrado em ambos os lados do transformador. Essa ligação simples permite que o gerador distribuído contribua para todos os tipos de defeitos que possam ocorrer na rede de distribuição.

Assim como para o Tipo 2, a presença da GD também impacta na proteção de terra da concessionária. A rede da distribuidora contribuirá para defeitos internos na GD e não há qualquer bloqueio para as componentes de sequência zero.

3.3.2 Estratégias de Solução

O estudo da proteção de alimentadores de redes de distribuição ativas é o principal foco deste trabalho. Como já foi mencionado, não há uma estratégia única de solução para a minimização dos impactos da GD nos esquemas de proteção. A Figura 13 apresenta algumas das metodologias mais comumente utilizadas.

Em geral, são utilizados métodos de proteção adaptativa, caracterizados pela alteração nos ajustes dos relés para atender condições operativas do sistema. Mesclado a isso, são empregados grupos de ajuste ou novos dispositivos ou funções de proteção. Também é cada vez mais difundido o emprego de técnicas de inteligência artificial. Nas próximas seções serão detalhadas essas estratégias de solução.

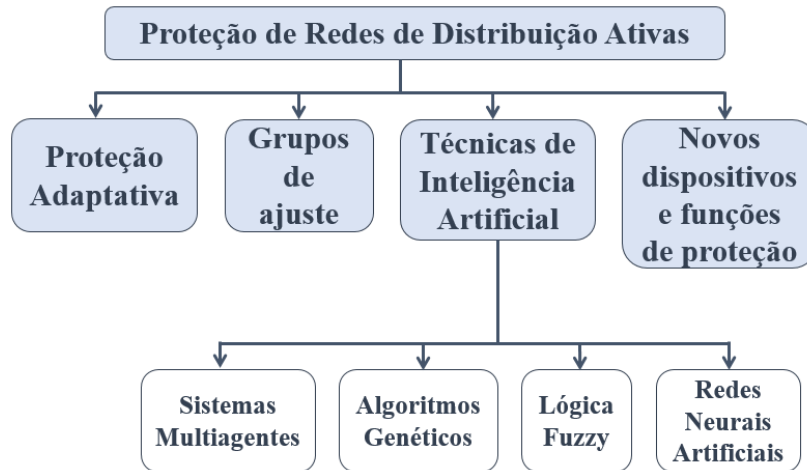


Figura 13: Metodologias para proteção de redes de distribuição ativas

3.3.2.1 Proteção Adaptativa

A proteção adaptativa é uma filosofia que permite e busca realizar ajustes em várias funções de proteção a fim de torná-las mais condizentes com as condições atuais dos sistemas elétricos de potência [40].

A evolução tecnológica dos relés digitais permitiu a aplicação da proteção adaptativa utilizando esse tipo de equipamento. É possível adequá-los para que, à medida que as condições de operação do sistema sejam modificadas, seus ajustes também sejam reconfigurados. A finalidade é manter o bom desempenho com relação aos princípios básicos de seu funcionamento: confiabilidade, sensibilidade, seletividade e velocidade.

A alteração dos ajustes da proteção em tempo real pode ser obtida com auxílio da medição fasorial [5]. O monitoramento contínuo de grandezas elétricas do sistema permite a adaptação dos ajustes para cada instante amostrado, e dessa forma, aumentar a eficácia do sistema de proteção.

3.3.2.2 Grupos de Ajuste

Outra alternativa adotada é o uso de grupos de ajustes. Os relés atuais permitem a configuração de vários grupos de ajustes pré-determinados através de estudos *offline*. Nesse caso, a proteção não é alterada em tempo real, mas sim entre intervalos fixos de tempo pré-determinados. Por exemplo, considera-se que o sistema terá três configurações distintas durante o dia: manhã, tarde e noite. Os ajustes então serão realizados para cada um desses períodos do dia, sendo modificados à medida que cada intervalo se finaliza.

3.3.2.3 Novos Dispositivos e Funções de Proteção

Além da alteração dos ajustes dos relés, outras estratégias adaptativas consideram o emprego de novas funções de proteção, aspecto que já é mais difundido em sistemas de transmissão de energia. Problemas apresentados pela redistribuição dos fluxos de potência podem ser solucionados pela inclusão da função direcional. Em sistemas com um número grande de GDs inseridas, novas soluções também consideram o uso da função de distância [37].

Investimentos na rede também são vistos como uma alternativa. Em alimentadores muito longos, a diferença entre a maior corrente de carga e a mínima corrente de defeito pode ficar muito baixa para garantir a sensibilidade da proteção. A solução é a instalação de novos disjuntores ao longo do alimentador.

Ademais, avanços nos sistemas de comunicação são fundamentais para a difusão das técnicas adaptativas. Dependendo da estratégia utilizada, pode ser necessária a transmissão de grande volume de dados. Entretanto, os sistemas de proteção e de comunicação nessas redes possuem usualmente um baixo grau de sofisticação. Para atender às novas soluções adaptativas, pode ser necessário um alto grau de investimento financeiro, como a compra de novos equipamentos para medição e transmissão de dados. A inviabilidade da realização de melhorias na rede pode se tornar um fator limitante [40].

3.3.2.4 Técnicas de Inteligência Artificial

A sofisticação exigida para a proteção de redes de distribuição ativas de energia trouxe força para aplicação de técnicas de inteligência artificial. As pesquisas nessa área sempre foram de grande valia para a melhoria dos sistemas elétricos, bem antes de se

estudar os impactos da geração distribuída, permitindo resolver problemas de grande complexidade [41].

Além de propor uma nova solução ao problema da inserção da GD na proteção, as técnicas de inteligência artificial podem ainda ser utilizadas como ferramentas da proteção adaptativa. São propostos mecanismos para realizar o ajuste em tempo real dos relés de acordo com as condições operativas do sistema [10] [11].

Uma das estratégias utilizadas é o uso de sistemas multiagentes [42]. Esse tipo de técnica busca resolver problemas de forma descentralizada – o que é denominado Inteligência Artificial Distribuída (IAD). O objetivo é decompor os problemas de um sistema complexo em problemas menores, facilitando o gerenciamento.

Nos sistemas multiagentes, existem entidades chamadas de agentes. Basicamente, são *hardwares* ou *softwares* que apresentam as seguintes propriedades [43]:

- **Habilidade Social** – Os agentes têm a capacidade de se comunicarem entre si através de uma linguagem específica (ACL – *agent communication language*);
- **Autonomia** – Os agentes operam com uma certa independência, sem influência direta do usuário;
- **Pró-Atividade** – A partir do recebimento de informações do ambiente, os agentes estão aptos a tomar decisões e realizar suas tarefas de acordo com sua finalidade;
- **Reatividade** – Os agentes são sensibilizados pelo ambiente e são capazes de reagir a ele.

A característica distribuída do sistema de proteção em que cada componente protege um equipamento específico do sistema favorece a utilização dos sistemas multiagentes. A operação conjunta dos agentes com os relés digitais permite alterar os ajustes de forma adaptativa e resolver problemas na detecção e eliminação de faltas.

Outra possibilidade adotada para solução do problema é o emprego dos algoritmos genéticos (AGs). Essa técnica computacional é baseada em uma metáfora do processo

biológico de evolução natural [44]. São utilizados para resolver uma série de problemas formulados como problemas de otimização.

A Figura 14 apresenta as etapas básicas dos algoritmos genéticos. O algoritmo é iniciado a partir da criação de uma população, composta por indivíduos ou cromossomos. Esses indivíduos podem ser possíveis soluções para o problema. Cada indivíduo passa por processo de avaliação, o qual determina a qualidade do indivíduo de acordo com sua capacidade de adaptação a um determinado ambiente.

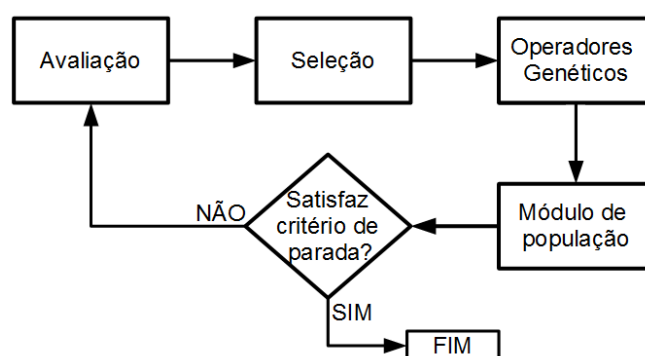


Figura 14: Esquema básico de um algoritmo genético

Após essa avaliação, a população é então submetida a uma série de operadores genéticos – seleção, reprodução e mutação – de forma a simular a sobrevivência do indivíduo mais apto. O módulo de população é responsável pelo controle da população, mantendo-a com tamanho fixo. Por fim, ao se atingir um critério de parada pré-estabelecido, o algoritmo se finaliza.

Com relação ao sistema elétrico, uma prática conhecida é o uso dos algoritmos genéticos para alocação de dispositivos de chaveamento. Nesse caso, cada indivíduo representa um trecho da rede, caracterizado pela presença de disjuntor de subestação, religador, fusível ou então pela ausência de qualquer equipamento. O objetivo é encontrar uma solução ótima com relação ao custo, número de equipamentos e melhores índices de confiabilidade da rede [45].

Os algoritmos genéticos também são utilizados para otimização dos ajustes e coordenação dos relés de sobrecorrente dos alimentadores de distribuição [11]. Em redes altamente interconectadas ou na presença de geração distribuída, os AGs atuam

fornecendo um maior grau de flexibilidade da proteção. Uma solução é o uso de curvas não-convencionais para relés de sobrecorrente de tempo inverso [46].

Para melhoria dos sistemas elétricos, tem-se também o uso da lógica *fuzzy*. Esse tipo de técnica é capaz de capturar informações ambíguas – em geral em forma de linguagem – e convertê-las para um formato numérico. Diferentemente da lógica booleana que apenas trata valores como verdadeiro ou falso, 0 ou 1, a lógica *fuzzy* permite também analisar valores entre 0 e 1. Por exemplo, 0,5 pode representar meia verdade, e 0,1 e 0,9, quase falso e quase verdadeiro, respectivamente [47].

Quanto à sua aplicabilidade, o uso da lógica *fuzzy* está mais difundido nos esquemas de proteção de transformadores [31]. A principal função de proteção desse equipamento é a diferencial (87). Através dela, os valores das correntes primária e secundária são comparados a um valor pré-ajustado. Se o valor estiver maior que o de ajuste, há uma falta interna, caso contrário, a situação é normal.

Entretanto, uma série de fatores pode levar ao falso disparo ou a ausência de sensibilidade da falta por parte do relé. A atuação indevida pode ocorrer no caso de defeitos externos. A saturação e os erros dos transformadores de corrente são exemplos de fatores que podem dificultar na proteção. A aplicação da lógica *fuzzy* permite considerar um maior número de critérios na avaliação das decisões do envio do *trip* por parte do relé, modelando melhor as incertezas. Em outras palavras, é possível tornar o relé mais suscetível a indicar o defeito ou a indicar situação normal, dependendo da situação no instante estudado.

Para redes de distribuição, o uso da lógica *fuzzy* surge como uma saída para falhas da proteção em casos de inserção de geração distribuída no sistema [10]. O princípio é obter a melhor escolha para os ajustes dos relés de proteção, levando em conta as incertezas de injeção de potência das GDs.

Há, ainda, o uso das redes neurais artificiais. As RNAs são modelos computacionais baseados no sistema nervoso biológico. Suas aplicações são destinadas para problemas em que não se tem uma formulação matemática consolidada. Em termos de aplicações, tem-se o uso na melhoria da proteção de distância em linhas de transmissão

de energia. Na distribuição, existem propostas de RNAs aplicadas tanto para detectar como para localizar defeitos [48].

Aspectos construtivos e de treinamento das RNAs serão mais discutidos no Capítulo 4. Serão apresentados conceitos sobre os tipos de arquitetura empregados nas RNAs e o detalhamento do processo de aprendizagem.

CAPÍTULO 4

REDES NEURAIS ARTIFICIAIS

4.1 Introdução

Este capítulo apresenta os principais conceitos das redes neurais artificiais. São detalhados os métodos mais utilizados para treinamento das redes, bem como aspectos construtivos de suas arquiteturas, topologias e funcionamento.

As redes neurais artificiais são modelos computacionais desenvolvidos de forma a tentar reproduzir o sistema nervoso biológico. Uma rede neural é um processador maciçamente paralelo e distribuído, constituído por unidades de processamento simples, as quais têm a propensão natural de armazenar conhecimento experimental e torna-lo disponível para uso [49].

As RNAs fazem parte do grupo da inteligência artificial da linha conexionista [50]. Funcionalmente, os parâmetros da rede são estimados de forma que a mesma possa reproduzir o mapeamento entrada-saída presente nos dados do problema.

A Figura 15 apresenta algumas das principais propriedades e benefícios da utilização das redes neurais artificiais. As RNAs podem ser utilizadas como solução de aplicações envolvendo altos graus de não-linearidade. A partir do mapeamento entrada-saída, a rede é capaz de resolver problemas em que não se tem uma formulação matemática consolidada. Caso exista um algoritmo – modelo fenomenológico – satisfatório, não é necessário o uso das redes neurais. As RNAs não são uma panaceia universal [50], são apenas mais um processo de modelagem.



Figura 15: Principais propriedades das redes neurais artificiais

Outro grande benefício das RNAs é a capacidade de generalização. Essa característica permite que a rede neural produza saídas aceitáveis para entradas que não estavam presentes em seu processo de treinamento. A mesma se torna apta a estimar respostas que eram até então desconhecidas.

A sua capacidade de aprendizagem é também uma propriedade importante. A rede consegue extrair o relacionamento existente entre variáveis que compõem a aplicação. A partir de um conjunto de amostras de treinamento, as quais relacionam sinais de entrada a uma ou mais respostas alvo (desejadas), a rede é treinada repetidamente, construindo o já mencionado mapeamento entrada-saída.

Além disso, a adaptabilidade é igualmente uma vantagem marcante. Alterações do ambiente são adaptadas pela rede, sendo capaz de ajustar seus parâmetros. A aquisição do conhecimento por experimentação permite que a RNA, uma vez treinada para uma aplicação específica, seja retreinada para pequenas modificações no sistema estudado.

A robustez das RNAs é a característica das redes em ser tolerantes a falhas. Graças a sua natureza distribuída, a rede não tem seu desempenho afetado de forma acentuada mesmo quando operada sob condições adversas.

Por fim, tem-se a resposta a evidências e a facilidade de prototipagem. A primeira se refere à capacidade que uma rede classificadora tem de não só selecionar o padrão da resposta, como indicar a confiança sobre a decisão optada. Já a facilidade de prototipagem é a característica de ser aplicada facilmente, na maioria das vezes, em *software* ou *hardware*.

A seguir, são apresentados conceitos básicos de um neurônio artificial.

4.2 Neurônio Artificial

O neurônio artificial é a unidade simples de processamento das RNAs. São modelos elementares dos neurônios biológicos [51], não-lineares e usualmente com saídas contínuas. A Figura 16 apresenta o modelo de um neurônio artificial.

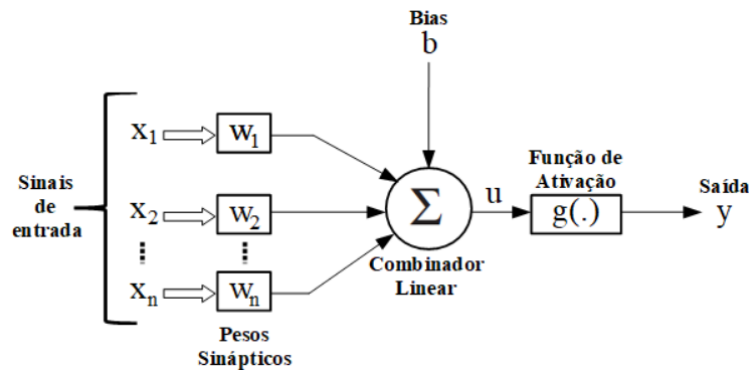


Figura 16: Modelo de um neurônio artificial adaptado de [51]

Os sinais de entrada $\{x_1, x_2, \dots, x_n\}$ são sinais vindos do meio externo, os quais normalmente são normalizados. Através dos pesos sinápticos $\{w_1, w_2, \dots, w_n\}$, esses sinais são ponderados. A seguir, o somador Σ (combinador linear) agrega todos os sinais de entrada com seus respectivos pesos sinápticos a fim de gerar o potencial de ativação u .

O limiar de ativação b (também conhecido como *bias*) é um sinal externo que tem a função de aumentar ou diminuir a saída do combinador linear. O potencial de ativação u passa pela função de ativação g , responsável por restringir a amplitude do sinal de saída y do neurônio dentro de um intervalo pré-estabelecido. O resultado obtido pelo neurônio pode ser também apresentado por (4.1) e (4.2):

$$u = \sum_{i=1}^n w_i * x_i \quad (4.1)$$

$$y = g(u + b) \quad (4.2)$$

4.2.1 Funções de Ativação

As funções de ativação dos neurônios podem ser de dois tipos: parcialmente ou totalmente diferenciáveis. No primeiro tipo, existem pontos na função cujas derivadas não existem. Já para o segundo, a função é diferenciável em todo intervalo. A seguir são apresentados alguns exemplos.

4.2.1.1 Função Degrau

A função degrau faz parte do grupo das parcialmente diferenciáveis. É expressa por (4.3). A saída do neurônio assumirá valor positivos quando o potencial de ativação for maior ou igual a 1. Caso contrário, a saída será nula. A Figura 17 ilustra essa função.

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases} \quad (4.3)$$




Figura 17: Função degrau

4.2.1.2 Função Degrau Bipolar

Outra função parcialmente diferenciável é a função degrau bipolar, definida em (4.4) e ilustrada na Figura 18.

$$g(u) = \begin{cases} 1, & \text{se } u > 0 \\ 0, & \text{se } u = 0 \\ -1, & \text{se } u < 0 \end{cases} \quad (4.4)$$




Figura 18: Função degrau bipolar

4.2.1.3 Função Rampa Simétrica

A função rampa simétrica, definida em (4.5), retorna valores iguais aos limites $-a$ e $+a$, com exceção ao intervalo $[-a, a]$, o qual retorna valores iguais ao potencial de ativação. Também é parcialmente diferenciável. A Figura 19 ilustra graficamente essa função.

$$g(u) = \begin{cases} a, & \text{se } u > a \\ u, & \text{se } -a \leq u \leq a \\ -a, & \text{se } u < -a \end{cases} \quad (4.5)$$




Figura 19: Função rampa simétrica

4.2.1.4 Função Logística

A função logística faz parte do grupo das funções totalmente diferenciáveis. Pode ser classificada também como uma função sigmoide (em forma de S). Esses tipos de funções são as mais aplicadas na construção das redes neurais artificiais [51].

A saída da função logística é obtida conforme a expressão (4.6):

$$g(u) = \frac{1}{1 + e^{-\beta u}} \quad (4.6)$$

Suas saídas se compreendem no intervalo entre 0 e 1. A constante β representa a inclinação da função logística. A representação gráfica dessa função é ilustrada na Figura 20.




Figura 20: Função logística

4.2.1.5 Função Tangente Hiperbólica

A função tangente hiperbólica também é do tipo sigmoide e totalmente diferenciável. Sua saída obedece à expressão (4.7):

$$g(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}} \quad (4.7)$$

A saída assume sempre valores reais entre -1 e 1. A Figura 21 ilustra essa função.




Figura 21: Função tangente hiperbólica

4.2.1.6 Função Gaussiana

A função gaussiana é definida pela expressão (4.8):

$$g(u) = e^{-\frac{(u-c)^2}{2\sigma^2}} \quad (4.8)$$

O valor de c representa o centro da gaussiana e σ é o desvio padrão. A saída é a mesma para valores equidistantes do centro da curva, como pode ser observado na Figura 22.




Figura 22: Função gaussiana

4.2.1.7 Função Linear

Por fim, tem-se a função linear. É comumente utilizada como função de ativação da camada de saída em RNAs para problemas de aproximação funcional [51]. Essa função reproduz na saída exatamente o valor do potencial de ativação e é definida por (4.9):

$$g(u) = u \quad (4.9)$$

A Figura 23 ilustra o gráfico da função linear.




Figura 23: Função linear

4.3 Treinamento

O processo de treinamento de uma rede neural é denominado algoritmo de aprendizagem. Esse processo se refere ao conhecimento obtido pela rede a partir de seu ambiente, sendo armazenado nas forças de conexão entre os neurônios artificiais – conhecidas como pesos sinápticos.

O objetivo do processo de aprendizagem é ajustar os pesos sinápticos de forma com que a rede seja eficiente em resolver o problema proposto. Pode-se dividir os métodos de aprendizagem em três grupos:

- **Treinamento supervisionado** – Para o treinamento da rede, são fornecidas amostras da entrada e suas correspondentes amostras de saída. A partir de uma tabela de dados de entrada e saída, a rede é capaz de aprender e estabelecer hipóteses sobre o sistema. Os pesos sinápticos são continuamente ajustados, buscando reduzir os desvios entre as saídas produzidas pela rede das saídas alvo desejadas. Existem duas variantes do treinamento supervisionado: usando lotes de padrões *offline* (*Batch*) ou usando lotes de padrões *online*. Na primeira variante, o treinamento é realizado a partir da apresentação de todo o conjunto de dados de treinamento, ajustando assim os pesos sinápticos. Para sistemas com número muito grande de dados, é comum a divisão dos pares de treinamento em lotes, visando um menor tempo de processamento computacional. O uso do *batch* – ou batelada – pode ser aplicado a sistemas invariantes no tempo. Na segunda, o treinamento *online* é aplicável a sistemas variantes no tempo. As sinapses são atualizadas a cada par entrada-saída apresentado. Após o ajuste dos pesos sinápticos, o respectivo par (amostra) de treinamento pode ser descartado;
- **Treinamento não-supervisionado** – Ao contrário do método anterior, o treinamento não-supervisionado treina a rede fornecendo apenas dados de entrada. Sendo assim, a própria rede se reorganiza buscando identificar subconjuntos nos dados de entrada que possuam alguma similaridade – os *clusters*. O número desses subconjuntos pode também ser indicado para o treinamento da rede;

- **Treinamento com reforço** – No treinamento com reforço, o valor do erro obtido no treinamento não é diretamente quantificado, uma vez que não se tem a resposta desejada. O aprendizado de um mapeamento de entrada-saída é realizado através da interação contínua com o ambiente, avaliando o comportamento da rede ao longo do treinamento. A rede aprende a tomar boas decisões a partir da observação de seu próprio comportamento e melhora suas ações através de um mecanismo de reforço.

Os dados coletados para treinamento de uma rede neural artificial são normalmente separados em duas categorias: dados de treinamento e dados de teste [52]. O primeiro grupo, como o próprio nome já diz, é apresentado à rede durante o seu treino. A rede é ajustada de acordo com o seu erro.

Ademais, é possível realizar uma subdivisão do conjunto de treinamento, criando conjunto de validação. Esse conjunto é destinado a verificar a eficiência da rede quanto a sua capacidade de generalização e ainda pode ser utilizado como um critério de parada do treinamento. Com isso, evita-se o fenômeno denominado *overfitting* (ajuste excessivo). Esse fenômeno é caracterizado pelo ajuste excessivo dos dados de treinamento, comprometendo o desempenho da rede para novos dados ainda não disponibilizados e reduzindo a capacidade de generalização do modelo [53].

O processo de aprendizagem é realizado de tal forma que o erro de treinamento da rede em relação ao subconjunto da validação é periodicamente calculado. Um dos critérios de parada estabelece que, quando o erro do subconjunto de validação começa a crescer sucessivamente, mesmo com o erro de treinamento decrescendo, opta-se por encerrar o processo de treinamento. Esse critério de parada é denominado parada antecipada do treinamento (*early stopping*) [53].

Tem-se ainda o segundo conjunto de dados, o conjunto de teste. Esses dados são utilizados para verificar o desempenho das RNAs ao final do processo de treinamento, medindo de forma independente a sua performance.

4.4 Arquiteturas

A arquitetura de uma rede neural estabelece a maneira como seus neurônios estão dispostos, ou seja, como os mesmos se interconectam. O tipo de arquitetura escolhida está diretamente ligado ao algoritmo de treinamento adotado para a rede. Basicamente, as redes são estruturadas em camadas: camada de entrada, camada(s) escondida(s) e camada de saída.

A camada de entrada é responsável por receber os sinais do meio externo. Na camada escondida, constituída por neurônios artificiais, são extraídas as características relacionadas à aplicação da rede. O teorema da aproximação universal [49] afirma que uma única camada escondida contendo neurônios com função de ativação, $\varphi(z): \mathbb{R} \rightarrow \mathbb{R}$, contínua, não-constante e limitada é capaz de aproximar qualquer função contínua não-linear $f(\underline{x}): \mathbb{R}^n \rightarrow \mathbb{R}$. Para isso, a estrutura deve apresentar uma saída linear, representando a aproximação da função $f(\underline{x})$ obtida pelo modelo. Por fim, há a camada de saída, também formada por neurônios. Essa camada tem a função de apresentar o resultado final da rede.

Em geral, pode-se classificar as arquiteturas das RNAs em três grupos: redes *feedforward* (camada simples ou camadas múltiplas), redes recorrentes e redes reticuladas.

4.4.1 *Feedforward*

As redes *feedforward* são caracterizadas pelo fluxo unidirecional de informações, da camada de entrada para a camada de saída. O número de camadas de neurônios pode ser variável. Além disso, possuem a vantagem de ser estruturalmente estáveis. A rede não é realimentada, logo a saída só é alterada caso a entrada seja modificada.

A Figura 24 ilustra uma rede *feedforward* de camada única, com n entradas e m saídas. Nessas redes, a camada de neurônios existente é a própria camada de saída. Existem outras configurações que preveem o uso de mais de uma camada de neurônios, denominadas redes *feedforward* de camadas múltiplas.




Figura 24: Rede *feedforward* de camada única

A Figura 25 apresenta uma rede *feedforward* com duas camadas, sendo uma delas escondida. São n entradas, i neurônios na camada escondida e m saídas. O termo “escondida” se refere ao fato que essa camada não é diretamente conectada às camadas que interagem com meio externo (entradas e saídas da rede).

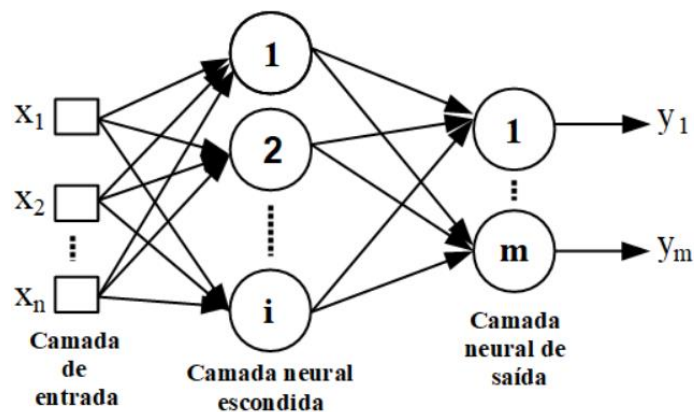


Figura 25: Rede *feedforward* de camadas múltiplas

O número de neurônios na camada escondida é dependente da aplicação. A escolha deve ser realizada de acordo com as características e complexidade do problema a ser mapeado pela rede. Por outro lado, o número de neurônios na camada de saída é o mesmo do número de saídas da rede.

As redes *feedforward* podem ser classificadas de acordo com sua aplicação. Sendo assim, são divididas em duas classes: os aproximadores e os classificadores. Na primeira,

as RNAs são utilizadas como aproximadores universais de funções, caracterizados por saídas contínuas. Já para segunda classe, as redes são destinadas a atuar no reconhecimento e classificação de padrões, com saídas lógicas.

4.4.1.1 *Perceptron* Multicamadas

A rede *perceptron* é a forma mais simples de configuração de uma rede neural artificial [51]. É um tipo de arquitetura *feedforward* com o fluxo unidirecional de informações. Apesar de sua simplicidade, foi alvo de estudo de grande parte da comunidade científica ao longo do tempo.

Quando a rede *perceptron* possui pelo menos uma camada escondida de neurônios, é denominada *perceptron* multicamadas (PMC). Como já mencionado, pelo teorema da aproximação universal [49], uma única camada oculta com número suficiente de neurônios já é satisfatória para aproximar qualquer função não-linear. Dessa forma, um dos principais desafios encontrados é determinar o número de neurônios suficiente na camada escondida que permita o bom desempenho da rede para aplicação em estudo.

A Figura 26 apresenta um esquema típico de uma rede *perceptron* com múltiplas camadas, com duas camadas escondidas de neurônios.

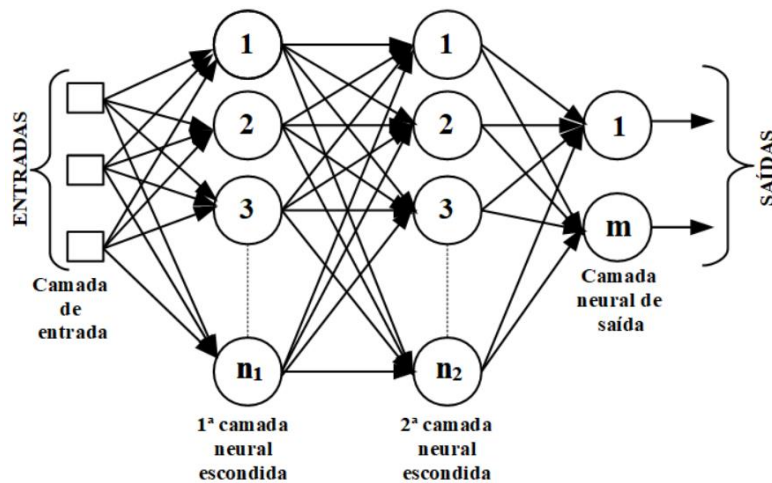


Figura 26: Rede *perceptron* multicamadas

O treinamento dessas redes é feito de forma supervisionada, fornecendo pares de amostras de entrada-saída. O método de aprendizagem comumente utilizado é o algoritmo

de retropropagação de erro, também conhecido como algoritmo *backpropagation* (BP). Sua aplicação consiste em dois passos distintos e sucessivos [49]:

- **Feedforward** – Na fase *feedforward*, também conhecida como propagação adiante, uma amostra do conjunto de entrada é propagada ao longo da rede, atravessando camada a camada, até que se obtenha a saída da rede. A saída obtida leva em conta os pesos sinápticos e limiares de ativação iniciais dos neurônios. A mesma é comparada com as saídas-alvo desejadas, calculando os desvios – erros – do conjunto da amostra;
- **Backward** – O segundo passo consiste na propagação reversa. Os pesos sinápticos e limiares de ativação são ajustados de acordo com os erros obtidos no primeiro passo, a fim de minimizá-los. O processo se repete a cada iteração, levando à redução gradativa dos erros obtidos.

O algoritmo de retropropagação do erro resume-se a um problema de otimização, buscando minimizar o erro entre a saída desejada e a saída obtida através da técnica chamada gradiente descendente [51]. O sinal de erro gerado na saída do neurônio é dado por:

$$e_j(n) = d_j(n) - y_j(n) \quad (4.10)$$

Onde:

- j : Índice do neurônio de saída da rede
 $e_j(n)$: Sinal de erro na saída do neurônio j , na iteração n , gerado após aplicação do n -ésimo padrão de entrada
 $d_j(n)$: Saída-alvo para o neurônio j na iteração n
 $y_j(n)$: Saída obtida pela RNA pelo neurônio j na iteração n

Definindo o valor instantâneo do erro quadrático para o neurônio j como $\frac{1}{2} e_j^2(n)$, o somatório dos erros quadráticos instantâneos de todos os neurônios de saída é dado por:

$$\mathcal{E}(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (4.11)$$

Sendo C o conjunto de todos os neurônios da camada de saída da rede.

Considerando N o número total de pares entrada-saída disponibilizados para treinamento, o erro médio quadrático é obtido por:

$$\mathcal{E}_{med}(n) = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n) \quad (4.12)$$

A expressão (4.12) é denominada função custo. O erro médio quadrático \mathcal{E}_{med} é obtido em função dos parâmetros de rede pesos sinápticos e bias. O objetivo do algoritmo de retropropagação é determinar o vetor desses parâmetros \underline{w} de forma a minimizar a função custo, ou seja, minimizando o erro médio quadrático, dado por:

$$\underline{w} = \min (\mathcal{E}_{med}(n)) \quad (4.13)$$

Esse algoritmo apresenta uma série de desvantagens, dentre as quais destacam-se a possibilidade de ficar retido em mínimos locais da superfície de erro e a elevada quantidade de iterações necessária para convergir, aumentando assim o custo computacional. Além disso, a concepção original do algoritmo *backpropagation* visa minimizar o erro focando apenas nos ajustes dos dados disponíveis. Na presença de dados ruidosos, o ajuste excessivo dos dados de treinamento pode reduzir a capacidade de generalização da rede.

No sentido de aprimorar o método *backpropagation*, são propostas uma série de heurísticas para modifica-lo. Técnicas da área de otimização são aplicadas para estimar os parâmetros das redes neurais, dando origem aos denominados métodos de segunda ordem, como *quasi-newton* e os métodos de gradiente conjugado [53].

São utilizados nesse trabalho três tipos de algoritmos de treinamento baseados no método *backpropagation* de aprendizagem: o algoritmo de *Levenberg-Marquardt* (LM), da Regularização Bayesiana (BR) e do Gradiente Conjugado Escalonado (SCG).

O algoritmo *Levenberg-Marquardt* foi desenvolvido por [54] e aprimorado por [55]. É o método mais difundido para treinamento das redes PMC. O algoritmo de retropropagação de erro tradicional descrito anteriormente utiliza apenas derivadas de primeira ordem e emprega o gradiente descendente como método de minimização da função custo. Já o algoritmo LM utiliza derivadas de segunda ordem na aproximação do mínimo erro, conseguindo conduzir o treinamento de redes PMC na ordem de 10 a 100 vezes mais rápido que o algoritmo *backpropagation* convencional [51]. Entretanto, sua

aplicação envolve a operação de inversão de matrizes, fato que pode tornar o método computacionalmente inviável dependendo da dimensão da RNA [56].

A Regularização Bayesiana é outro algoritmo utilizado neste trabalho. Proposto originalmente por David J.C. Mackay em 1992 [57], é resultado da aplicação de técnicas de inferência bayesiana ao problema de treinamento das redes PMC. A regularização de uma RNA consiste no controle de sua complexidade, evitando o ajuste excessivo dos dados e visando à obtenção de modelos com elevada capacidade de generalização [53] [58]. Para isso, é introduzido no algoritmo de treinamento o parâmetro λ , denominado parâmetro de regularização. O mesmo é responsável pelo equilíbrio entre o ajuste de dados de treinamento e o controle de complexidade (regularização).

Uma das formas de estimar esse parâmetro é através da aplicação de técnicas de inferência *bayesiana* no treinamento das PMC, estimando-o automaticamente ao longo do algoritmo de treinamento. Dessa forma, necessita-se de uma menor interferência por parte do usuário. Pode-se destacar também como vantagem do uso dessas técnicas o desenvolvimento de um algoritmo de determinação automática de relevância das entradas, o *automatic relevance determination* (ARD). Esse algoritmo pode ser utilizado para seleção de variáveis de entrada de redes neurais [53].

Por último tem-se o método gradiente conjugado escalonado [59]. O método SCG é uma versão aperfeiçoada do método gradiente conjugado. Seu objetivo principal é acelerar a taxa de convergência normalmente lenta com o uso do *backpropagation*, evitando custos computacionais com a manipulação de matrizes [60]. Apesar do SCG possuir uma maior quantidade de passos e cálculos que o BP, o algoritmo é capaz de convergir rapidamente e com melhor desempenho em relação ao mesmo.

Como ponto negativo do método, tem-se a necessidade de definição de dois novos parâmetros escalares introduzidos durante o treinamento para o funcionamento do algoritmo: λ_k e σ_k . Caso tais parâmetros não sejam corretamente especificados, a convergência pode não ser tão rápida e a rede ter seu desempenho prejudicado.

Usualmente, o emprego das redes PMC englobam aplicações como aproximadores universais, resolução de problemas de reconhecimento de padrões,

otimização, identificação e controle de processos, previsão de séries temporais, dentre outros.

As funções de ativação utilizadas também variam de aplicação. Normalmente, utiliza-se na camada de saída a função linear para problemas de aproximação. Para problemas de classificação e reconhecimento de padrões, é recomendável a utilização de funções sigmóides na camada de saída, como a tangente hiperbólica. As funções sigmóides como tangente hiperbólica e logística também são usadas nas duas aplicações na camada escondida de neurônios [51].

A Figura 27 ilustra os diagramas de treinamento e operação das redes neurais. Esses diagramas apresentam os passos recomendáveis para implementação das redes PMC. As fases são sucessivas, isto é, uma vez realizado o treinamento, as redes são testadas e entram em operação.

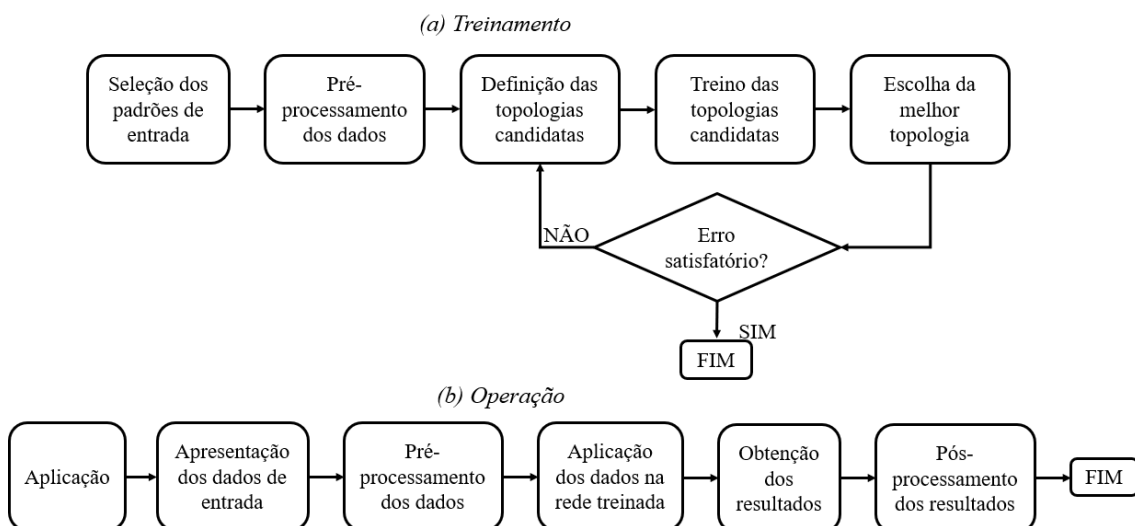


Figura 27: Diagrama de implementação das redes PMC

Através do diagrama da Figura 27, é possível observar outros processos importantes para aplicação das RNAs: o pré e pós-processamento dos dados. O objetivo é melhorar o desempenho tanto do conjunto de treinamento como de teste. Uma ação comumente empregada é a normalização das entradas e saídas. Com isso, evita-se as regiões de saturação das funções de ativação dos neurônios da rede.

4.4.1.2 Redes de Função de Base Radial

As redes de função de base radial (*radial basis function* - RBF) também fazem parte do grupo de redes de arquitetura *feedforward*. Ao contrário das redes PMC, as redes RBFs são constituídas obrigatoriamente por apenas uma camada intermediária – escondida.

Uma configuração padrão das redes RBF é apresentada na Figura 28. Na camada escondida, é utilizada a função de ativação gaussiana. Para camada de saída, a função linear. Seu treinamento também é realizado de forma supervisionada, porém possui características próprias [51].

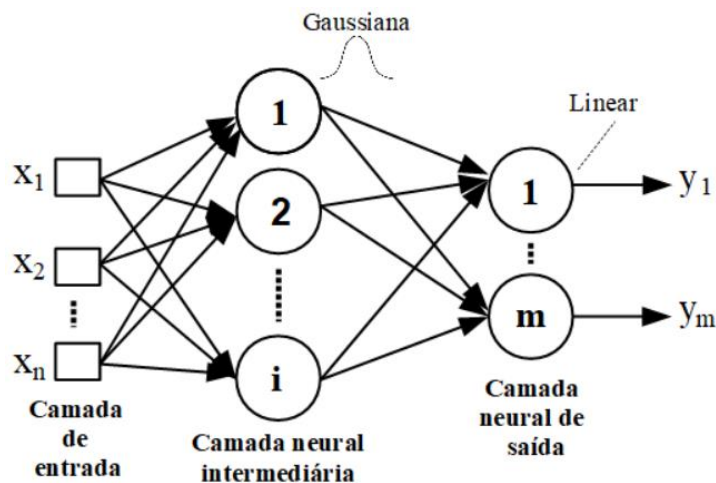


Figura 28: Redes de função de base radial

O processo de aprendizagem pode ser separado em duas fases distintas. Na primeira, o ajuste dos pesos sinápticos dos neurônios é realizado de forma não-supervisionada, diretamente relacionado à alocação das funções de base radial. Já para os neurônios da camada de saída, o ajuste dos pesos é feito de forma similar ao utilizado nas redes PMC.

4.4.2 Recorrentes

As redes recorrentes (ou realimentadas) são caracterizadas pela existência de uma realimentação na rede, ou seja, as entradas da RNA são influenciadas pelas saídas da própria rede. A Figura 29 ilustra uma rede recorrente.

A presença de laços de realimentação tem um profundo impacto na capacidade de aprendizagem da rede e no seu desempenho. A realimentação permite o uso das RNAs em sistemas variantes no tempo, como controle de processos, previsão de séries temporais e otimização.

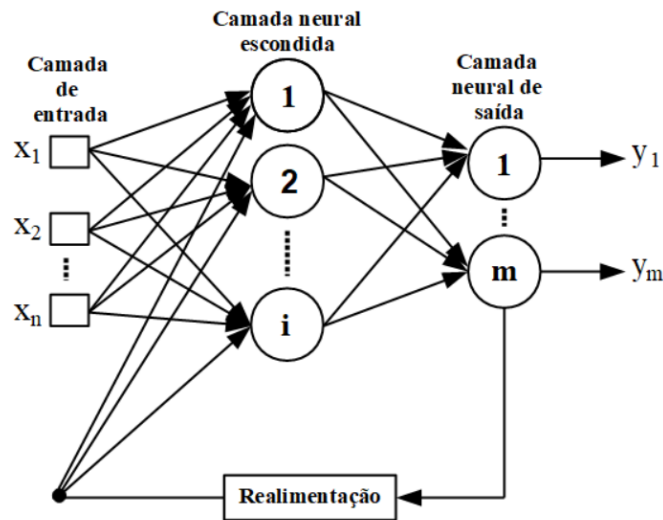


Figura 29: Rede recorrente

4.5 Métricas de Avaliação de Desempenho

Para analisar o desempenho das RNAs quando às suas diferentes aplicações, são utilizadas métricas para conhecer a confiabilidade de uma classificação ou aproximação realizada pela rede neural. Dentre as métricas mais adotadas destaca-se a Matriz de Confusão.

Através da Matriz de Confusão, é possível verificar o erro da RNA classificadora para as diferentes classes utilizadas. A Figura 30 ilustra uma matriz confusão genérica, apresentando a disposição de seus dados. As linhas da matriz consistem nas saídas estimadas, isto é, as saídas obtidas no treinamento pela rede neural. As colunas representam as saídas-alvo, aquelas que são as desejadas.

Em verde, são apresentados os verdadeiros positivos e verdadeiros negativos. São as representações da quantidade e porcentagem de dados que foram corretamente classificadas. Em vermelho, são apresentados os falsos positivos e falsos negativos, ou seja, o número e porcentagem das amostras classificadas erroneamente.

Estimadas	Classe 1	Verdadeiro Positivo	Falso Positivo	% Classe 1 Estimada
	Classe 2	Falso Negativo	Verdadeiro Negativo	% Classe 2 Estimada
		% Classe 1 Alvo	% Classe 2 Alvo	% Total
		Classe 1	Classe 2	
		Alvo		

Figura 30: Matriz confusão genérica

O método de avaliação de uma RNA que atua como aproximador universal é através cálculo do coeficiente R, denominado Coeficiente de Correlação. Esse coeficiente relaciona as saídas obtidas pela rede com as saídas-alvo. Quanto mais próximo de 1 for o valor de R para os três conjuntos de treinamento (treinamento, validação e teste), menor é o erro entre as saídas desejadas e as saídas da RNA. Entretanto, se o valor obtido é próximo de 1 apenas para o conjunto de treinamento, é sinal de *overfitting*.

No Capítulo 5, será apresentada a metodologia proposta para solução do impacto da GD na proteção de alimentadores de redes de distribuição. Detalhes das RNAs desenvolvidas bem como o fluxograma de operação da metodologia são mostrados.

CAPÍTULO 5

METODOLOGIA PROPOSTA

5.1 Introdução

A estratégia de solução proposta para o impacto da GD na proteção de redes de distribuição consiste na utilização das redes neurais artificiais como proteção redundante da proteção principal. Em caso de falha da proteção principal, a proteção redundante é que deve atuar, eliminando e localizando o defeito. Além disso, a RNA também é explorada para auxiliar na localização do defeito. A metodologia de solução é ilustrada na Figura 31 e é destinada para um sistema de distribuição apresentado na Figura 32. A rede é constituída de três alimentadores de diferentes comprimentos: AL1 (barra 2 a barra 6), AL2 (barra 2 a barra 10) e AL3 (barra 2 a barra 14) de 20km, 15km e 13km, respectivamente.

O método se inicia a partir da coleta dos módulos das injeções de correntes de cada uma das fontes do sistema, bem como das correntes que circulam no início de cada trecho dos alimentadores da rede. Esses dados são importantes para a solução proposta, uma vez que são reorganizados em matrizes de entrada para cada uma das redes neurais.

O emprego de RNAs foi realizado em três estágios distintos e sucessivos. O primeiro estágio é responsável pela detecção de qualquer tipo de defeito no sistema. A rede neural deve ser capaz de constatar se o sistema está sob condição de falta ou não. Caso não esteja, uma nova coleta de dados da rede deve ser realizada.

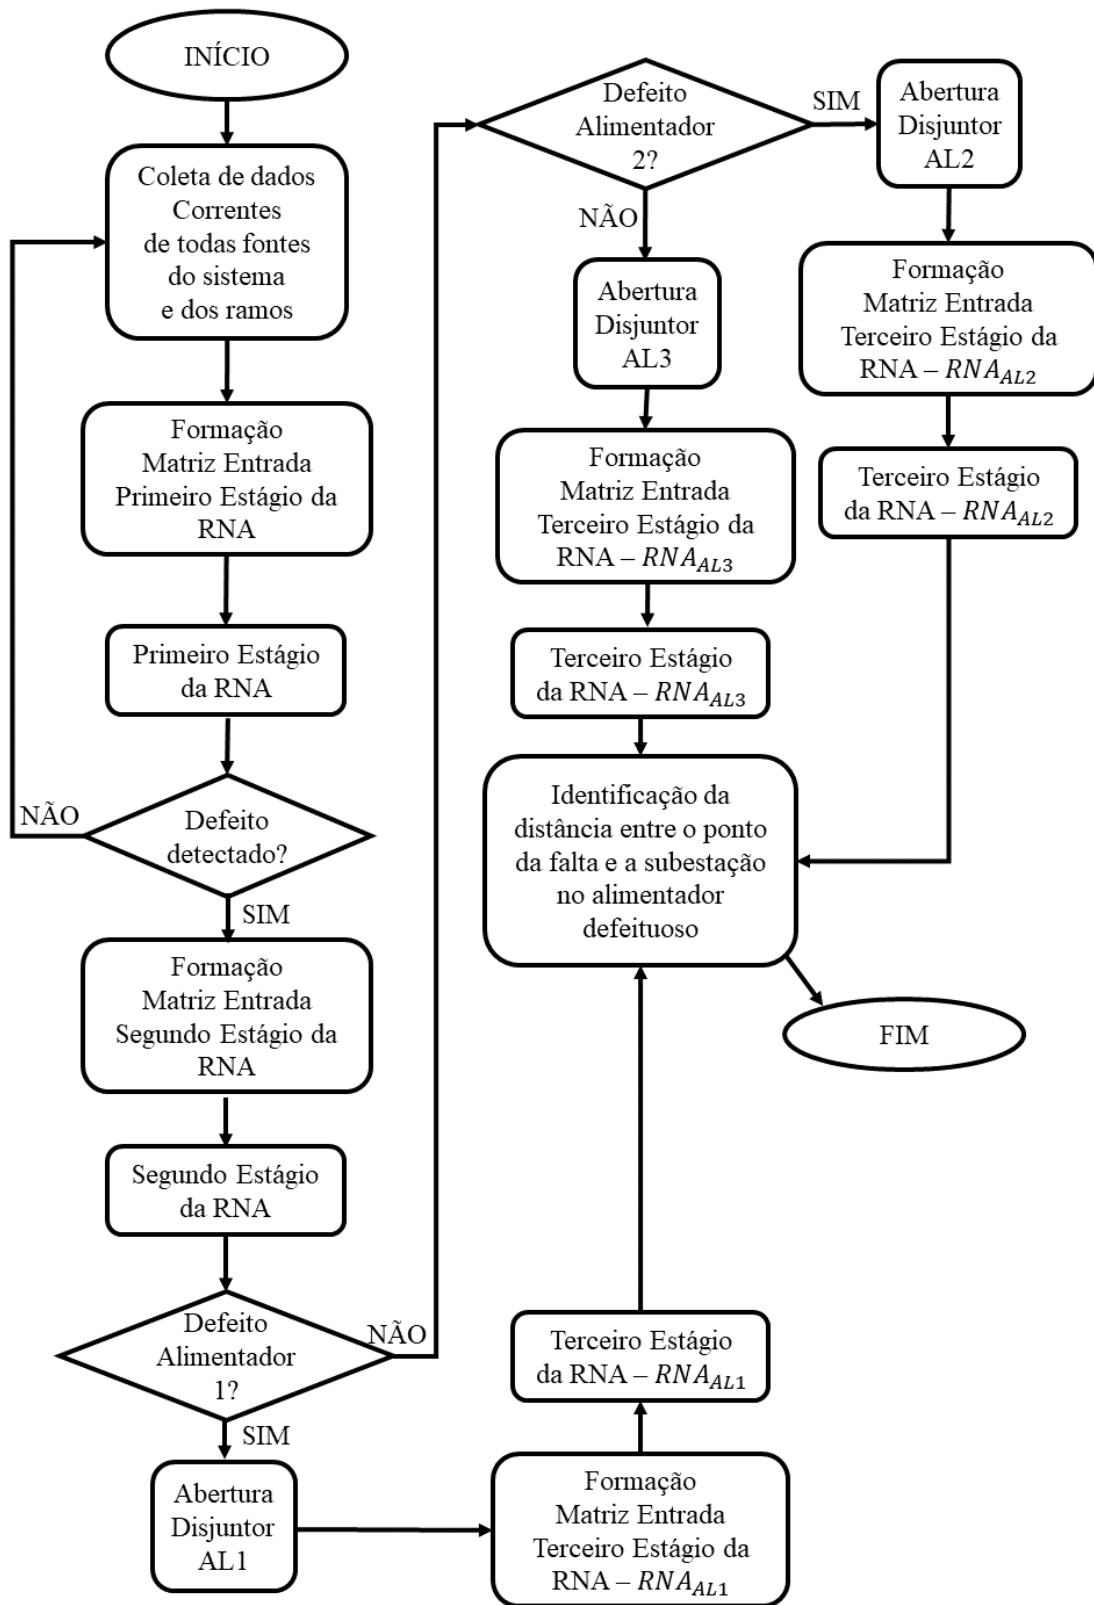


Figura 31: Fluxograma de operação da estratégia de solução proposta

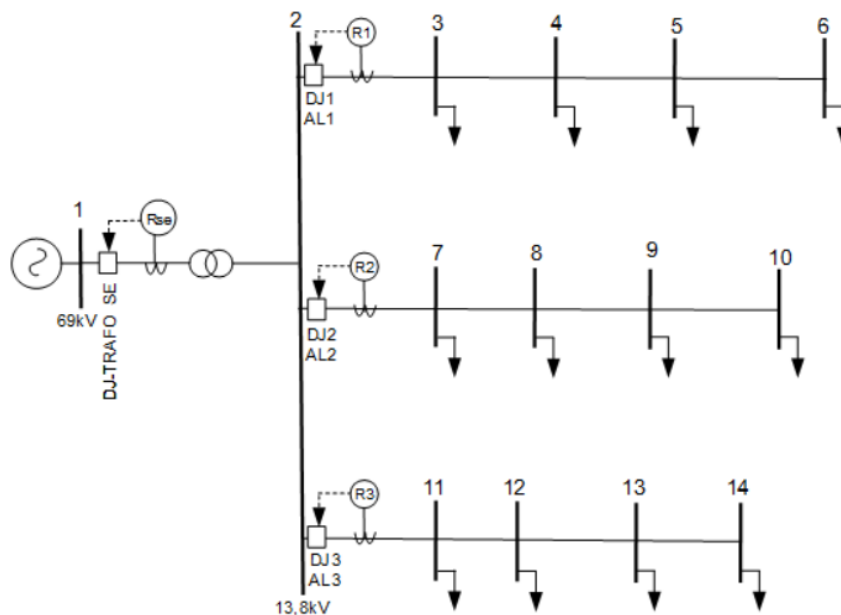


Figura 32: Diagrama unifilar do sistema de distribuição de 14 barras

Uma vez detectado o defeito, o segundo estágio da rede neural é acionado – a identificação do alimentador defeituoso. Nesse estágio, a RNA deve indicar em qual alimentador está presente o defeito e acionar a abertura de seu respectivo disjuntor.

Por fim, tem-se o terceiro estágio – aquele que identifica o ponto do defeito do alimentador. Para esse estágio, são desenvolvidas três redes neurais distintas, cada uma destinada a localizar a falta em um alimentador específico. A utilização desse estágio tem como função beneficiar a atuação das equipes de reparo da concessionária, possibilitando uma maior agilidade no reparo do sistema e reduzindo o tempo para restabelecimento da rede.

As RNAs são específicas para cada configuração da rede, destinada a operar para um número específico de geradores distribuídos. Sabe-se que pode ocorrer inserção de mais GDs ao longo do tempo, conseqüentemente, há a necessidade de retrainar a rede a fim de garantir a detecção e localização de falta precisos.

Esse treinamento das RNAs é realizado *offline*, de maneira supervisionada com o algoritmo de treinamento *backpropagation*. Antes de iniciar o fluxograma proposto, a rede é treinada para uma configuração da rede com número específico de GDs. Todas as redes neurais desenvolvidas são do tipo *Perceptron* Multi-Camadas, composto por apenas uma camada escondida de neurônios, visto que é o suficiente segundo o teorema de

aproximação universal [49]. As entradas correspondem a valores amostrados de corrente do sistema de distribuição. Nas seções a seguir, serão detalhados aspectos de treinamento e topologia de cada uma das redes neurais utilizadas no sistema.

5.2 Primeiro Estágio da RNA

O Primeiro Estágio da RNA é responsável pela detecção de defeitos no sistema. A rede PMC é composta por três camadas: a camada de entrada, saída e outra intermediária – escondida. Tanto a camada de saída como a escondida são compostas por neurônios. O número de neurônios na camada escondida é dimensionado de acordo com a aplicação proposta. São testados diferentes números de neurônios e verificada a eficácia da rede para cada configuração.

O número de entradas é também variável, dependendo do número de GDs no sistema. Já o número de saídas é sempre igual a dois. É uma indicação binária da ausência ou presença de defeito no sistema, conforme apresentado pela Tabela 5. A rede neural desenvolvida é destinada para resolver um problema de classificação e reconhecimento de padrões. Por ser um classificador, as saídas são valores lógicos.

Tabela 5: Respostas esperadas do Primeiro Estágio da RNA

Situação da operação do sistema de distribuição	Saída ₁	Saída ₂
Normal	0	1
Sob-falta	1	0

O treinamento da rede é realizado a partir dos conjuntos de amostras de entradas-saídas do sistema. As saídas fornecidas são as apresentadas pela Tabela 5. Por outro lado, as entradas correspondem às injeções de corrente das fontes do sistema para cada um dos defeitos estudados, incluindo as correntes de saída da subestação.

A Figura 33 ilustra a composição dos dados de entrada e saída para treinamento da RNA. Os módulos das correntes de fase de cada fonte são dispostos em dois instantes consecutivos de simulação (t e $t + a$). A constante a se refere à taxa de amostragem

utilizada, no valor de 0,005s. Esse valor se mostrou eficiente para a aplicação proposta e coincide com o passo utilizado na simulação.

Dessa forma, para cada padrão, existem duas saídas, que correspondem a uma situação específica da rede: [0 1] para situação normal ou [1 0] para sistema defeituoso. Essa composição é específica para o caso de apenas uma GD no sistema, com 12 entradas. O intervalo de simulação para cada defeito é de 0s a 2s, com falta aplicada no instante de 1 segundo. Dessa forma, tem-se um equilíbrio nos padrões de treinamento da rede: 1 segundo com sistema em operação normal e 1 segundo com defeito. Assim, 199 padrões obtidos correspondem a 1 segundo no intervalo de simulação. São ao todo 398 padrões por defeito simulado. Como foram simulados 10 tipos de defeitos diferentes, totalizaram-se assim 3980 padrões para treinamento da RNA do Primeiro Estágio.

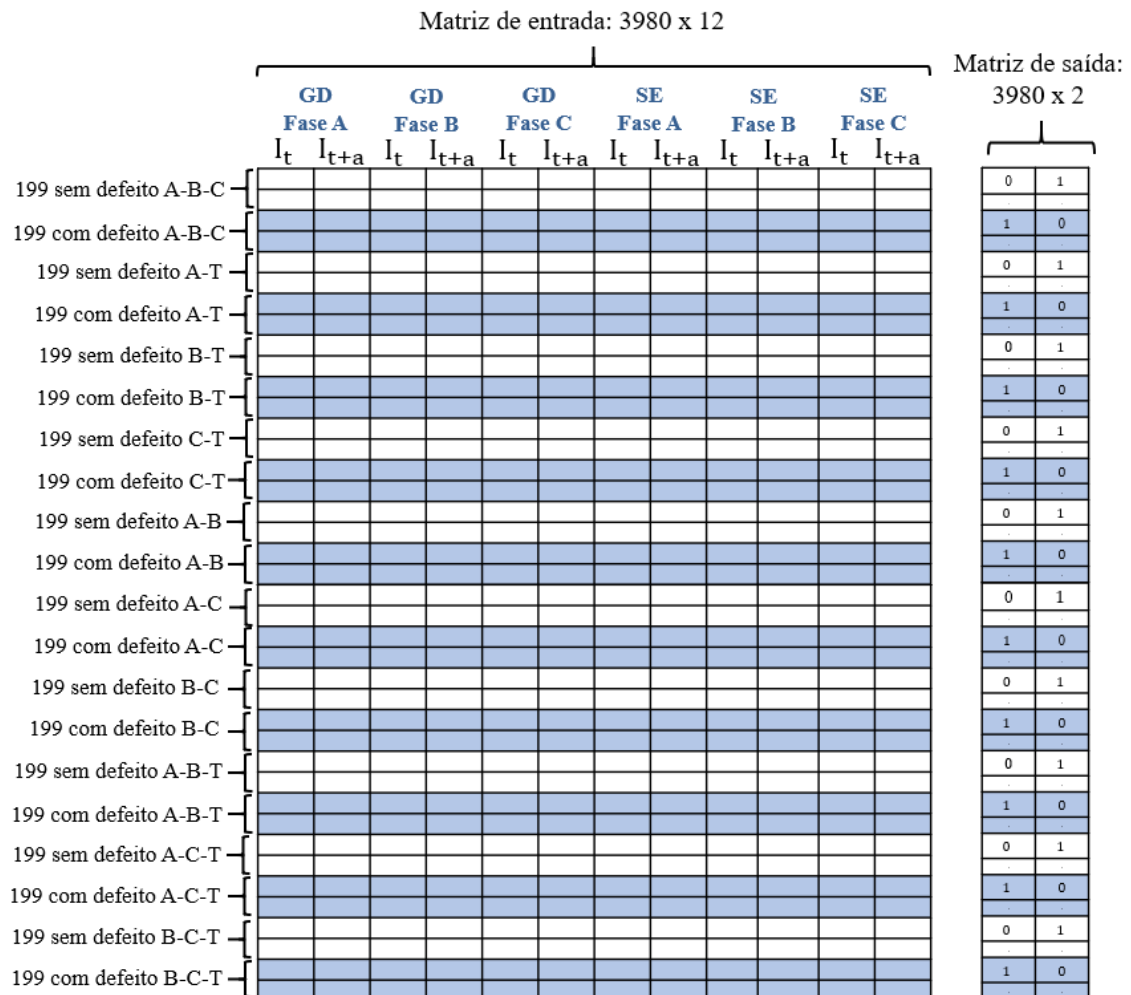


Figura 33: Composição dos dados de entrada-saída para treino do 1ºEstágio da RNA

Todos os defeitos estudados ocorrem na Barra 6 do sistema, final do AL1. São simulados dez tipos de defeitos distintos, incluindo faltas trifásicas, bifásicas e monofásicas: ABC, AT, BT, CT, AB, AC, BC, ABT, ACT, BCT. A Figura 34 ilustra os pontos de medições das correntes de entrada da RNA na presença de 1 GD do sistema, bem como a barra de defeito para treinamento do Primeiro Estágio da RNA.

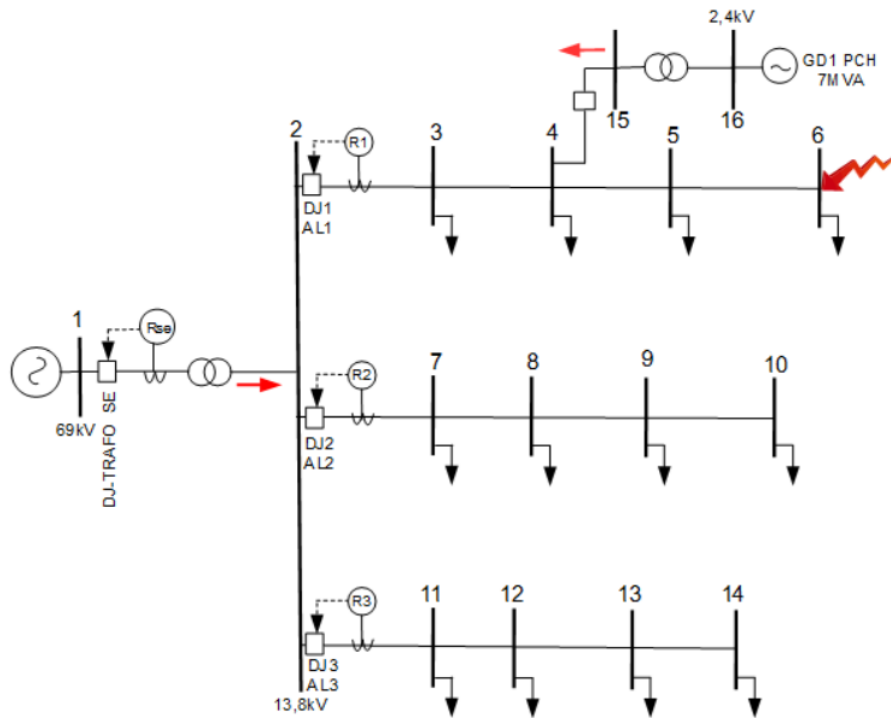


Figura 34: Correntes e defeito para Primeiro Estágio da RNA

Os conjuntos de treinamento, validação e teste das RNAs são dispostos de acordo com a Tabela 6. O agrupamento dos dados é realizado através de divisão por índices, permitindo que a divisão seja realizada a cada 199 padrões de entrada.

Tabela 6: Divisão dos dados de treinamento

Conjunto	Divisão (%)
Treinamento	60
Validação	20
Teste	20

Os neurônios da camada escondida e da camada de saída possuem como função de ativação a tangente hiperbólica sigmoide, visto que se trata de um problema de

reconhecimento de padrões. Os valores de entrada e saída são normalizados para intervalo $[-1,1]$, coincidindo assim com o intervalo de saída da função de ativação proposta. A saída sigmoïdal é convertida na resposta da lógica comparando os dois sinais obtidos pelos dois neurônios da camada de saída. O neurônio que apresentar maior sinal de saída, retornará saída 1, enquanto o com menor saída, retornará 0.

É sob esse aspecto que se justifica o uso de múltiplos neurônios na camada de saída. A princípio, apenas um neurônio de saída seria o suficiente para identificar o defeito no sistema. Entretanto, utiliza-se dois neurônios na camada de saída para facilitar a decodificação da resposta. Em um contexto de inferência bayesiana [53], o seu uso permite uma futura abordagem probabilística ao problema, tornando a rede capaz de indicar qual a resposta mais provável a partir de uma amostra de entrada.

5.3 Segundo Estágio da RNA

O Segundo Estágio da RNA é caracterizado pela indicação de qual alimentador está presente o defeito. Após o Primeiro Estágio, sabe-se que há um defeito no sistema, mas não é conhecida a sua localização. Novamente, o número de entradas para treinamento é variável de acordo com número de GDs, assim como número de neurônios na camada escondida.

A Tabela 7 apresenta as respostas esperadas das redes neurais de acordo com o alimentador defeituoso. Novamente, trata-se de um problema de reconhecimento de padrões. São sempre três saídas para treinamento, responsáveis por indicar em qual alimentador está presente o defeito. Para o treinamento, além dos módulos das correntes de defeito das GD(s) e de saída da subestação, também são utilizadas as correntes nos primeiros trechos de cada um dos alimentadores: Trecho 2-3, Trecho 2-7 e Trecho 2-11.

Tabela 7: Respostas esperadas do Segundo Estágio da RNA

Alimentador Defeituoso	Saída ₁	Saída ₂	Saída ₃
Alimentador 1	0	0	1
Alimentador 2	0	1	0
Alimentador 3	1	0	0

Essa composição é específica para o caso de um gerador distribuído no sistema, contabilizando ao todo 30 entradas. Assim como para o Primeiro Estágio, os módulos das correntes de fases de entrada são organizados para os instantes t e $t + a$. A taxa de amostragem é a mesma utilizada anteriormente (0,005s).

Diferentemente do Primeiro Estágio, a rede é treinada para três pontos diferentes de defeito no sistema: Barra 6, Barra 10 e Barra 14. A Figura 35 ilustra os pontos de defeito para treinamento, assim como as correntes utilizadas para entrada da RNA. São aplicados novamente dez tipos de defeito para as barras finais de cada alimentador: ABC, AT, BT, CT, AB, AC, BC, ABT, ACT, BCT. A composição dos dados de entrada-saída de treinamento é ilustrada na Figura 36.

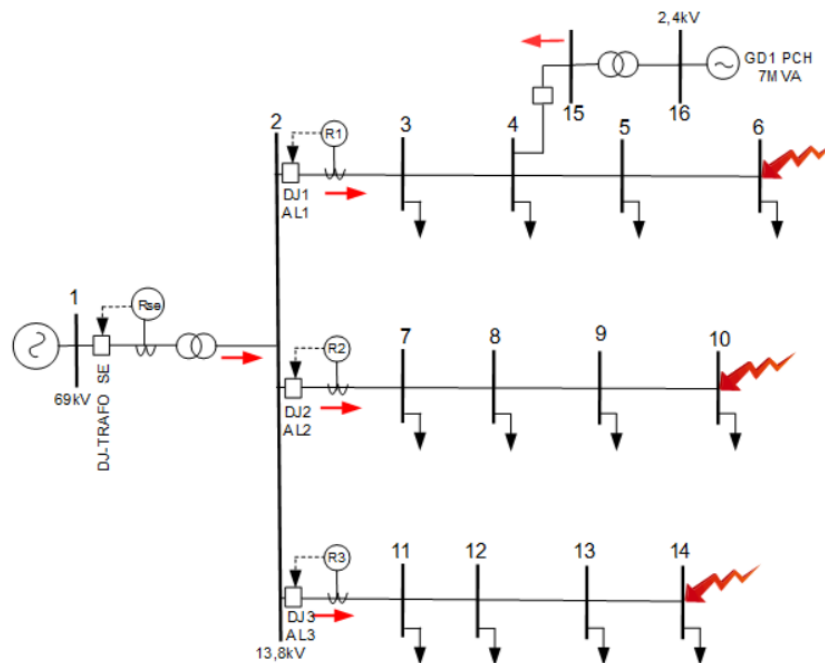


Figura 35: Correntes e defeitos para Segundo Estágio da RNA

Além disso, a rede é treinada apenas para dados do sistema com defeito. Cada 199 padrões utilizados correspondem ao intervalo de 1 a 2 segundos de simulação, com o defeito aplicado no instante de 1 segundo. São utilizados um total de 5970 padrões, cada um deles relacionando 30 entradas com 3 saídas do sistema.

Observa-se também um equilíbrio dos padrões fornecidos para treinamento da rede. Cada 1/3 dos dados correspondem a defeitos em um alimentador específico. A divisão dos conjuntos de treinamento segue o apresentado pela Tabela 6. Da mesma

forma, o mesmo processo de pré e pós-processamento dos dados via normalização no intervalo $[-1,1]$ do Primeiro Estágio é utilizado. A função de ativação tanto da camada escondida como da camada de saída é a tangente sigmoide. O neurônio com saída sigmoideal que retorna o maior sinal apresentará resposta lógica 1, indicando qual alimentador que está com defeito. Os outros dois neurônios restantes indicarão resposta 0.

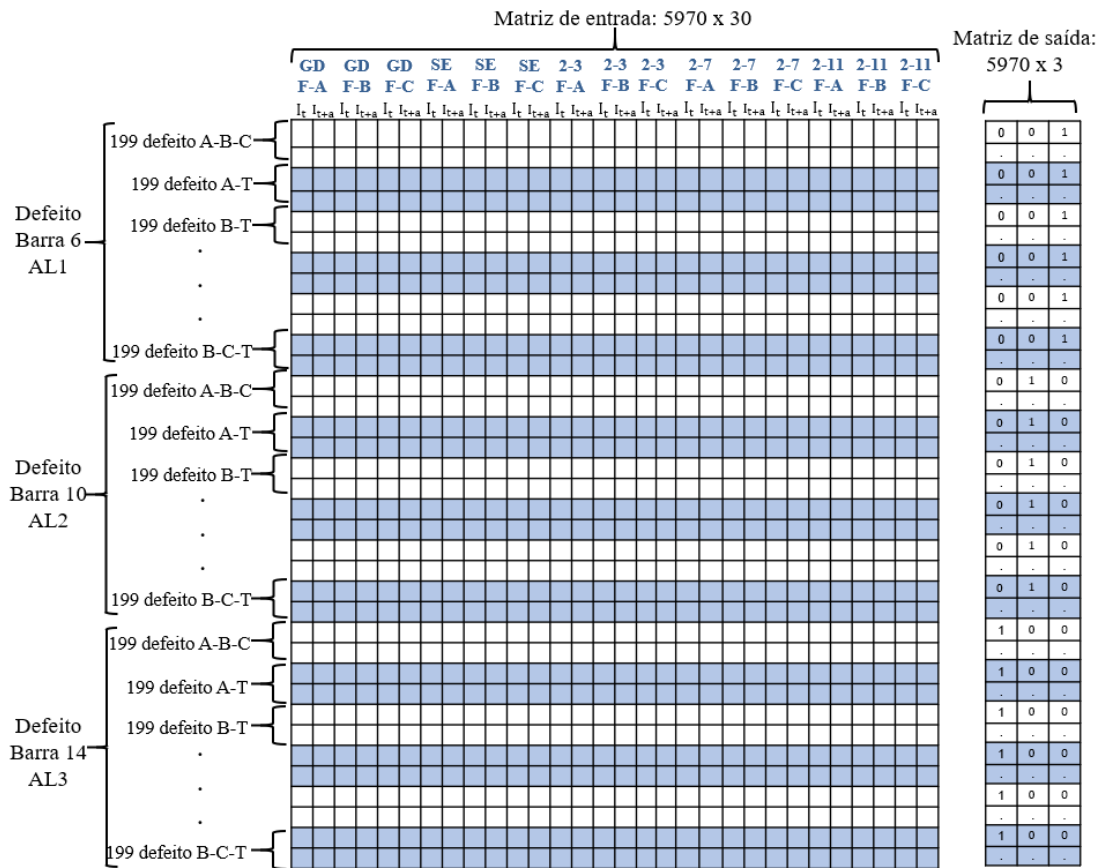


Figura 36: Composição dos dados de entrada-saída para treino do 2º Estágio da RNA

5.4 Terceiro Estágio da RNA

O Terceiro Estágio da RNA consiste na localização do ponto do defeito em cada alimentador. É composto por três redes neurais distintas, cada uma treinada para localizar faltas em um alimentador específico do sistema: RNA_{AL1} para Alimentador 1, RNA_{AL2} para Alimentador 2 e RNA_{AL3} para o Alimentador 3. Cada rede é acionada dependendo da resposta obtida pelo Segundo Estágio da RNA. O fluxograma desse Estágio é ilustrado na Figura 37.

Para o treinamento da RNA_{AL1} , são aplicados dez tipos defeitos (ABC, AT, BT, CT, AB, AC, BC, ABT, ACT, BCT) em todas as barras do alimentador: B2, B3, B4, B5 e B6. Para cada barra, é associada uma distância, que corresponde ao comprimento em quilômetros entre o ponto de defeito e a subestação.

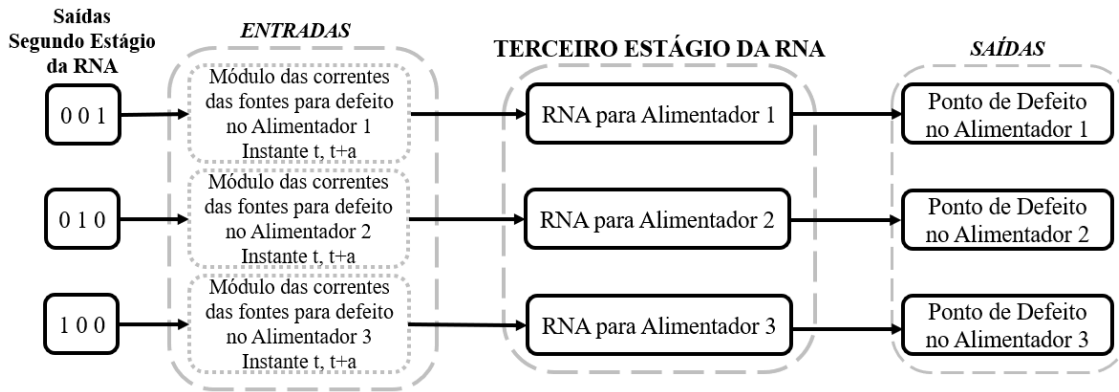


Figura 37: Mapeamento entradas-saídas para treinamento do Terceiro Estágio da RNA

A Tabela 8 apresenta a correspondência entre a barra de defeito e a saída utilizada para treinamento da rede RNA_{AL1} . A saída indica a distância entre o ponto de defeito e a subestação. A Figura 38 ilustra os defeitos aplicados para treinamento.

Tabela 8: Respostas esperadas da RNA_{AL1} para localização do defeito

Barra de Defeito	Saída da RNA
2	0
3	8
4	12
5	16
6	20

Os dados de módulos de corrente de entrada são referentes às fases A, B e C da GD e de saída da subestação. A Figura 39 apresenta a composição dos dados de entrada e saída para RNA_{AL1} . São 9950 padrões utilizados, 12 entradas (para o caso de 1 GD no sistema) e 1 saída.

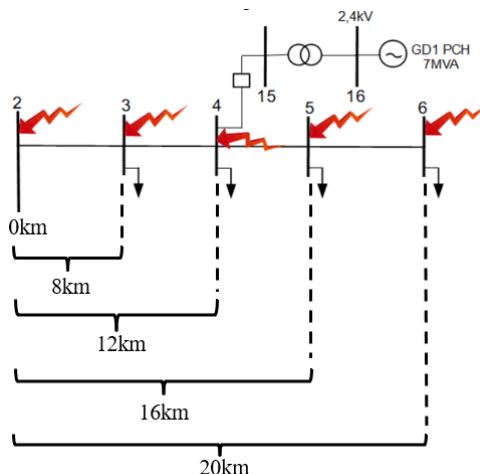


Figura 38: Defeitos aplicados para treinamento da RNA_{AL1}

Para a rede neural RNA_{AL2}, também são consideradas saídas contínuas. A rede é treinada para cinco pontos de defeito: B2, B7, B8, B9 e B10. A Tabela 9 relaciona a barra de defeito com a sua respectiva distância para a subestação. Na Figura 40 são apresentados os defeitos aplicados no treinamento.

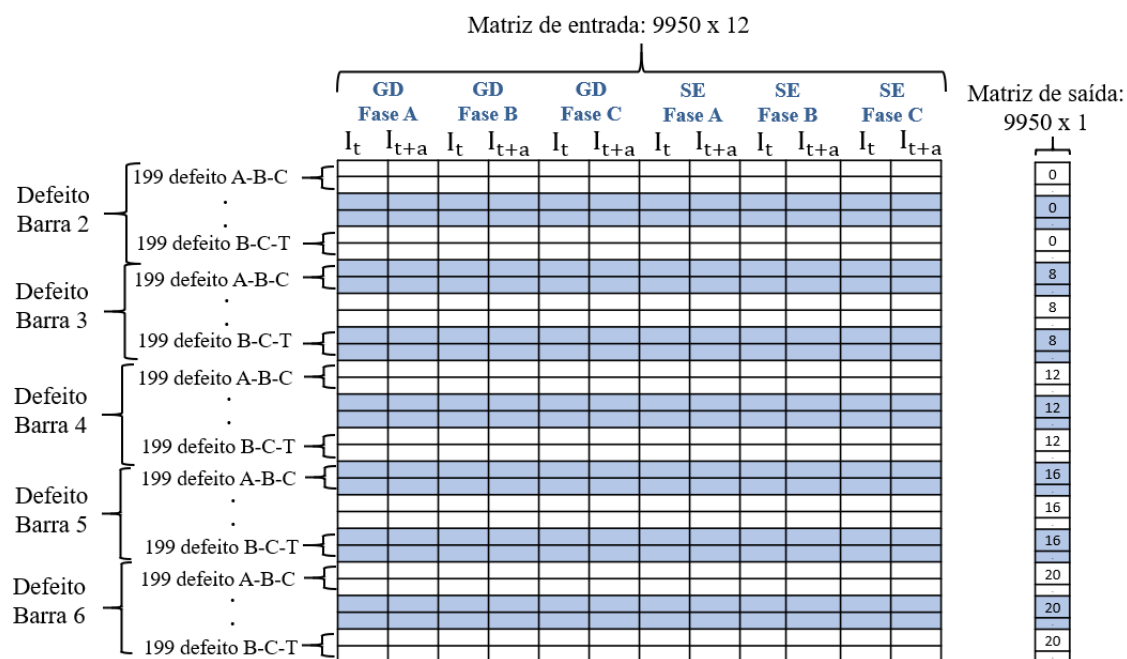


Figura 39: Composição dos dados de entrada-saída para treino RNA_{AL1}

Tabela 9: Respostas esperadas da RNA_{AL2} para localização do defeito

Barra de Defeito	Saída da RNA
2	0
7	3
8	7
9	11
10	15

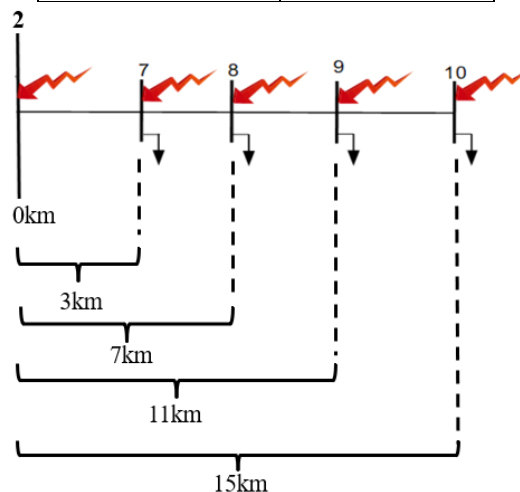


Figura 40: Defeitos aplicados para treinamento da RNA_{AL2}

Da mesma forma para a rede neural do Alimentador 1, foram aplicados dez tipos diferentes de defeito para cada barra do Alimentador 2. Resultou-se em um total de 9950 padrões, 12 entradas e 1 saída, apresentados na Figura 41.

Tem-se ainda a RNA_{AL3}, responsável por indicar o ponto de defeito no Alimentador 3. O processo de treinamento foi similar às duas redes anteriores. A rede é treinada para cinco pontos de defeito ao longo de seu alimentador, correspondentes às barras B2, B11, B12, B13 e B14. A Tabela 10 apresenta a relação entre as saídas esperadas da rede para cada defeito aplicado, de acordo com a distância da falta para a subestação.

A Figura 42 ilustra a disposição dos defeitos ao longo do alimentador para treinamento da RNA_{AL3}.

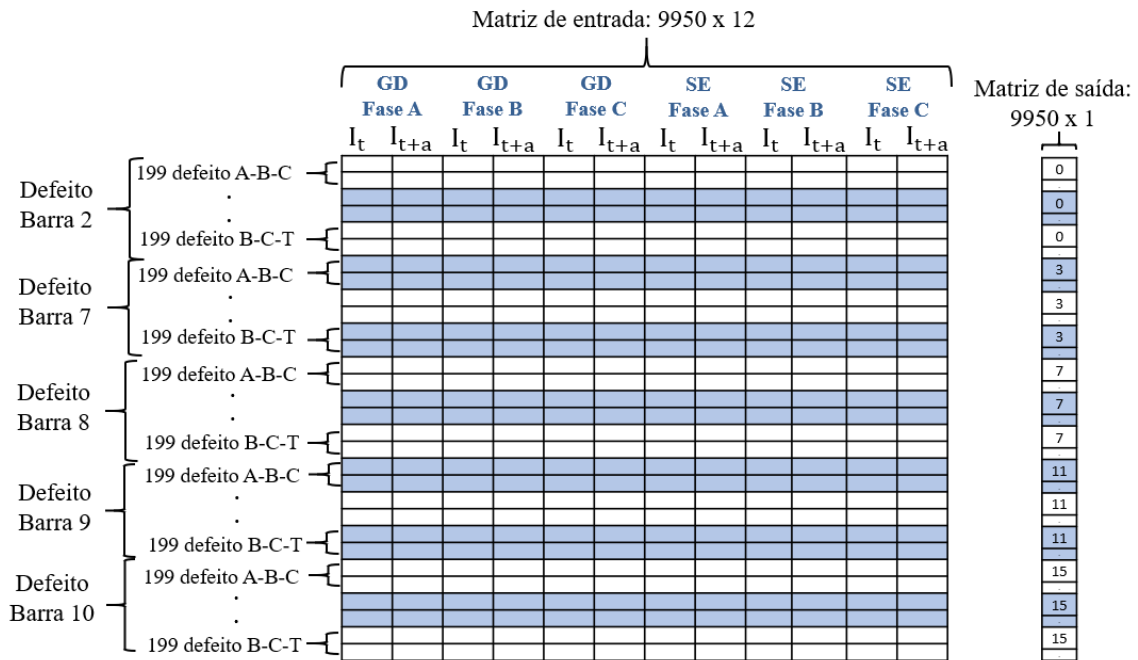


Figura 41: Composição dos dados de entrada-saída para treino RNA_{AL2}

Tabela 10: Respostas esperadas da RNA_{AL3} para localização do defeito

Barra de Defeito	Saída da RNA
2	0
11	1
12	5
13	9
14	13

Novamente, dez tipos de defeitos são aplicados em cada uma das barras do Alimentador 3, compreendendo faltas trifásicas, bifásicas e monofásicas. A Figura 43 apresenta a composição dos dados de entrada e saída para o treinamento da RNA_{AL3} . Para 9950 padrões, tem-se 12 entradas e 1 saída.




Figura 42: Defeitos aplicados para treinamento da RNA_{AL3}

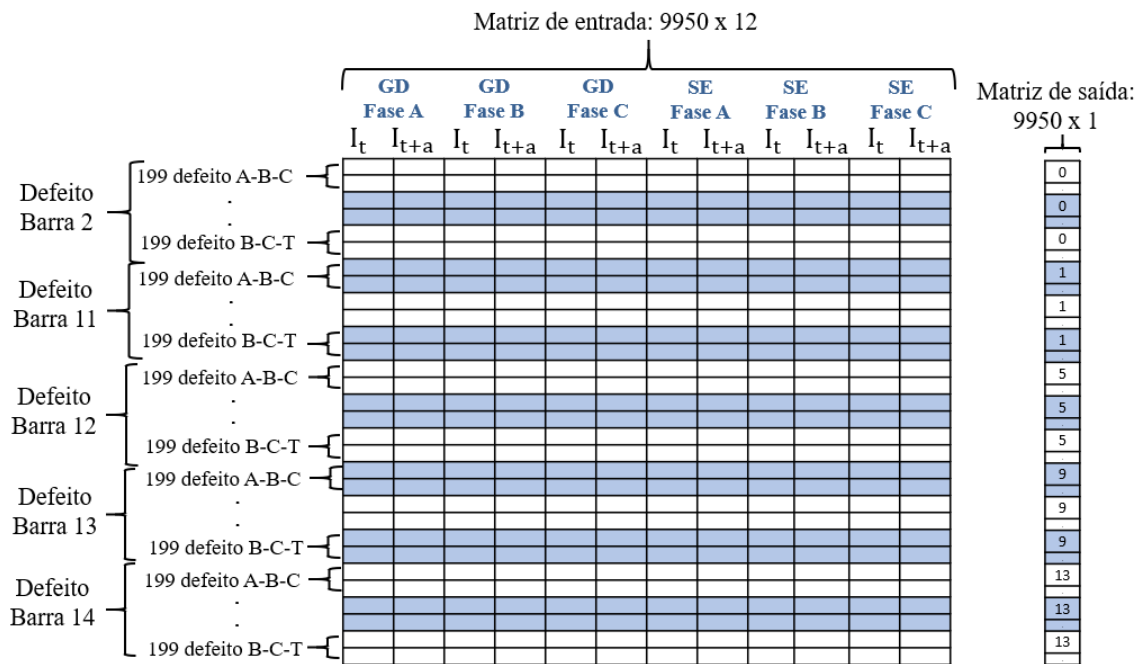


Figura 43: Composição dos dados de entrada-saída para treino RNA_{AL3}

O treinamento das três RNAs do Terceiro Estágio RNA_{AL1}, RNA_{AL2} e RNA_{AL3} utilizam dados de módulos das correntes apenas na presença de defeito do sistema, em um intervalo de 1 a 2 segundos de simulação. Obtém-se desse modo 199 padrões por defeito simulado. Os padrões de treinamento se encontram equilibrados: cada 1/5 dos dados corresponde a um defeito em uma barra diferente.

Como as saídas são contínuas, todas as três redes neurais RNA_{AL1} , RNA_{AL2} e RNA_{AL3} comportam-se como aproximadores de funções. Dessa forma, a função de ativação utilizada para as três RNAs na camada de saída é linear, enquanto da camada escondida permanece sendo a tangente hiperbólica sigmoide.

As divisões dos dados de treinamento para as três RNAs também seguem a Tabela 6, assim como os dados de entrada e saída são normalizados no intervalo $[-1,1]$.

No Capítulo 6, será descrito o estudo de caso proposto para este trabalho, assim como são apresentados as simulações e os resultados obtidos.

CAPÍTULO 6

ESTUDO DE CASO

6.1 Introdução

Neste Capítulo são apresentadas informações relativas à implementação computacional das redes neurais artificiais como solução para o problema da proteção em redes de distribuição ativas de energia.

Para as simulações do sistema elétrico, foi utilizado o *software* SIMULIGHT [61], [62]. Desenvolvido pela COPPE, o SIMULIGHT permite uma modelagem trifásica de um dado sistema de distribuição. O mesmo conta com aplicativos de fluxo de potência para análise estática e simulação dinâmica no tempo. A modelagem dos equipamentos é formulada a partir de uma biblioteca existente, permitindo a edição dos dados do sistema por parte do usuário em uma *interface* simples.

O uso do SIMULIGHT teve como objetivo a formação de um banco de dados com informações dos níveis de curto-circuito de toda a rede de distribuição. A partir da manipulação desse banco de dados, são criadas matrizes de entrada para as redes neurais artificiais. As matrizes contêm dados de contribuições de correntes das fontes do sistema para cada um dos defeitos estudados.

A implementação das redes neurais artificiais foi realizada no *software* MATLAB®. Através do mesmo, é possível realizar cálculos com matrizes, construção de gráficos, análises numéricas, dentre outras funcionalidades. Além disso, o *software*

conta com uma *toolbox* específica para redes neurais artificiais. As RNAs podem ser simuladas também via *script* – programação em linguagem própria do programa, opção essa que foi utilizada nesse trabalho. O código desenvolvido no MATLAB é apresentado no Anexo A.

A metodologia de estudo proposta se restringiu ao uso de GDs baseadas em máquinas síncronas. Isso se deve ao fato das RNAs utilizarem como entrada as correntes de defeito de cada uma das fontes e GDs conectadas via conversores eletrônicos não apresentam uma contribuição significativa para as faltas no sistema. O impacto estudado pela inserção da GD se refere aos relés de sobrecorrente dos alimentadores da empresa distribuidora. A análise do tipo de interconexão de transformadores com a concessionária bem como o esquema de proteção próprio do gerador distribuído estão fora do escopo deste trabalho. A estratégia adotada será avaliada em um sistema de distribuição de 14 barras, descrito a seguir.

6.2 Sistema Teste

O diagrama unifilar do sistema de distribuição estudado é apresentado na Figura 32. Trata-se de uma rede de distribuição de 13,8kV. Os alimentadores estão conectados a uma subestação equipada com um transformador abaixador de 69/13,8 kV. O sistema consiste em uma rede de distribuição rural típica, com alimentadores radiais. É composto também por cargas balanceadas nas barras dos alimentadores e cinco bancos de capacitores fixos. O perfil de tensão do sistema atende aos limites estabelecidos pela referência [20].

Os dados do sistema são apresentados nas Tabelas 11, 12, 13 e 14 a seguir, modelados em pu nas bases 100MVA e 13,8kV. As simulações realizadas utilizam modelagem trifásica da rede e dos equipamentos associados.

Tabela 11: Dados do transformador da subestação

EQUIPAMENTO	Potência (MVA)	Alta Tensão (kV)	Baixa Tensão (kV)	R(%)	X(%)	Tipo de Ligação
TRANSFORMADOR SE	12,5	69	13,8	3,55	63,90	

Tabela 12: Dados das cargas

Barra	Fase A		Fase B		Fase C		Total	
	P(MW)	Q(Mvar)	P(MW)	Q(Mvar)	P(MW)	Q(Mvar)	P(MW)	Q(Mvar)
3	0,333	0,16	0,333	0,16	0,333	0,16	1	0,48
4	0,2233	0,1067	0,2233	0,1067	0,2233	0,1067	0,67	0,32
5	0,5567	0,27	0,5567	0,27	0,5567	0,27	1,67	0,81
6	0,2233	0,1067	0,2233	0,1067	0,2233	0,1067	0,67	0,32
7	0,333	0,16	0,333	0,16	0,333	0,16	1	0,48
8	0,2233	0,1067	0,2233	0,1067	0,2233	0,1067	0,67	0,32
9	0,5567	0,27	0,5567	0,27	0,5567	0,27	1,67	0,81
10	0,2233	0,1067	0,2233	0,1067	0,2233	0,1067	0,67	0,32
11	0,333	0,16	0,333	0,16	0,333	0,16	1	0,48
12	0,2233	0,1067	0,2233	0,1067	0,2233	0,1067	0,67	0,32
13	0,5567	0,27	0,5567	0,27	0,5567	0,27	1,67	0,81
14	0,2233	0,1067	0,2233	0,1067	0,2233	0,1067	0,67	0,32
TOTAL							12,03	5,83

Tabela 13: Dados dos bancos de capacitores

Barra	Potência (Mvar)		
	Fase A	Fase B	Fase C
3	0,1	0,1	0,1
7	0,6	0,6	0,6
10	0,5	0,5	0,5
11	0,6	0,6	0,6
14	0,5	0,5	0,5

6.2.1 Ajuste da Proteção dos Alimentadores

A modelagem da proteção requer a determinação dos ajustes do relé de sobrecorrente 50/51 de fase e de neutro dos três alimentadores. A atuação dos relés permite eliminar defeitos trifásicos, bifásicos ou monofásicos que porventura podem

ocorrer no sistema. O ajuste é composto de três aspectos a serem escolhidos: o valor de *pick-up*, dial de tempo e tipo de curva de tempo inverso.

Tabela 14: Dados dos ramais dos alimentadores

Trecho	R(%)	X(%)	L(km)
2-3	126,906	171,86	8
3-4	127,011	91,12	4
4-5	127,011	91,12	4
5-6	127,011	91,12	4
2-7	47,59	64,45	3
7-8	127,011	91,12	4
8-9	127,011	91,12	4
9-10	127,011	91,12	4
2-11	15,86	21,48	1
11-12	127,011	91,12	4
12-13	127,011	91,12	4
13-14	127,011	91,12	4

No estudo não foram utilizados equipamentos como religadores, fusíveis e seccionadores para proteção do sistema. Entretanto, para uma análise futura de todo o esquema de proteção, é necessário considerar a presença desses dispositivos.

6.2.1.1 Ajuste do Relé de Sobrecorrente de Fase

O valor de *pick-up* de ajuste do relé de sobrecorrente de fase é realizado a partir das expressões (3.2) e (3.3). O limite mínimo é estabelecido na condição normal do sistema com carga pesada. A Tabela 15 apresenta as correntes de carga que circulam nos relés R1, R2 e R3 nessa configuração.

Tabela 15: Correntes de carga pesada

Corrente de carga pesada (pu)		
Trecho 2-3 – Relé R1	Trecho 2-7 – Relé R2	Trecho 2-11 – Relé R3
0,044	0,041	0,040

Sendo assim, o limite mínimo pode ser calculado pela Tabela 16.

Tabela 16: Limites mínimos para ajuste dos relés de sobrecorrente de fase

Relé	Limite Mínimo (pu)
R1	$1,5 * 0,044 = 0,066$
R2	$1,5 * 0,041 = 0,061$
R3	$1,5 * 0,0040 = 0,060$

Para calcular o limite máximo do ajuste, são obtidas as correntes para defeitos trifásicos no final de cada um dos alimentadores e calculada as correntes bifásicas a partir de (3.3). A Tabela 17 apresenta as correntes mínimas de defeito e o cálculo do limite máximo, na situação de carga leve no sistema. A partir dos limites mínimos e máximos, é possível determinar o ajuste de cada relé. A faixa de ajuste é apresentada na Tabela 18.

Tabela 17: Corrente de defeito mínima no final do trecho e limite máximo

Ponto de defeito	Relé	Corrente de defeito trifásico (pu)	Corrente de defeito bifásico (pu)	Limite Máximo (pu)
Barra 6	R1	0,141	0,121	$0,121 / 1,1 = 0,111$
Barra 10	R2	0,173	0,149	$0,149 / 1,1 = 0,136$
Barra 14	R3	0,190	0,165	$0,165 / 1,1 = 0,149$

Tabela 18: Faixas de ajuste dos relés de sobrecorrente de fase

R1	$0,066 \leq I_{\text{ajuste fase R1}} \leq 0,111$
R2	$0,061 \leq I_{\text{ajuste fase R2}} \leq 0,136$
R3	$0,060 \leq I_{\text{ajuste fase R3}} \leq 0,149$

Dessa forma, é estabelecido o mesmo valor de ajuste para todos os relés de fase. O valor de ajuste (*pick-up*) escolhido é de 0,10 pu.

Além do valor de ajuste, foi escolhida a curva Tipo 1, moderadamente inversa, segundo a referência [28] e alavanca de tempo de 0,2. A Tabela 19 sintetiza os ajustes escolhidos para os relés de fase R1, R2 e R3.

Tabela 19: Ajustes definidos para os relés de sobrecorrente de fase

Corrente de <i>Pick-up</i>	Tipo de Curva Inversa	Dial de Tempo
0,10	Moderadamente Inversa	0,2

6.2.1.2 Ajuste do Relé de Sobrecorrente de Neutro

O ajuste do relé de sobrecorrente de neutro é realizado a partir de (3.4) e da Figura 3. As correntes de carga pesada no sistema são as mesmas apresentadas pela Tabela 15. A Tabela 20 apresenta o cálculo dos limites mínimos para ajustes dos relés de neutro.

Tabela 20: Limites mínimos para ajuste dos relés de sobrecorrente de neutro

Relé	Limite Mínimo (pu)
R1	$0,45 * 0,044 = 0,020$
R2	$0,45 * 0,041 = 0,019$
R3	$0,45 * 0,040 = 0,018$

Para o cálculo do limite máximo da corrente de *pick-up* do relé é aplicado um defeito monofásico na fase A no final do AL1 (Barra 6), no instante de 1 segundo. A Figura 44 ilustra o comportamento das correntes de fase e de neutro que circulam pelo relé R1 para esse defeito, em situação de carga leve no sistema.

Inicialmente, o circuito está equilibrado, sem circulação de corrente no neutro. Após o defeito, as correntes das fases são permanecem as mesmas para atender as cargas do circuito. Já as correntes da fase A e de neutro sofrem um aumento substancial imediatamente após a aplicação do defeito. A corrente de neutro representa a soma das três correntes de fase (Fase A, Fase B e Fase C). Pela mesma circula a corrente do sistema elétrico em direção à terra.




Figura 44: Correntes do trecho 2-3 para defeito monofásico na fase A na barra 6

As mesmas simulações são feitas para os relés R2 e R3. A Tabela 21 apresenta as correntes de defeito detectadas por cada relé quando um defeito monofásico na fase A é aplicado no final de seu respectivo alimentador. Também é apresentado o limite máximo, calculado a partir da corrente de neutro no defeito. Assim, obtém-se as faixas de ajustes para cada um dos relés, mostradas na Tabela 22.

Tabela 21: Corrente de defeito monofásico no final do trecho e limite máximo

Ponto de defeito	Relé	Corrente de defeito monofásico (pu)	Limite Máximo (pu)
Barra 6	R1	0,125	$0,125 /_{1,1} = 0,113$
Barra 10	R2	0,153	$0,153 /_{1,1} = 0,139$
Barra 14	R3	0,170	$0,170 /_{1,1} = 0,154$

Tabela 22: Faixas de ajuste dos relés de sobrecorrente de neutro

R1	$0,020 \leq I_{\text{ajuste neutro R1}} \leq 0,113$
R2	$0,019 \leq I_{\text{ajuste neutro R2}} \leq 0,139$
R3	$0,018 \leq I_{\text{ajuste neutro R3}} \leq 0,154$

A partir do intervalo de ajuste, é escolhido o ajuste 0,09 pu para o valor de *pick-up* do relé de sobrecorrente de neutro. O tipo de curva inversa e dial de tempo são os mesmos do relé de fase. O ajuste é apresentado pela Tabela 23.

Tabela 23: Ajustes definidos para os relés de sobrecorrente de neutro

Corrente de <i>Pick-up</i>	Tipo de Curva Inversa	Dial de Tempo
0,09	Moderadamente Inversa	0,2

6.3 Inserção da Geração Distribuída

Com o sistema de proteção dimensionado, o próximo passo consiste na avaliação do impacto de um gerador distribuído nos ajustes das proteções existentes. Para isso, foi inserida uma pequena central hidrelétrica (PCH) no sistema. Trata-se de um gerador distribuído caracterizado pelo uso de máquinas síncronas. Esse tipo de geração é comum no Brasil todo, estando presente também no Estado do Rio de Janeiro.

As PCHs são usinas hidrelétricas de potências entre 1,1 e 30 megawatts (MW) [63]. Caso a usina tenha tamanho máximo de 1MW, é classificada como central geradora hidrelétrica (CGH). Esses empreendimentos são de baixo impacto ambiental, auxiliando na proteção das margens de rios contra a erosão. Segundo consulta à Banco de Informações da Geração (BIG) da ANEEL (Agência Nacional de Energia Elétrica) [64], há 428 PCHs e 694 CGHs instaladas no Brasil. O Estado do Rio de Janeiro conta com 19 PCHs e 16 CGHs ao todo.

Inicialmente é inserida uma PCH (GD1) de 7MW na Barra 4 do Alimentador 1. A Figura 45 ilustra o sistema de distribuição com a presença da GD. Os dados dos geradores síncronos podem ser encontrados na Tabela 24, em que os valores estão na base 3,125MVA. O tipo de ligação do transformador de interconexão é estrela-aterrado / estrela-aterrado.

A fim de demonstrar o impacto da GD no sistema de proteção, foram simulados três casos distintos, apresentados na Tabela 25. Para todos esses casos, foram aplicadas faltas trifásicas e monofásicas na Barra 6 do sistema.

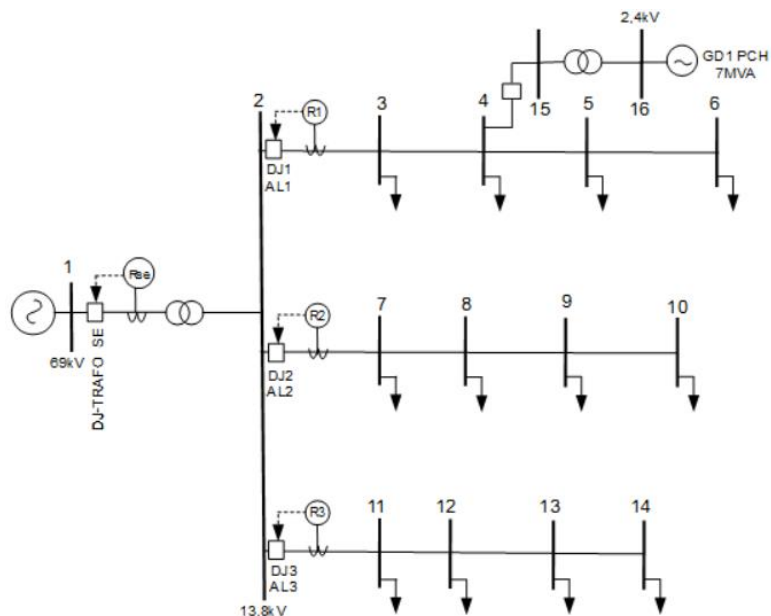


Figura 45: Diagrama unifilar com GD1

Tabela 24: Parâmetros das máquinas

Parâmetro	Valor	Parâmetro	Valor
H (constante de inércia)	3s	T''do (constante de tempo subtransitória eixo-d)	0,04s
r (resistência do estator)	0,3%	T''qo (constante de tempo subtransitória eixo-q)	0,06s
xd (reatância síncrona eixo-d)	91,1%	Rneg (resistência de sequência negativa)	30%
xq (reatância síncrona eixo-q)	58%	Xneg (reatância de sequência negativa)	17,1%
x'd (reatância transitória eixo-d)	40,8%	Rzer (resistência de sequência zero)	0,85%
x''d (reatância subtransitória eixo-d)	32,9%	Xzer (reatância de sequência zero)	30%
T'do (constante de tempo transitória eixo-d)	4,2s	Número de unidades	3

Tabela 25: Casos de impacto na proteção do alimentador

Caso	Descrição			
	Barra da GD	Barra de Defeito	Modelagem da Proteção	
			Alimentador	GD
1	----	6	Sim	Não se aplica
2	4	6	Sim	Sim
3	4	6	Sim	Não

6.3.1 Caso 1

O Caso 1 é caracterizado pela ausência de qualquer geração distribuída no sistema. Para um defeito no final do alimentador, espera-se que atue a unidade de tempo inverso do relé 50/51 localizado na saída da subestação para o AL1, de acordo com Figura 5. Dessa forma, a Figura 46 apresenta o comportamento da corrente que circula pelo trecho 2-3 ao ser aplicado um defeito trifásico na Barra 6, no final do Alimentador 1, no instante de 1s. O relé de sobrecorrente de tempo inverso atua e elimina o defeito em 0,285s após o defeito.




Figura 46: Corrente no trecho 2-3 para defeito trifásico na Barra 6 para Caso 1

A simulação é repetida para um defeito monofásico na fase A do Alimentador 1, também na Barra 6. As correntes no trecho 2-3 são apresentadas na Figura 47. O defeito é eliminado em 0,260s pelo relé de fase.




Figura 47: Correntes para defeito monofásico na fase A na Barra 6 para Caso 1

6.3.2 Caso 2

No Caso 2, ocorre a inserção da geração distribuída no sistema. A proteção própria da GD1 foi parametrizada de forma simplificada, sendo composta por um relé de sobrecorrente instantâneo, com corrente de *pick-up* igual 0,10 pu e tempo de atraso de 0,05s, correspondente ao tempo para abertura do disjuntor da GD1. Os ajustes são satisfatórios, uma vez que permitem o desligamento da GD1 para defeitos que possam ocorrer na rede de distribuição. A Figura 48 ilustra o comportamento das correntes do trecho 2-3 do AL1 e da GD1 para um defeito trifásico na Barra 6 do sistema.

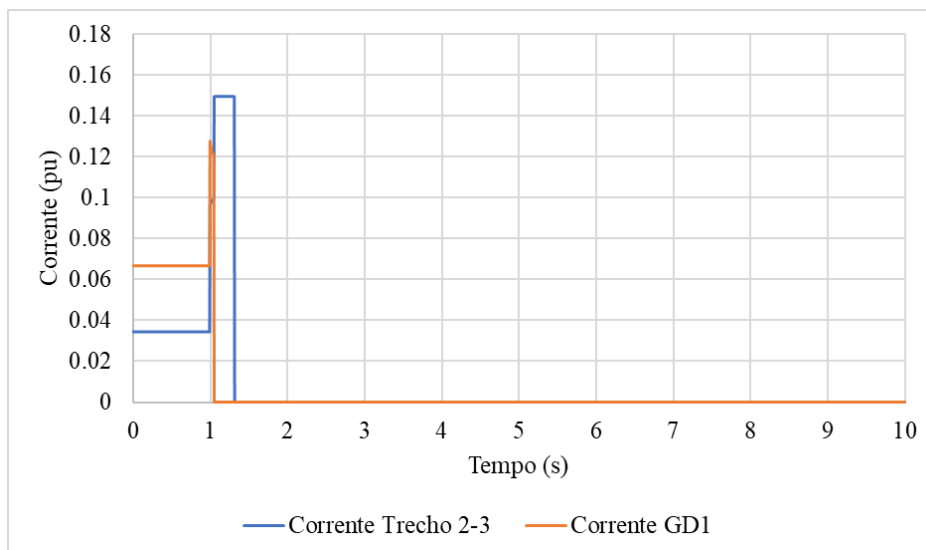


Figura 48: Correntes para defeito trifásico na Barra 6 para Caso 2

Para o Caso 2, tanto a proteção do alimentador como a da GD1 atuam para um defeito no AL1. A GD1 é desconectada do sistema de 0,055s, enquanto o relé R1 atua após 0,320s. Também foi simulado um defeito monofásico na fase A no final do AL1. Os resultados são demonstrados na Figura 49.

Assim como no defeito trifásico, o gerador distribuído é desconectado do sistema de 0,055s e a proteção do alimentador leva 0,320s para eliminar o defeito.

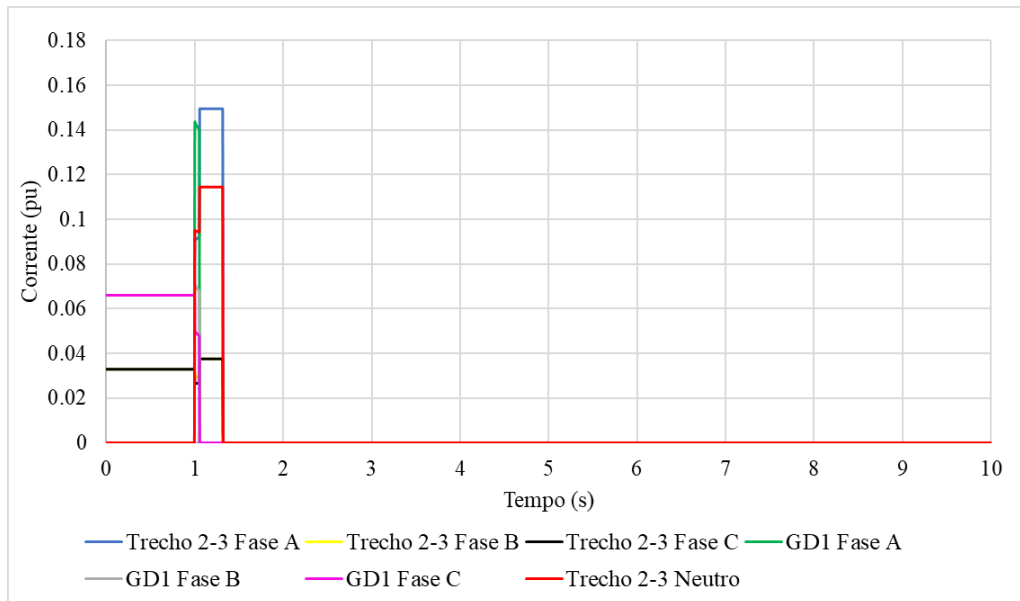


Figura 49: Correntes para defeito monofásico na fase A na Barra 6 para Caso 2

6.3.3 Caso 3

O Caso 3 ilustra o cenário mais grave, que consiste na não-atuação da proteção da GD para defeitos na rede. Dessa forma, ao ocorrer uma falta no alimentador, a GD permanece conectada, contribuindo para o defeito. Essa situação é indesejável e impacta diretamente na proteção do alimentador.

A Figura 50 apresenta o impacto da GD na atuação do relé R1 para um defeito trifásico no final do Alimentador 1. A proteção atua em um tempo total de 2,845 segundos, podendo provocar consideráveis danos aos equipamentos da rede, consumidores finais e à própria GD. Também foi simulado um defeito fase A-T na Barra 6 do sistema. A Figura 51 ilustra o comportamento das correntes para esse defeito. Como a proteção da GD não atua, o relé de neutro do alimentador leva 1,70s para atuar, caracterizando um tempo longo de atuação.




Figura 50: Correntes no trecho 2-3 para defeito trifásico na Barra 6 para Caso 3




Figura 51: Correntes para defeito monofásico na fase A na Barra 6 para Caso 3

6.3.4 Comparação dos Casos

A Tabela 26 resume os resultados obtidos nos Casos 1, 2 e 3, apresentando os respectivos tempos de atuação da proteção para cada caso. Esse tempo compreende o intervalo entre o instante de ocorrência do defeito e o instante de abertura do disjuntor.

O Caso 1 é caracterizado pela atuação esperada da proteção. Sem a inserção de geração distribuída no sistema, os relés de sobrecorrente eliminam os defeitos em menos de 300ms. No Caso 2, já é possível verificar a influência da GD na proteção do

alimentador. Entretanto, como a GD é desconectada do sistema pela sua proteção logo após o defeito, o tempo para atuação do relé do alimentador não é aumentado consideravelmente (de 0,285 para 0,320s, para defeito trifásico, e 0,260s para 0,320s, para defeito monofásico).

Tabela 26: Comparação dos tempos de atuação da proteção para casos estudados

Caso	Tempo para atuação da proteção (s)			
	Defeito trifásico na Barra 6		Defeito monofásico na Barra 6	
	Alimentador	GD1	Alimentador	GD1
1	0,285	Não se aplica	0,260	Não se aplica
2	0,320	0,055	0,320	0,055
3	2,845	Não atua	1,700	Não atua

O Caso 3 ilustra um problema mais significativo na proteção do alimentador. Os relés de sobrecorrente são sensibilizados pela corrente de defeito, mas acionam a abertura de seus respectivos disjuntores em um tempo longo: 1,700s para defeito monofásico e 2,845s para defeito trifásico. Um aumento no tempo de atuação de mais de 9 vezes, com relação ao Caso 1, para defeito trifásico, e mais de 6 vezes, para falta monofásica.

Buscando evitar que essa situação ocorra, faz-se necessário utilizar uma alternativa à proteção convencional, de forma que a concessionária não dependa da atuação da proteção da GD, garantindo a segurança do sistema mesmo que a GD não seja desconectada do sistema após o defeito. Caso a RNA consiga detectar o defeito e localizá-lo em menos de 1,70s, a mesma se apresenta como solução ao caso estudado. Na seção a seguir a metodologia proposta será aplicada para o sistema de distribuição estudado em dois cenários distintos.

6.4 Simulações

Nesta seção são apresentados os resultados para as simulações dos três estágios das redes neurais artificiais. Para isso, são estudados dois cenários distintos, apresentados na Tabela 27. O Cenário 1 é caracterizado pela presença de apenas um gerador distribuído no sistema, uma PCH de 7MW, localizada na Barra 4 e já detalhada na Tabela 24.

Tabela 27: Cenários estudados

Cenário	Descrição
1	GD1 – PCH de 7MW na Barra 4
2	GD1 – PCH de 7MW na Barra 4 e GD2 – PCH de 2,5MW na Barra 12

No Cenário 2, uma outra pequena central hidrelétrica é adicionada no sistema (GD2). É uma GD similar à inserida no primeiro cenário, mas injetando menos potência na rede: 2,5MW. A GD2 está localizada no Alimentador 3, na Barra 12. Como já demonstrado, a inserção desse tipo de GD impacta diretamente no funcionamento da proteção de sobrecorrente dos alimentadores de distribuição.

Para cada um dos cenários estudados, foram utilizados três tipos de funções de treinamento para as RNAs presentes no MATLAB: Regularização Bayesiana, *Levenberg-Marquardt* e Gradiente Conjugado Escalonado. O desempenho de cada uma das funções é comparado para a escolha da melhor rede (arquitetura e pesos sinápticos). Como critério de parada do treinamento, foram utilizados o número de épocas 10000 e mínimo gradiente de $1,00e^{-07}$, sendo escolhido o conjunto de pesos e bias que resultam no menor erro para o conjunto de validação. O parâmetro μ é utilizado para o controle do algoritmo de treinamento, sendo incrementado à medida que o gradiente diminui.

São testados diferentes números de neurônios na camada escondida e verificada a topologia que produz um melhor desempenho para cada rede neural e cenário estudado.

6.4.1 Cenário 1

O diagrama unifilar do sistema para o Cenário 1 é ilustrado na Figura 45. A seguir, serão detalhados os resultados dos três estágios das RNAs.

6.4.1.1 Primeiro Estágio da RNA

O Primeiro Estágio da RNA é iniciado a partir do treinamento *offline* da primeira rede neural artificial. A partir dos dados de correntes da GD1 e de saída da subestação e das saídas [0 1] ou [1 0], a rede é treinada. Na presença de uma GD no sistema, a composição de dados é apresentada na Figura 33.

O desempenho de cada modelo (variação do número de neurônios) é obtido para cada conjunto de dados (treinamento, validação e teste) para cada algoritmo de treinamento (Regularização Bayesiana, Levenberg-Marquardt e Gradiente Conjugado Escalonado). São consideradas dez topologias candidatas da rede PMC para cada algoritmo de treinamento utilizado, variando de 1 a 10 neurônios na camada escondida. Todas as redes treinadas possuem 12 entradas, 2 saídas e compostas por 3980 padrões. Após o treinamento da RNA, é escolhida a topologia com melhor desempenho.

Mesmo com a variação do número de neurônios da camada escondida e também com o teste de diferentes funções de treinamento, a rede foi capaz de ter 100% de eficácia em todas as configurações testadas para cada um dos conjuntos de treinamento (treinamento, validação e teste). Esses valores de eficácia são obtidos através das Matrizes de Confusão de cada topologia treinada, comparando as saídas obtidas pela rede com as saídas-alvo. Assim, é possível avaliar a eficácia da rede para cada conjunto de treinamento.

Dessa forma, é escolhida a topologia apresentada Tabela 28, obtida no treinamento com Regularização Bayesiana. A rede com 1 neurônio na camada escondida é mais simples de ser implementada computacionalmente e ao mesmo tempo é eficaz. O uso do algoritmo BR se deve ao fato de intrinsecamente controlar o problema de *overfitting* [53]. Como todos os algoritmos obtiveram o mesmo resultado, esse critério teórico é utilizado para escolha da topologia.

Tabela 28: Topologia escolhida do Primeiro Estágio da RNA para o Cenário 1

Nº de Neurônios da Camada Escondida	Método de Treinamento	Número de entradas	Número de saídas	Número de padrões
1	BR	12	2	3980

O gráfico da evolução dos erros dos conjuntos de treinamento para a topologia escolhida é apresentado na Figura 52. A simulação consistiu em um total de 151 épocas, atingindo o mínimo valor de gradiente $1,00e^{-07}$. A Figura 53 ilustra as Matrizes de Confusão da topologia escolhida.




Figura 52: Evolução dos erros no treinamento do 1º Estágio da RNA para Cenário 1

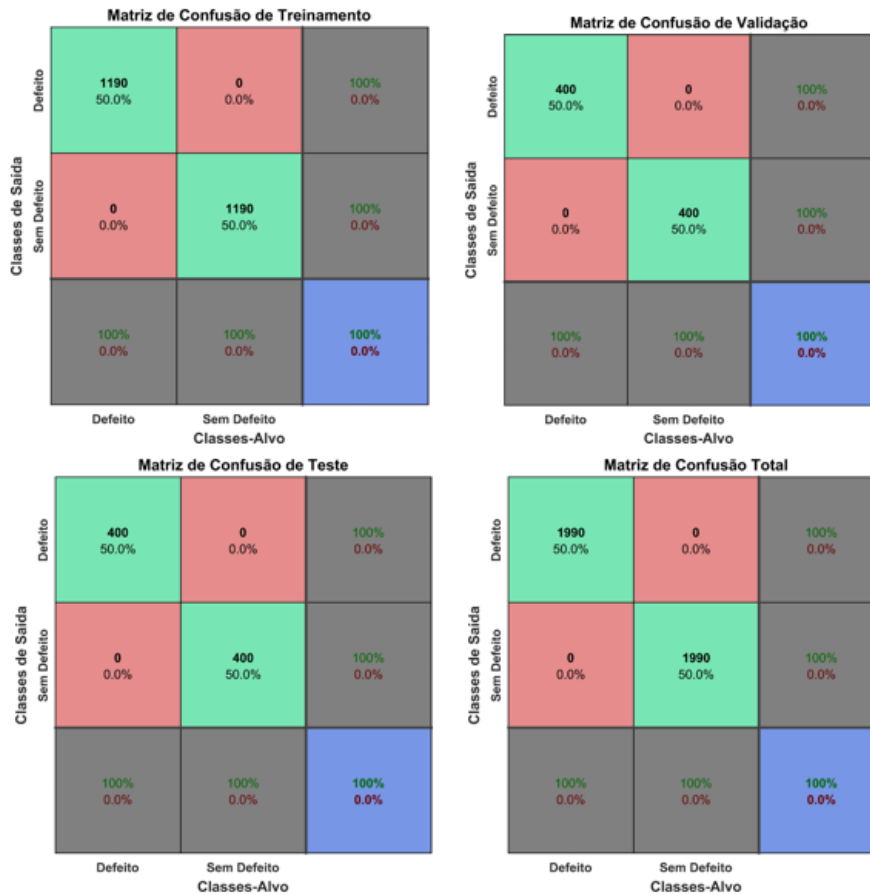


Figura 53: Matriz confusão do Primeiro Estágio da RNA para o Cenário 1

Uma vez escolhida a topologia da RNA, o próximo passo consiste no teste da RNA para outros pontos de defeito no sistema. O objetivo é verificar se a RNA é capaz de identificar defeitos para pontos os quais a mesma não foi treinada. A Figura 54 ilustra

os pontos de defeito no sistema em que a RNA é testada. São ao todo defeitos em cinco barras: B3, B8, B10, B11 e B14. Para cada um deles, é avaliado o desempenho da rede para dez tipos de defeitos diferentes.




Figura 54: Pontos de defeito para teste da RNA do Primeiro Estágio para Cenário 1

As entradas de teste das RNAs correspondem a dois instantes consecutivos de simulação para cada um dos módulos das correntes de fase de entrada do sistema. O primeiro instante corresponde ao instante antes do defeito ($t = 1 - a = 0,995s$) e o segundo ao instante de defeito ($t = 1s$). Totalizam-se 12 entradas e 1 único padrão para cada defeito testado. Com isso, espera-se que a rede indique a presença de defeito no sistema para todos os casos simulados.

As respostas obtidas pela rede nos testes são apresentadas na Tabela 29. A saída 10 significa que a rede indicou um sistema defeituoso. Como pode-se verificar, para todos os defeitos, nas cinco barras, a rede neural foi capaz de detectar a presença de defeito no sistema.

6.4.1.2 Segundo Estágio da RNA

Inicialmente, é realizado o treinamento do Segundo Estágio da RNA. Utilizando a composição de dados de treinamento segundo a Figura 36, a rede é treinada para as três funções de treinamento: Regularização Bayesiana, Levenberg-Marquardt e Gradiente Conjugado Escalonado. A Tabela 30, a Tabela 31 e a Tabela 32 apresentam a eficácia de cada uma das redes treinadas de acordo com o número de neurônios na camada escondida.

Novamente, optou-se por variar entre 1 a 10 neurônios e avaliar o desempenho para cada configuração. São treinadas para 30 entradas e 3 saídas, com 5970 padrões.

Tabela 29: Resultados dos testes do 1º Estágio da RNA para outros pontos de defeito no Cenário 1

Barra de defeito	Saída da RNA									
	Trifásico	Monofásico-Terra			Bifásico			Bifásico-Terra		
	ABC	AT	BT	CT	AB	AC	BC	ABT	ACT	BCT
3	10	10	10	10	10	10	10	10	10	10
8	10	10	10	10	10	10	10	10	10	10
10	10	10	10	10	10	10	10	10	10	10
11	10	10	10	10	10	10	10	10	10	10
14	10	10	10	10	10	10	10	10	10	10

Tabela 30: Eficácias do 2º Estágio da RNA com algoritmo de Regularização Bayesiana para o Cenário 1

Número de neurônios	Eficácia (%) – Segunda RNA			
	Treinamento	Validação	Teste	Total
1	66,7	66,7	66,7	66,7
2	100	100	100	100
3	100	100	100	100
4	100	100	100	100
5	100	100	100	100
6	100	100	100	100
7	100	100	100	100
8	100	100	100	100
9	100	100	100	100
10	100	100	100	100

Tabela 31: Eficácias do 2º Estágio da RNA com algoritmo Levenberg Marquardt para o Cenário 1

Número de neurônios	Eficácia (%) – Segunda RNA			
	Treinamento	Validação	Teste	Total
1	66,7	66,7	66,7	66,7
2	100	100	100	100
3	100	100	100	100
4	100	100	100	100
5	100	100	100	100
6	100	100	100	100
7	100	100	100	100
8	100	100	100	100
9	100	100	100	100
10	100	100	100	100

Tabela 32: Eficácias do 2º Estágio da RNA com algoritmo Gradiente Conjugado Escalonado para o Cenário 1

Número de neurônios	Eficácia (%) – Segunda RNA			
	Treinamento	Validação	Teste	Total
1	76,7	76,7	76,7	76,7
2	100	100	100	100
3	100	100	100	100
4	100	100	100	100
5	100	100	100	100
6	100	100	100	100
7	100	100	100	100
8	100	100	100	100
9	100	100	100	100
10	100	100	100	100

Com exceção da configuração de 1 neurônio na camada escondida, todas as outras redes tiveram 100% de eficácia, tanto para os conjuntos de treinamento, validação, teste

e o conjunto total. A Tabela 33 apresenta a rede então escolhida, novamente treinada através do método de Regularização Bayesiana. Novamente, como todos os algoritmos apresentaram os mesmos resultados, a escolha pelo algoritmo BR se dá pela sua capacidade intrínseca de controlar o problema de *overfitting*.

A evolução dos erros dos conjuntos de treinamento para a respectiva topologia escolhida é apresentada na Figura 55. Observa-se uma redução no erro quadrático médio suficiente para garantir a eficácia da RNA. Além disso, é obtida também a Matriz de Confusão, ilustrada na Figura 56, com 100% de eficácia para todos os conjuntos.

Tabela 33: Topologia escolhida do Segundo Estágio da RNA para o Cenário 1

Nº de Neurônios da Camada Escondida	Método de Treinamento	Número de entradas	Número de saídas	Número de padrões
2	BR	30	3	5970




Figura 55: Evolução dos erros no treinamento do 2º Estágio da RNA para Cenário 1

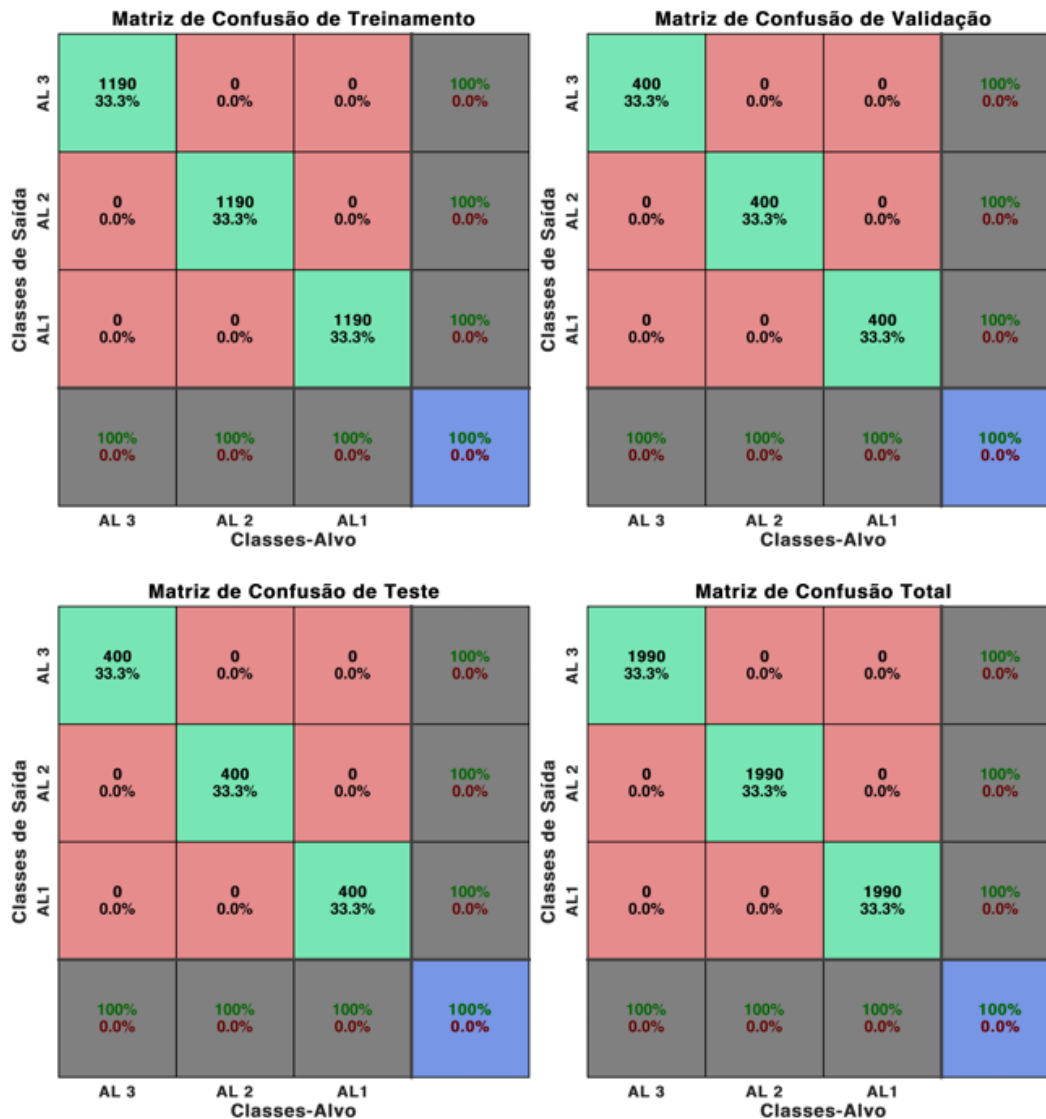


Figura 56: Matriz confusão do Segundo Estágio da RNA para o Cenário 1

O próximo passo consiste no teste da RNA para outros pontos de defeito do sistema, os quais a rede não foi treinada. A Figura 57 ilustra os pontos de defeito para testes, contabilizando no total de três barras: B3, B8 e B11.

Cada padrão de teste contém os módulos das correntes de entrada de cada fase para dois instantes de tempo consecutivos. O primeiro corresponde ao instante de defeito ($t = 1s$) e o segundo ao instante seguinte de amostragem ($t = 1 + 0,005 = 1,005s$). A Tabela 34 apresenta os resultados obtidos nos testes. É possível verificar que a rede foi capaz de identificar corretamente o alimentador defeituoso para todos os tipos de defeitos testados.

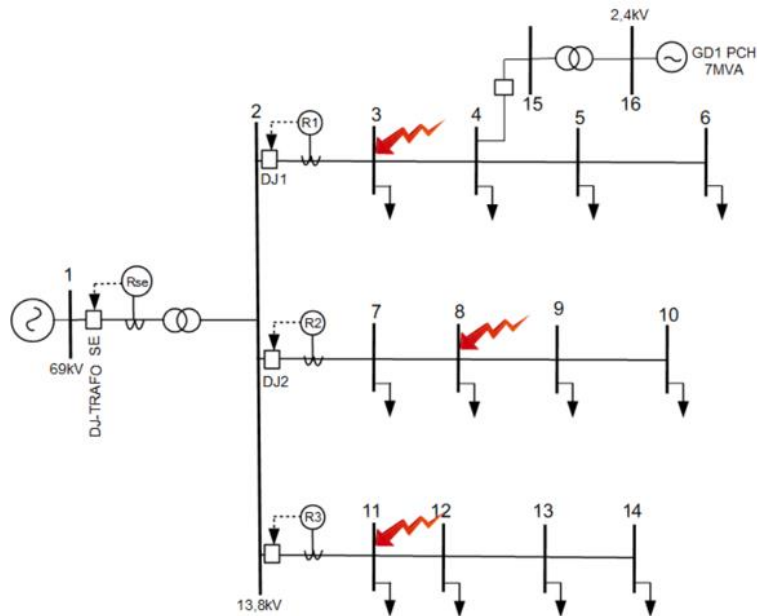


Figura 57: Pontos de defeito para teste da RNA do Segundo Estágio para Cenário 1

Tabela 34: Resultados dos testes do 2º Estágio da RNA para outros pontos de defeito no Cenário 1

Barra de defeito	Saída da RNA									
	Trifásico	Monofásico-Terra			Bifásico			Bifásico-Terra		
	ABC	AT	BT	CT	AB	AC	BC	ABT	ACT	BCT
3	001	001	001	001	001	001	001	001	001	001
8	010	010	010	010	010	010	010	010	010	010
11	100	100	100	100	100	100	100	100	100	100

6.4.1.3 Terceiro Estágio da RNA

O Terceiro Estágio da RNA é composto por três RNAs: RNA_{AL1} , RNA_{AL2} e RNA_{AL3} . Cada uma delas é treinada separadamente. A Tabela 35, a Tabela 36 e a Tabela 37 apresentam os resultados do treinamento da RNA_{AL1} para diferentes topologias, variando o número de neurônios na camada escondida e o tipo de algoritmo de treinamento. A Figura 39 apresenta a composição dos dados de treinamento.

Tabela 35: Coeficientes de correlação da RNA_{ALI} com algoritmo Regularização Bayesiana para o Cenário 1

Número de neurônios	Coeficiente de Correlação (R)			
	RNA_{ALI}			
	Treinamento	Validação	Teste	Total
1	0,95467	0,95985	0,95975	0,95634
2	0,97606	0,97932	0,97496	0,97624
3	0,99085	0,99091	0,98771	0,99002
4	0,99308	0,99224	0,99162	0,99256
5	0,99777	0,99723	0,99345	0,9967
6	0,99761	0,99667	0,99417	0,9967
7	0,99701	0,99564	0,9901	0,99532
8	0,99744	0,99605	0,99266	0,99619
9	0,99971	0,99877	0,99519	0,99851
10	0,99991	0,99917	0,99718	0,99908

Tabela 36: Coeficientes de correlação da RNA_{ALI} com algoritmo Levenberg-Marquardt para o Cenário 1

Número de neurônios	Coeficiente de Correlação (R)			
	RNA_{ALI}			
	Treinamento	Validação	Teste	Total
1	0,95454	0,95977	0,95966	0,95625
2	0,97565	0,98009	0,97742	0,97675
3	0,98833	0,98491	0,98721	0,98737
4	0,99535	0,99532	0,99531	0,99532
5	0,99601	0,99601	0,99582	0,9958
6	0,99728	0,99636	0,9952	0,99663
7	0,99378	0,98957	0,98025	0,9902
8	0,99947	0,99812	0,9944	0,99817
9	0,99889	0,99618	0,98825	0,99616
10	0,99788	0,99611	0,99339	0,99658

Tabela 37: Coeficientes de correlação da RNA_{AL1} com algoritmo Gradiente Conjugado Escalonado para o Cenário 1

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL1}			
	Treinamento	Validação	Teste	Total
1	0,95397	0,95945	0,95928	0,95585
2	0,96588	0,97098	0,97007	0,96741
3	0,99048	0,99071	0,99026	0,99043
4	0,99247	0,99392	0,99218	0,99261
5	0,99399	0,9939	0,98948	0,99305
6	0,99717	0,9964	0,99389	0,99634
7	0,99818	0,99701	0,99207	0,99671
8	0,99912	0,99813	0,99472	0,99799
9	0,99942	0,99861	0,99468	0,99829
10	0,99857	0,99786	0,99554	0,99779

Diferentemente do Primeiro e do Segundo Estágio da RNA, a rede aqui atua como um aproximador com saídas contínuas. Conforme pode ser observado, a rede treinada pela Regularização Bayesiana com 10 neurônios na camada escondida obteve o melhor desempenho para a rede RNA_{AL1}, com o valor do R mais próximo de 1 para os conjuntos de treinamento, validação e teste. As características da rede escolhida são apresentadas na Tabela 38. O gráfico da evolução dos erros dessa rede é apresentado na Figura 58.

Tabela 38: Topologia escolhida da RNA_{AL1} para o Cenário 1

Nº de Neurônios da Camada Escondida	Método de Treinamento	Número de entradas	Número de saídas	Número de padrões
10	BR	12	1	9950

A seguir, a rede é testada para outros dois pontos de defeito no sistema. A Figura 59 ilustra a localização desses pontos e suas respectivas distâncias em relação à subestação. A Tabela 39 apresenta os resultados. Os dados de entrada são os módulos das correntes de cada fase para dois instantes de tempo consecutivos: 1 s e 1,005 s.




Figura 58: Evolução dos erros no treinamento da RNA_{AL1} para Cenário 1




Figura 59: Pontos de defeito para teste da RNA_{AL1} para Cenário 1

Tabela 39: Resultados dos testes da RNA_{AL1} para outros pontos de defeito no Cenário 1

Pto. da falta (km)	Erro (km) – Valor em módulo – RNA _{AL1}									
	ABC	AT	BT	CT	AB	AC	BC	ABT	ACT	BCT
4	1,069	2,802	1,599	0,269	0,089	1,850	0,406	0,667	0,516	0,253
18	0,199	0,161	0,021	0,198	0,433	0,020	0,302	0,126	0,037	0,167

O maior erro encontrado pela RNA_{AL1} foi para o defeito monofásico a 4km da subestação no valor de 2,8km. Entretanto, o erro médio obtido para todos os defeitos

testados foi de 559 metros, o que corresponde a 2,7% do comprimento total (20km) do Alimentador 1. O resultado é considerado satisfatório para localização dos defeitos no AL1.

Os mesmos procedimentos foram realizados para o treinamento da rede neural RNA_{AL2}, responsável pela localização de defeitos no Alimentador 2. A Tabela 40, Tabela 41 e Tabela 42 apresentam os coeficientes de correlação obtidos para cada RNA treinada.

Novamente, o melhor resultado encontrado se deu na configuração de 10 neurônios na camada escondida para o algoritmo de treinamento Regularização Bayesiana, apresentando um valor de R mais próximo de 1 para os conjuntos de treinamento, validação e teste.

A topologia escolhida para a RNA_{AL2} é apresentada na Tabela 43. Semelhante às RNA_{AL1}, a rede é composta por 12 entradas, 1 neurônio na camada de saída, 1 saída e 9950 padrões. A evolução dos erros é ilustrada na Figura 60.

Tabela 40: Coeficientes de correlação da RNA_{AL2} com algoritmo Regularização Bayesiana para o Cenário 1

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL2}			
	Treinamento	Validação	Teste	Total
1	0,92635	0,92527	0,92609	0,92603
2	0,92753	0,92593	0,92731	0,92706
3	0,96611	0,96205	0,9595	0,96372
4	0,95994	0,95625	0,95353	0,95777
5	0,99935	0,99937	0,99934	0,99935
6	0,99803	0,99751	0,9951	0,99728
7	0,99993	0,99969	0,99767	0,99936
8	0,99897	0,99872	0,99707	0,99851
9	0,9997	0,99995	0,99965	0,999
10	1	0,99999	0,99997	0,99999

Tabela 41: Coeficientes de correlação da RNA_{AL2} com algoritmo Levenberg-Marquardt para o Cenário 1

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL2}			
	Treinamento	Validação	Teste	Total
1	0,92639	0,92525	0,92612	0,92605
2	0,95945	0,95703	0,95795	0,95861
3	0,93145	0,92984	0,9313	0,93099
4	0,98696	0,98544	0,98473	0,98613
5	0,99729	0,99631	0,99601	0,99681
6	0,99947	0,99934	0,99539	0,99856
7	0,99945	0,99914	0,99893	0,99927
8	0,99989	0,99984	0,99961	0,99981
9	0,99476	0,9946	0,99222	0,9942
10	0,99978	0,99971	0,99953	0,99971

Tabela 42: Coeficientes de correlação da RNA_{AL2} com algoritmo Gradiente Conjugado Escalonado para o Cenário 1

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL2}			
	Treinamento	Validação	Teste	Total
1	0,9264	0,92539	0,92616	0,92611
2	0,95913	0,95687	0,95757	0,95831
3	0,98728	0,98611	0,98525	0,98657
4	0,99535	0,99519	0,99512	0,99522
5	0,99799	0,99804	0,99762	0,99791
6	0,99923	0,99895	0,99833	0,99898
7	0,99969	0,99967	0,99943	0,99963
8	0,99834	0,99823	0,99777	0,99815
9	0,99891	0,99882	0,99843	0,99879
10	0,99911	0,99909	0,99902	0,99908

Tabela 43: Topologia escolhida da RNA_{AL2} para o Cenário 1

Nº de Neurônios da Camada Escondida	Método de Treinamento	Número de entradas	Número de saídas	Número de padrões
10	BR	12	1	9950




Figura 60: Evolução dos erros no treinamento da RNA_{AL2} para Cenário 1

O teste da RNA_{AL2} foi realizado para outros dois pontos de defeito ao longo do Alimentador 2, conforme ilustrado na Figura 61. A Tabela 44 apresenta os resultados dos testes. A disposição das correntes de entrada dos testes é a mesma da RNA_{AL1}, para os instantes $t = 1s$ e $t = 1,005s$.




Figura 61: Pontos de defeito para teste da RNA_{AL2} para Cenário 1

Tabela 44: Resultados dos testes da RNA_{AL2} para outros pontos de defeito no Cenário 1

Pto. da falta (km)	Erro (km) – Valor em módulo – RNA _{AL2}									
	ABC	AT	BT	CT	AB	AC	BC	ABT	ACT	BCT
1,5	1,279	0,727	0,894	0,667	0,408	0,762	0,376	0,516	0,311	0,466
13	0,196	0,293	0,142	0,069	0,214	0,197	0,098	0,165	0,092	0,051

O defeito trifásico a 1,5km da subestação foi o que apresentou maior erro: 1,279km. O erro médio para os testes nesse alimentador é de 396 metros, correspondendo a 1,98% do comprimento do Alimentador 2. Novamente, um resultado satisfatório para localização de faltas.

Por fim, é realizado o treinamento da terceira RNA do Terceiro Estágio, a RNA_{AL3}. A sua finalidade é localizar defeitos no Alimentador 3. Assim como para as simulações anteriores, são testadas dez configurações distintas para cada um dos algoritmos de treinamento. A composição dos dados de entrada-saída foi apresentada na Figura 43. São 12 entradas, 1 saída, 9950 padrões de treinamento.

A partir dos resultados de treinamento obtidos apresentados na Tabela 45, Tabela 46 e Tabela 47, a rede candidata escolhida é com dez neurônios na camada escondida, treinada a partir do algoritmo de Regularização Bayesiana. Os valores dos Coeficiente de Correlação ficaram mais próximos de 1 para essa rede. A Tabela 48 sintetiza as configurações da topologia escolhida para a RNA_{AL3} e a Figura 62 apresenta a evolução dos erros ao longo do processo de treinamento.

A fim de testar a topologia escolhida, são simulados dois defeitos ao longo do Alimentador 3. A Figura 63 ilustra a localização desses defeitos e a Tabela 49 os resultados obtidos por esses testes. Novamente, as correntes para os testes estão dispostas em dois instantes de amostragem consecutivo, no instante que ocorre o defeito ($t=1s$) e no instante seguinte ($t=1,005s$).

Tabela 45: Coeficientes de correlação da RNA_{AL3} com algoritmo Regularização Bayesiana para o Cenário 1

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL3}			
	Treinamento	Validação	Teste	Total
1	0,93389	0,93302	0,93375	0,93365
2	0,97172	0,97222	0,97229	0,97191
3	0,99403	0,99531	0,99436	0,99435
4	0,96444	0,95931	0,95226	0,96082
5	0,99615	0,9961	0,99619	0,99613
6	0,9986	0,99786	0,99671	0,99804
7	0,99906	0,99858	0,99805	0,99874
8	0,99993	0,99988	0,99964	0,99985
9	0,99996	0,99987	0,99952	0,99985
10	0,99999	0,99997	0,99991	0,99997

Tabela 46: Coeficientes de correlação da RNA_{AL3} com algoritmo Levenberg-Marquardt para o Cenário 1

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL3}			
	Treinamento	Validação	Teste	Total
1	0,9339	0,93297	0,93375	0,93364
2	0,96707	0,96575	0,96547	0,96644
3	0,97551	0,96838	0,97173	0,9731
4	0,99533	0,99471	0,99401	0,9949
5	0,99827	0,99792	0,99779	0,99807
6	0,99675	0,99531	0,991	0,99521
7	0,99893	0,99778	0,98748	0,9962
8	0,9988	0,99872	0,9983	0,99867
9	0,99989	0,99966	0,99871	0,99958
10	0,99998	0,99994	0,99977	0,99993

Tabela 47: Coeficientes de correlação da RNA_{AL3} com algoritmo Gradiente Conjugado Escalonado para o Cenário 1

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL3}			
	Treinamento	Validação	Teste	Total
1	0,9338	0,93314	0,93366	0,93362
2	0,96187	0,95939	0,96056	0,96109
3	0,97725	0,9785	0,97763	0,97757
4	0,99723	0,99716	0,99655	0,99706
5	0,99769	0,99771	0,99762	0,99768
6	0,99913	0,99917	0,99909	0,99913
7	0,99979	0,99976	0,99967	0,99976
8	0,9992	0,99985	0,9997	0,99984
9	0,99909	0,99892	0,99882	0,99899
10	0,99968	0,99966	0,99959	0,99965

Tabela 48: Topologia escolhida da RNA_{AL3} para o Cenário 1

Nº de Neurônios da Camada Escondida	Método de Treinamento	Número de entradas	Número de saídas	Número de padrões
10	BR	12	1	9950




Figura 62: Evolução dos erros no treinamento da RNA_{AL3} para Cenário 1




Figura 63: Pontos de defeito para teste da RNA_{AL3} para Cenário 1

Tabela 49: Resultados dos testes da RNA_{AL3} para outros pontos de defeito no Cenário 1

Pto. da falta (km)	Erro (km) – Valor em módulo – RNA _{AL3}									
	ABC	AT	BT	CT	AB	AC	BC	ABT	ACT	BCT
0,5	0,416	0,183	0,063	0,083	0,022	0,019	0,170	0,132	0,035	0,200
11	0,138	0,100	0,025	0,005	0,260	0,049	0,142	0,205	0,001	0,109

O maior erro apresentado ocorreu para defeito trifásico a 0,5km da subestação. O erro médio obtido é de 0,118km, o que corresponde a 0,59% do total do AL3. Resultado satisfatório e o melhor encontrado até aqui para as redes neurais do Terceiro Estágio no Cenário 1.

6.4.2 Cenário 2

O Cenário 2 consiste na presença de duas GDs na rede de distribuição, uma PCH e uma CGH. A primeira está localizada no Alimentador 1 (Barra 4), enquanto que a segunda está no Alimentador 3 (Barra 12). A Figura 64 ilustra o diagrama unifilar do sistema com as duas GDs.

Para as RNAs, a diferença com relação ao Cenário 1 é apenas no número de entradas utilizadas. A quantidade de padrões permanece a mesma. A Tabela 50 compara o número de entradas de cada Cenário. Observa-se um aumento, visto que, com a inserção

de mais um gerador distribuído no sistema, são criadas mais seis entradas: Fase A, Fase B e Fase C dos módulos das correntes da GD2, nos instantes t e $t + a$.

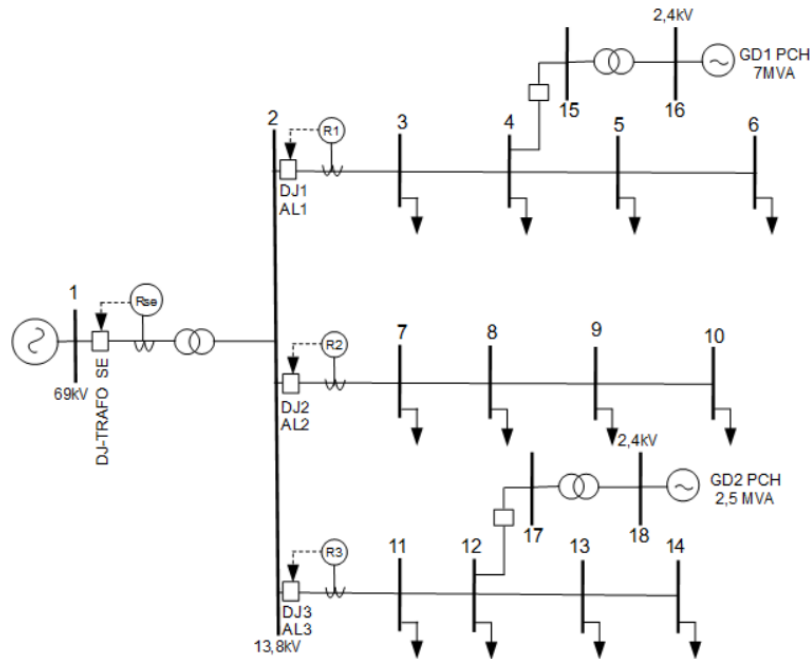


Figura 64: Diagrama Unifilar do Cenário 2

Tabela 50: Comparação do nº de entradas das RNAs para os Cenários estudados

Estágio da RNA	Número de Entradas	
	Cenário 1	Cenário 2
Primeiro Estágio	12	18
Segundo Estágio	30	36
Terceiro Estágio	12	18

6.4.2.1 Primeiro Estágio da RNA

As eficácias do treinamento da rede neural do Primeiro Estágio são obtidas utilizando os algoritmos de treinamento Regularização Bayesiana, Levenberg-Marquardt e Gradiente Conjugado Escalonado, respectivamente. O treinamento conta com 3980 padrões, 18 entradas e 2 saídas.

Com 100% de eficácia obtido nas Matrizes de Confusão para todas as topologias treinadas e para todos os conjuntos de treinamento (treinamento, validação e teste), a rede

escolhida conta com 1 neurônio da camada escondida, treinada a partir do algoritmo Regularização Bayesiana. A Tabela 51 resume as características dessa rede. A Figura 65 apresenta a evolução dos erros durante o treinamento dessa rede, assim como a Figura 66 ilustra as Matrizes de Confusão.

Tabela 51: Topologia escolhida do Primeiro Estágio da RNA para o Cenário 2

Nº de Neurônios da Camada Escondida	Método de Treinamento	Número de entradas	Número de saídas	Número de padrões
1	BR	18	2	3980




Figura 65: Evolução dos erros no treinamento do 1º Estágio da RNA para Cenário 2

O próximo passo consiste na verificação da eficácia da rede neural escolhida. O teste da rede neural para detecção de defeito foi aplicado para outras cinco barras do sistema: 3, 8, 10, 11 e 14. O objetivo é verificar a capacidade da RNA de detectar defeitos para pontos os quais a rede não foi treinada, assim como para o Cenário 1. A Tabela 52 apresenta os resultados obtidos. As entradas de teste das RNAs correspondem a dois instantes consecutivos de simulação para cada um dos módulos das correntes de fase de entrada do sistema ($t=0,995s$ e $t=1s$).

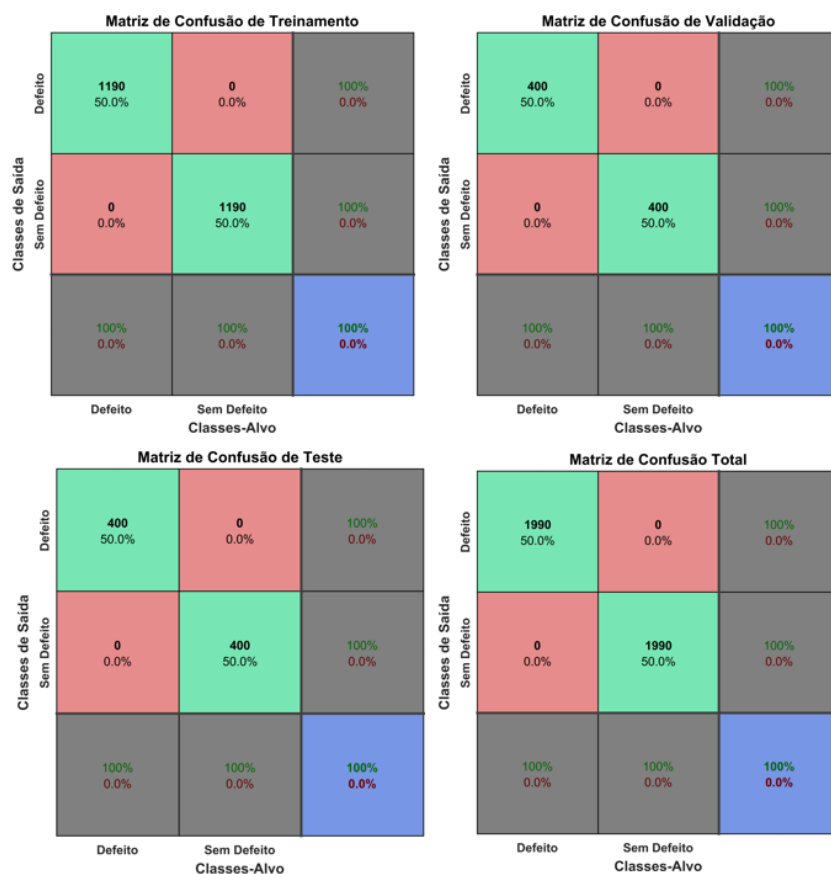


Figura 66: Matriz confusão do Primeiro Estágio da RNA para o Cenário 2

Tabela 52: Resultados dos testes do 1º Estágio da RNA para outros pontos de defeito no Cenário 2

Barra de defeito	Saída da RNA									
	Trifásico	Monofásico-Terra			Bifásico			Bifásico-Terra		
	ABC	AT	BT	CT	AB	AC	BC	ABT	ACT	BCT
3	10	10	10	10	10	10	10	10	10	10
8	10	10	10	10	10	10	10	10	10	10
10	10	10	10	10	10	10	10	10	10	10
11	10	10	10	10	10	10	10	10	10	10
14	10	10	10	10	10	10	10	10	10	10

A saída 10 para todos os tipos de defeito indica que a RNA teve 100% de eficácia na detecção do defeito. Dessa forma, a mesma é apta para indicar que o sistema está defeituoso para amostras fora de seu conjunto de treinamento.

6.4.2.2 Segundo Estágio da RNA

A Tabela 53, a Tabela 54 e a Tabela 55 apresentam as eficácias de treinamento do 2º Estágio da RNA. Essa rede é responsável por identificar o alimentador defeituoso.

Tabela 53: Eficácias do 2º Estágio da RNA com algoritmo Regularização Bayesiana para o Cenário 2

Número de neurônios	Eficácia (%) – 2º Estágio			
	Treinamento	Validação	Teste	Total
1	66,7	66,7	66,7	66,7
2	100	100	100	100
3	100	100	100	100
4	100	100	100	100
5	100	100	100	100
6	100	100	100	100
7	100	100	100	100
8	100	100	100	100
9	100	100	100	100
10	100	100	100	100

Tabela 54: Eficácias do 2º Estágio da RNA com Levenberg-Marquardt para o Cenário 2

Número de neurônios	Eficácia (%) – 2º Estágio			
	Treinamento	Validação	Teste	Total
1	66,7	66,7	66,7	66,7
2	100	100	100	100
3	100	100	100	100
4	100	100	100	100
5	100	100	100	100
6	100	100	100	100
7	100	100	100	100
8	100	100	100	100
9	100	100	100	100
10	100	100	100	100

Tabela 55: Eficácias do 2º Estágio da RNA com algoritmo Gradiente Conjugado Escalonado para o Cenário 2

Número de neurônios	Eficácia (%) – 2º Estágio			
	Treinamento	Validação	Teste	Total
1	66,7	66,7	66,7	66,7
2	100	100	100	100
3	100	100	100	100
4	100	100	100	100
5	100	100	100	100
6	100	100	100	100
7	100	100	100	100
8	100	100	100	100
9	100	100	100	100
10	100	100	100	100

Após o treinamento, a Tabela 56 apresenta a topologia escolhida. Com exceção das configurações com 1 neurônio na camada escondida, todas as outras tiveram 100% de eficácia para todos os conjuntos de treinamento. A Figura 67 e a Figura 68 apresentam a evolução dos erros e as Matrizes de Confusão para a topologia escolhida.

Tabela 56: Topologia escolhida do Segundo Estágio da RNA para o Cenário 2

Nº de Neurônios da Camada Escondida	Método de Treinamento	Número de entradas	Número de saídas	Número de padrões
2	BR	36	3	5970

A seguir, a rede é treinada para outros três pontos de defeito na rede. A disposição dos dados de corrente para teste é similar ao Cenário 1. Os resultados podem ser encontrados na Tabela 57. É possível observar que a rede foi capaz de identificar corretamente o alimentador onde está presente o defeito para todas as simulações realizadas.




Figura 67: Evolução dos erros no treinamento do 2º Estágio da RNA para Cenário 2




Figura 68: Matriz confusão do Segundo Estágio da RNA para o Cenário 2

Tabela 57: Resultados dos testes do 2º Estágio da RNA para outros pontos de defeito no Cenário 2

Barra de defeito	Saída da RNA – 2º Estágio									
	Trifásico	Monofásico-Terra			Bifásico			Bifásico-Terra		
	ABC	AT	BT	CT	AB	AC	BC	ABT	ACT	BCT
3	001	001	001	001	001	001	001	001	001	001
8	010	010	010	010	010	010	010	010	010	010
11	100	100	100	100	100	100	100	100	100	100

6.4.2.3 Terceiro Estágio da RNA

O Terceiro Estágio da RNA também consiste em um treinamento *offline*, para dez topologias candidatas para cada uma das funções de treinamento utilizadas. A Tabela 58, a Tabela 59 e a Tabela 60 apresentam os coeficientes de correlação obtidos no treinamento da rede para cada um dos algoritmos de treinamento.

Tabela 58: Coeficientes de correlação da RNA_{AL1} com algoritmo Regularização Bayesiana para o Cenário 2

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL1}			
	Treinamento	Validação	Teste	Total
1	0,9593	0,96267	0,96415	0,96053
2	0,97874	0,98139	0,98138	0,97941
3	0,99382	0,99005	0,97997	0,99
4	0,9949	0,99139	0,98224	0,99157
5	0,99664	0,99298	0,98375	0,99328
6	0,99858	0,99616	0,99516	0,99737
7	0,99888	0,99729	0,99163	0,99704
8	0,99894	0,99684	0,98934	0,99656
9	0,99938	0,99712	0,99105	0,99721
10	0,99997	0,99864	0,99258	0,99821

Tabela 59: Coeficientes de correlação da RNA_{AL1} com algoritmo Levenberg-Marquardt para o Cenário 2

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL1}			
	Treinamento	Validação	Teste	Total
1	0,95928	0,9627	0,96417	0,96053
2	0,98188	0,98262	0,98183	0,98166
3	0,95274	0,94979	0,94357	0,94995
4	0,99422	0,99301	0,98964	0,99304
5	0,99746	0,99642	0,99445	0,99661
6	0,9989	0,99731	0,9944	0,99758
7	0,99787	0,99713	0,9917	0,99632
8	0,99932	0,997	0,99101	0,99713
9	0,99564	0,99566	0,99348	0,99521
10	0,9996	0,99776	0,98874	0,99701

Tabela 60: Coeficientes de correlação da RNA_{AL1} com algoritmo Gradiente Conjugado Escalonado para o Cenário 2

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL1}			
	Treinamento	Validação	Teste	Total
1	0,95899	0,96239	0,96369	0,96023
2	0,97822	0,9822	0,9785	0,97895
3	0,99536	0,99528	0,99504	0,99526
4	0,99583	0,99546	0,99273	0,99509
5	0,99613	0,99591	0,99358	0,99542
6	0,99712	0,9958	0,98888	0,99493
7	0,99644	0,99594	0,99315	0,99564
8	0,99694	0,99535	0,99206	0,99554
9	0,9974	0,99649	0,99405	0,99639
10	0,99829	0,99761	0,9956	0,99754

Detalhes da rede escolhida são apresentados na Tabela 61. A Figura 69 apresenta a evolução dos erros durante o treinamento.

Tabela 61: Topologia escolhida da RNA_{AL1} para o Cenário 2

Nº de Neurônios da Camada Escondida	Método de Treinamento	Número de entradas	Número de saídas	Número de padrões
10	BR	18	1	9950




Figura 69: Evolução dos erros no treinamento da RNA_{AL1} para Cenário 2

O passo seguinte consiste em testar a rede para outros dois pontos no Alimentador 1, assim como foi realizado para o Cenário 1. A Tabela 62 apresenta os resultados obtidos.

Tabela 62: Resultados dos testes da RNA_{AL1} para outros pontos de defeito no Cenário 2

Pto. da falta (km)	Erro (km) – Valor em módulo – RNA _{AL1}									
	ABC	AT	BT	CT	AB	AC	BC	ABT	ACT	BCT
4	1,310	1,102	2,185	0,988	0,274	0,100	0,116	0,184	0,036	0,428
18	0,007	0,057	0,370	0,209	0,008	0,278	0,509	0,079	0,092	0,265

Os padrões de testes são dispostos da mesma forma como realizado para Cenário 1, para os dois instantes consecutivos: o instante de defeito ($t = 1s$) e o seguinte ($t = 1,005s$). Observa-se que o maior erro encontrado se deu para defeito monofásico na Fase B do Alimentador 1 no valor de 2,185km. O erro médio é satisfatório no valor de 0,430km, 2,15% do tamanho total do AL1.

Os mesmos procedimentos são realizados para a rede neural RNA_{AL2} , responsável pela localização de defeitos no Alimentador 2. A Tabela 63, Tabela 64 e Tabela 65 apresentam os coeficientes de correlação obtidos no treinamento da rede.

Novamente, o melhor desempenho observado ocorreu para a configuração com 10 neurônios na camada escondida, utilizando a função de treinamento da Regularização Bayesiana. Os detalhes da topologia escolhida são detalhados na Tabela 66, assim como a evolução dos erros durante o treinamento é apresentada na Figura 70.

Tabela 63: Coeficientes de correlação da RNA_{AL2} com algoritmo Regularização Bayesiana para o Cenário 2

Número de neurônios	Coeficiente de Correlação (R)			
	RNA_{AL2}			
	Treinamento	Validação	Teste	Total
1	0,92669	0,92516	0,92579	0,92604
2	0,9282	0,92543	0,92641	0,9269
3	0,98399	0,98262	0,97513	0,98114
4	0,99108	0,9876	0,98987	0,99005
5	0,99648	0,99544	0,98818	0,9945
6	0,99947	0,99856	0,99623	0,99846
7	0,99988	0,99975	0,99924	0,9997
8	0,99986	0,99963	0,999	0,99963
9	0,99969	0,99913	0,99421	0,99842
10	1	0,99978	0,99933	0,99982

A RNA foi testada para dois pontos de defeito, os quais não fizeram parte de seu treinamento. Os resultados são apresentados na Tabela 67.

Tabela 64: Coeficientes de correlação da RNA_{AL2} com algoritmo Levenberg-Marquardt para o Cenário 2

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL2}			
	Treinamento	Validação	Teste	Total
1	0,92623	0,92517	0,9255	0,92571
2	0,95977	0,95723	0,95725	0,95863
3	0,99086	0,98712	0,97627	0,9871
4	0,9957	0,99476	0,98953	0,99411
5	0,98688	0,97889	0,9698	0,98167
6	0,99934	0,99711	0,99112	0,99702
7	0,99595	0,99068	0,98089	0,99182
8	0,99978	0,99893	0,99533	0,99868
9	0,99994	0,99945	0,99802	0,99945
10	0,99924	0,99837	0,99056	0,99697

Tabela 65: Coeficientes de correlação da RNA_{AL2} com algoritmo Gradiente Conjugado Escalonado para o Cenário 2

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL2}			
	Treinamento	Validação	Teste	Total
1	0,92678	0,92555	0,92613	0,92628
2	0,97951	0,96769	0,96122	0,97257
3	0,99147	0,9915	0,99036	0,99124
4	0,9951	0,98856	0,9804	0,99076
5	0,99577	0,99586	0,99482	0,99559
6	0,99908	0,99867	0,99833	0,99882
7	0,99964	0,99931	0,9976	0,9991
8	0,99933	0,99863	0,9963	0,99856
9	0,99979	0,99973	0,99932	0,99965
10	0,99992	0,99982	0,9994	0,99978

Tabela 66: Topologia escolhida da RNA_{AL2} para o Cenário 2

Nº de Neurônios da Camada Escondida	Método de Treinamento	Número de entradas	Número de saídas	Número de padrões
10	BR	18	1	9950




Figura 70: Evolução dos erros no treinamento da RNA_{AL2} para Cenário 2

Tabela 67: Resultados dos testes da RNA_{AL2} para outros pontos de defeito no Cenário 2

Pto. da falta (km)	Erro (km) – Valor em módulo – RNA _{AL2}									
	ABC	AT	BT	CT	AB	AC	BC	ABT	ACT	BCT
1,5	0,686	0,343	0,733	0,656	0,019	1,214	0,699	0,165	0,699	0,646
13	0,138	0,140	0,132	0,157	0,221	0,181	0,140	0,209	0,158	0,077

Os padrões de teste são organizados de forma similar ao Cenário 1. Verifica-se que o maior erro encontrado se deu para defeito bifásico Fases A-C, para ponto de defeito a 1,5 km da subestação. O erro médio encontrado para todos os defeitos é de 0,371 km, equivalente a 2,47 % de comprimento do Alimentador 2. Novamente, o erro é considerado satisfatório para a aplicação proposta.

Por fim, é aplicada a mesma metodologia para a terceira RNA do Terceiro Estágio, aquela responsável pela localização de defeitos no Alimentador 3. A Tabela 68, a Tabela 69 e a Tabela 70 apresentam os coeficientes de correlação obtidos durante o treinamento.

A melhor configuração se deu para dez neurônios da camada escondida. Observa-se que para todos os casos simulados, em todas os cenários, o melhor desempenho se deu à rede treinada pelo algoritmo da Regularização Bayesiana. A Tabela 71 apresenta os detalhes da rede escolhida e a Figura 71 mostra a evolução dos erros durante o treinamento.

Seguindo o procedimento já adotado, a RNA é testada para outros dois pontos de defeito e os resultados são apresentados na Tabela 72. O defeito na Fase A do Alimentador 3 apresentou maior erro de localização, no valor de 0,417km. O valor médio do erro para RNA_{AL3} é de 0,206km, correspondente a 1,58% do comprimento do Alimentador 3. Novamente, a rede foi capaz de localizar os defeitos de forma satisfatória.

Tabela 68: Coeficientes de correlação da RNA_{AL3} com algoritmo de Regularização Bayesiana para o Cenário 2

Número de neurônios	Coeficiente de Correlação (R)			
	RNA_{AL3}			
	Treinamento	Validação	Teste	Total
1	0,9444	0,9436	0,94759	0,94478
2	0,9689	0,9671	0,96636	0,96784
3	0,99477	0,99379	0,99058	0,99366
4	0,99606	0,99261	0,97844	0,99154
5	0,99766	0,99446	0,98837	0,99504
6	0,99964	0,998	0,99462	0,99828
7	0,99979	0,99798	0,99168	0,9976
8	0,99996	0,99923	0,99593	0,99897
9	0,99998	0,99961	0,99628	0,99906
10	0,99999	0,99983	0,99839	0,99964

Tabela 69: Coeficientes de correlação da RNA_{AL3} com algoritmo Levenberg-Marquardt para o Cenário 2

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL3}			
	Treinamento	Validação	Teste	Total
1	0,94459	0,94353	0,94876	0,94511
2	0,97031	0,96922	0,96835	0,96957
3	0,98727	0,98017	0,97557	0,98239
4	0,99751	0,99264	0,98022	0,99298
5	0,99934	0,99716	0,99375	0,99777
6	0,99758	0,99264	0,98198	0,99334
7	0,99756	0,99444	0,98627	0,99444
8	0,99933	0,99749	0,99107	0,99715
9	0,99044	0,97434	0,95875	0,98042
10	0,99997	0,99906	0,98044	0,99557

Tabela 70: Coeficientes de correlação da RNA_{AL3} com algoritmo Gradiente Conjugado Escalonado para o Cenário 2

Número de neurônios	Coeficiente de Correlação (R)			
	RNA _{AL3}			
	Treinamento	Validação	Teste	Total
1	0,94407	0,94385	0,94695	0,94454
2	0,97144	0,9707	0,96655	0,97019
3	0,99136	0,99117	0,98818	0,99068
4	0,99812	0,9969	0,99561	0,99735
5	0,99867	0,99764	0,99511	0,99774
6	0,99419	0,99406	0,9888	0,99295
7	0,99937	0,99814	0,99451	0,99799
8	0,99979	0,99859	0,99565	0,99865
9	0,99951	0,99862	0,99649	0,99866
10	0,99899	0,99844	0,99699	0,99834

Tabela 71: Topologia escolhida da RNA_{AL3} para o Cenário 2

Nº de Neurônios da Camada Escondida	Método de Treinamento	Número de entradas	Número de saídas	Número de padrões
10	BR	18	1	9950




Figura 71: Evolução dos erros no treinamento da RNA_{AL3} para Cenário 2

Tabela 72: Resultados dos testes da RNA_{AL3} para outros pontos de defeito no Cenário 2

Pto. da falta (km)	Erro (km) – Valor em módulo – RNA _{AL3}									
	ABC	AT	BT	CT	AB	AC	BC	ABT	ACT	BCT
0,5	0,048	0,417	0,258	0,055	0,044	0,348	0,071	0,139	0,058	0,112
11	0,304	0,314	0,310	0,097	0,312	0,202	0,247	0,350	0,317	0,111

6.4.3 Comparação dos Cenários

O Primeiro e Segundo Estágios atuam satisfatoriamente como classificadores, tanto para Cenário 1 como para o Cenário 2. São capazes de indicar ou não a presença de defeito na rede e revelar em qual alimentador está o defeito, respectivamente.

Já as três redes neurais que compõem o Terceiro Estágio atuam como aproximadores. Foram observados diferentes erros médios para cada Cenário e cada Alimentador. A Tabela 73 compara os resultados obtidos.

Tabela 73: Comparação dos erros médios dos Cenários 1 e 2

Cenário	Erro Médio (%)		
	RNA _{AL1}	RNA _{AL2}	RNA _{AL3}
1	2,70	2,64	0,90
2	2,15	2,47	1,58

Os cenários com uma ou duas GDs apresentam erros médios satisfatórios. O menor erro encontrado foi para o Cenário 1, na RNA destinada a localizar defeitos no Alimentador 3.

CAPÍTULO 7

CONCLUSÕES

Este trabalho teve como objetivo desenvolver um esquema de proteção para redes de distribuição ativas de energia através do uso das redes neurais artificiais. A inserção cada vez mais comum de geradores distribuídos no sistema traz benefícios e malefícios à rede, especialmente ao sistema de proteção.

O uso de geradores distribuídos surgiu como uma solução para se depender cada vez menos das grandes centrais geradoras de energia, localizadas longe dos centros urbanos. Uma energia limpa que representa uma redução do impacto ambiental. Entretanto, a sua inserção pode tornar mais complexa a forma de operar e proteger a rede de distribuição e os próprios consumidores finais.

Inicialmente, foram apresentados os principais impactos das GDs em sistemas de distribuição, dando-se um enfoque ao seu efeito no sistema de proteção. Dependendo do tipo, tamanho e localização da GD, a sua influência pode ser maior.

A seguir, foram apresentados conceitos da proteção tradicional de redes de distribuição de energia e as alternativas existentes para proteger o sistema na presença de GDs. Não existe um método único de solução do problema. Pode-se adotar novas filosofias de proteção do sistema bem como ajustar a proteção existente para atender ao novo cenário operativo.

O uso da proteção adaptativa, alterando os ajustes da proteção em tempo real, surge como uma possibilidade para tratar o problema. Também são utilizados grupos de ajustes pré-determinados através de estudos *offlines*. Pode-se buscar também a inserção

de novos equipamentos na rede, como disjuntores, ou a inclusão de novas funções nos relés de proteção dos alimentadores, como a diferencial ou distância.

Tais soluções podem apresentar fatores limitantes para a sua aplicabilidade, como a necessidade de altos investimentos em tecnologias avançadas para transmissão de dados. É sob esse aspecto que se mostra interessante o emprego de técnicas de inteligência artificial, em especial o uso das redes neurais artificiais. A solução proposta buscou aproveitar ao máximo a tecnologia disponível na maioria das redes de distribuição, utilizando a medição dos módulos das correntes.

Entretanto, a aplicabilidade do método proposto baseado no uso das RNAs também depende de uma série de fatores, como canais de comunicação e taxa de amostragem disponível pelos equipamentos de medição. O esquema necessita de uma comunicação em tempo real entre as GDs e subestação do sistema. O tempo total de atuação das RNAs é determinado de acordo com a taxa de amostragem utilizada, tempo de comunicação e tempo de processamento dos dados.

Além disso, a metodologia estudada é destinada para uma configuração específica da rede, com a modelagem do esquema de proteção composto apenas por relés de sobrecorrente e disjuntores associados. Caso novos dispositivos sejam inseridos, como religadores ou fusíveis, ou mesmo novas GDs sejam conectadas a rede, são necessários novos treinamentos das RNAs para encontrar a melhor topologia para cada nova configuração.

Neste trabalho, o estudo de caso foi caracterizado pela inserção de GDs do tipo PCH em uma rede de distribuição rural típica. Tal cenário tem se tornado comum no Brasil assim como no Estado do Rio de Janeiro. Foram ilustrados os impactos no tempo de atuação dos relés de sobrecorrente que protegem os alimentadores.

A metodologia de solução proposta para esse problema se mostrou satisfatória. O emprego das RNAs *feedforward* do tipo *Perceptron* Multicamadas permitiu que os defeitos fossem detectados e localizados. Além disso, a utilização das RNAs em três estágios distintos e consecutivos permitiu transformar um problema complexo de localização de falta em três mais simples, tornando apto de ser solucionado.

Observa-se também que a metodologia proposta se destina a redes de distribuição na presença de geradores distribuídos de natureza síncrona, com sua ligação à rede sem o uso de inversores eletrônicos. Desse modo, utilizou-se as correntes de contribuição das fontes para cada defeito como solução do problema.

7.1 Trabalhos Futuros

Como sugestão para trabalhos futuros, indica-se a reprodução da metodologia aqui desenvolvida para sistemas de maior porte. Um sistema com a presença de maior número de GDs pode implicar numa maior dificuldade na localização de defeitos. Propõem-se também explorar as características do tipo de ligação do transformador de interconexão da GD com o sistema. Dependendo da ligação utilizada, pode-se implicar na falha da proteção por parte da concessionária de distribuição.

Outro aspecto que seria interessante é a comparação do método de localização de faltas proposto através de RNAs com relação a outros métodos tradicionais já existentes na literatura, como ondas viajantes ou uso de relés de distância. É fato também que as redes de distribuição implicam em uma dificuldade de aplicação desses métodos por suas características básicas, como a inserção das próprias GDs e a presença de cabos de diferentes bitolas ao longo dos alimentadores. Devido a isso, as RNAs se mostram como uma ótima alternativa para a localização das faltas.

Com relação às topologias e características das RNAs, outros conceitos podem ser explorados. Assim como o uso das redes *Perceptron* Multicamadas, tem-se difundido o emprego das redes de base radial – RBF. Como já mencionado no texto, muitas das aplicações resolvidas através de redes PMC podem também ser solucionadas pelas redes RBF.

Outra sugestão é a comparação do método desenvolvido para diferentes taxas de amostragem, comparando os tipos de comunicação de dados existentes em redes de distribuição. Dessa forma, pode-se observar qual a mínima taxa é necessária para que a RNA atue em um tempo satisfatório.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] JENKINS, N., EKANAYAKE J.B., STRBAC, G., *Distributed Generation*. The Institution of Engineering and Technology, Londres, Reino Unido, 2010.
- [2] TRINDADE, F. C. L., 2013, *Desenvolvimento de Metodologias para Localização de Defeitos em Sistemas de Distribuição com Medidores Inteligentes*. Tese de D.Sc., Unicamp, Campinas, SP, Brasil.
- [3] JAVADIAN, S. A. M., NASRABADI, A. M., HAGHIFAM, M. -R., REZVANTALAB, J., “Determining Fault’s Type and Accurate Location in Distribution Systems with DG using MLP Neural Networks”, *2009 International Conference on Clean Electrical Power*, Capri, Itália, 9-11, Jun 2009.
- [4] LIAN, G., LIYUAN, P., RUIHUAN, L., FEN, Z., XIN, W., “Fault Location in Distribution Network with Distributed Generation Based on Neural Network”, *2014 China International Conference on Electricity Distribution (CICED)*, Shenzhen, China, 23-26, Set. 2014.
- [5] BRAHMA, S., GIRGIS, A., “Development of Adaptive Protection Scheme for Distribution Systems with High Penetration of Distributed Generation”, *IEE Transaction Power Delivery*, v. 19, n. 1, pp. 56-63, Jan. 2004.
- [6] REZAEI, N., HAGHIFAM, M.-R., “Protection Scheme for a Distribution System with Distributed Generation Using Neural Networks”, *International Journal of Electrical Power & Energy Systems*, v. 30, pp. 235-241, Mai. 2008.
- [7] ZAYANDEHROODI, H., MOHAMED A., SHAREEF, H., MOHAMMADJAFARI, M., “An Automated Protection Method for Distribution Networks with Distributed Generations Using Radial Basis Function Neural Network”, *The 5th International Power Engineering and Optimization Conference*, Shah Alam, Malásia, 6-7, Jun. 2011.
- [8] SUNG, B.C., LEE, S.H., PARK, J.-W., MELIOPOULOS, A.P.S, “Adaptive Protection Algorithm for Overcurrent Relaying Distribution System with DG”,

- Journal of Electrical Systems and Information Technology*, v. 8, n. 5, pp. 1002-1011, Mai. 2013.
- [9] ANANDA, S.A., GU J., “Multi-Agent Based Protection on Highly Dominated Distributed Energy Resources”, *Energy and Power Engineering*, v. 5, n. 4B, pp. 927-931, Jul. 2013.
- [10] KUMAR, D. S., RADHAKRISHNAN, B. M., SRINIVASAN, D., REINDL, T., “An Adaptive Fuzzy based Relay for Protection of Distribution Networks”, *2015 IEEE International Conference on Fuzzy Systems*, Istanbul, Turquia, 2-5, Ago. 2015.
- [11] CHAKOR, S. V., DATE, T. N., “Optimum Coordination of Directional Overcurrent Relay in Presence of Distributed Generation Using Genetic Algorithm”, *10th International Conference on Intelligent Systems and Control*, Coimbatore, Índia, 7-8, Jan. 2016.
- [12] NIKOLAIDIS, V., ARSENOPOULOS, C., SAFIGIANNI, A.; VOURNAS, C. D., “A distance based protection scheme for distribution systems with distributed generators”, *IEEE Power Systems Computation Conference (PSCC)*, pp. 1-7, 2016.
- [13] PETITE, F. S. V., DOS SANTOS, R. C., ASANO, P. T., “A Scheme Based on ANNs for Single-Phase Fault Location in Distribution Systems with DG”, *2017 IEEE Manchester PowerTech*, Manchester, Reino Unido, Jul. 2017.
- [14] JENKINS, N., ALLAN, R., CROSSLEY, P., KIRSCHEN, D., STRBAC, G., *Embedded Generation*. The Institution of Engineering and Technology, Londres, Reino Unido, 2008.
- [15] FERREIRA, A. P. F, RÊGO, L. O., TARANTO, G. N., ASSIS, T. M. L., FALCÃO, D. M., “Technical Losses Assessment in Medium Voltage Feeders in the Presence of Distributed Generation”, *2018 IEEE PES Transmission & Distribution Conference and Exhibition – Latin America (T&D-LA)*, Lima, Peru, 18-21, Set. 2018.

- [16] BRAGA JUNIOR, M. F., 2017, *Impacto da Geração Distribuída na Proteção de Sistema de Distribuição*, Dissertação de M. Sc., UNIFEI, Itajubá, MG, Brasil.
- [17] MAMEDE FILHO, J., MAMEDE, D.R, *Proteção de Sistemas Elétricos de Potência*, LTC, Rio de Janeiro, Brasil, 2016.
- [18] CARVALHO, R. C., 2015, *Uma Metodologia para Análise Expedida da Máxima Injeção de Potência Ativa por Gerador Distribuído*, Tese de D.Sc.. COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- [19] TARANTO, G. N., ASSIS, T. M. L., FALCÃO, D. M., “Highlighting the Importance of Chronology on Voltage Protection and Control in Active Distribution Networks”, *IEEE Transactions on Power Delivery*, v. 32, pp. 361-369, Fev. 2017.
- [20] ANEEL – Agência Nacional de Energia Elétrica, Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST – Módulo 8 – Qualidade de Energia Elétrica, 2017.
- [21] BACELAR, M. N., ASSIS, T. M. L., TARANTO, G. N., “Performance Evaluation of Microgrids in Occurrence of Intentional Islanding”, *2013 IEEE PES Conference on Innovative Smart Grid Technologies (ISGT Latin America)*, São Paulo, Brasil, 15-17, Abr. 2013.
- [22] IEEE – Institute of Electrical and Electronic Engineers, Std. 1547.2-2008, *IEEE Standard for Interconnecting Distributed Resources with Electric Power Systems*, Abr. 2008.
- [23] VIEIRA JR, J. C. M. “Detecção de Ilhamento de Geradores Distribuídos: Uma Revisão Bibliográfica sobre o Tema”, *Revista Eletrônica de Energia - UNIFACTS*, v.1, n.1, p. 3-14, Jul./Dez. 2011.
- [24] TAVARES, T. N., 2003, *Avaliação do Impacto Causado na Proteção pela Interligação de Produtores Independentes no Sistema de Distribuição*, Dissertação de M. Sc., UFSC, Florianópolis, SC, Brasil.

- [25] LUIZ, C. M., 2012, *Avaliação dos Impactos da Geração Distribuída para Proteção do Sistema Elétrico*, Dissertação de M. Sc., UFMG, Belo Horizonte, MG, 2012.
- [26] KINDERMANN, G., *Proteção de Sistemas Elétricos de Potência*. Ed. do Autor, Florianópolis, Brasil, 1999.
- [27] ANDERSON, P. M., *Power System Protection*. IEEE Press, Nova Iorque, 1999.
- [28] IEEE – Institute of Electrical and Electronic Engineers, Std. C37.112-1996, *IEEE Standard Inverse-Time Characteristic Equations for Overcurrent Relays*, Set. 1996.
- [29] SALLES, N. J. De, 2007, *Modelagem e Análise Dinâmica de Sistemas de Proteção de Redes de Distribuição de Energia Elétrica na Presença de Geradores Síncronos*, Dissertação de M. Sc., Unicamp, Campinas, SP, Brasil.
- [30] ZHANG, C., LIU, Z., HUANG, J., WANG, B., WANG, X., “Fault Location in Active Distribution Network Based on the Change of Current Phase”, *2017 IEEE Conference on Energy Internet and Energy System Integration*, Pequim, China, 26-28, Nov. 2017.
- [31] BITTENCOURT, A. A., 2011, *Proteção Adaptativa de Alimentadores de Distribuição de Energia Elétrica considerando Geração Distribuída*, Dissertação de M. Sc., UFSC, Florianópolis, SC, Brasil.
- [32] ANEEL – Agência Nacional de Energia Elétrica, *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST – Módulo 3 – Acesso ao Sistema de Distribuição*, 2016.
- [33] LIGHT – IT DTE/DTP, *Procedimentos para a Conexão de Microgeração e Minigeração ao Sistema de Distribuição da Light SESA BT e MT – Até Classe 36,2kV – Rev. 4*, 2018.
- [34] KUMPULAINEN, L. K., KAUHANIEMI, K. T., “Analysis of the Impact of Distributed Generation on Automatic Reclosing”, *IEEE PES Power Systems Conference and Exposition*, Nova Iorque, Estados Unidos, 10-13, Out. 2004.

- [35] WALLING, R.A., MILLER, N.W., "Distributed generation islanding – implications on power system dynamic performance". *Power Engineering Society Summer Meeting*, v. 1, pp. 92-96, 2002.
- [36] BAGHZOUZ, Y., "Voltage Regulation and Overcurrent Protection Issues in Distribution Feeders with Distributed Generation – A Case Study", *38th Hawaii Conference on System Sciences*, Havaí, Estados Unidos, 2005.
- [37] NIKOLAIDIS, V. C., ARSENOPOULOS, C., SAFIGIANNI, A.S., "A Distance Based Protection Scheme for Distribution Systems with Distributed Generators", *2016 Power Systems Computation Conference (PSCC)*, Gênova, Itália, 20-24, Jun 2016.
- [38] BACKER, P. P., DE MELLO, R. W., "Determining the Impact of Distributed Generation on Power Systems. I. Radial Distribution Systems", *2000 Power Engineering Society Summer Meeting*, Seattle, Estados Unidos, 16-20, Jul. 2000.
- [39] IEEE – Institute of Electrical and Electronic Engineers, Impact of Distributed Resources on Distribution Relay Protection, Ago. 2004.
- [40] PHADKE, A. G., THORP, J. S., *Computer Relaying for Power Systems*. 2 ed., Wiley, Inglaterra, 2009.
- [41] MAIOLA, P. C., 2014, *Arquitetura Multiagente para Coordenação de Relés de Sobrecorrente na Proteção de Sistemas Radiais na Presença de Geração Distribuída*, Dissertação de M. Sc., UFSC, Florianópolis, SC, Brasil.
- [42] NASCIMENTO, L. L., 2014, *Sistema Multiagente para Proteção Adaptativa de Microrredes*, Dissertação de M. Sc., UFSC, Florianópolis, SC, Brasil.
- [43] WOOLDRIDGE, M., JENNINGS, N. R., "Intelligent Agents: Theory and Practice", *Knowledge Engineering Review*, Cambridge Univ. Press, v.10, n.2, p. 115-152, Jan. 1995.
- [44] LINDEN, R., *Algoritmos Genéticos*. 3ª Edição, Editora Ciência Moderna Ltda, 2011.

- [45] BURIAN, R., 2019, *Algoritmos Genéticos na Alocação de Dispositivos de Proteção de Distribuição de Energia Elétrica*, Tese de D. Sc., USP, São Paulo, SP, Brasil.
- [46] CASTILLO, C., CONDE, A., “Coordination of Overcurrent Relays Using Genetic Algorithms and Unconventional Curves”, *IEEE Latin America Transaction*, v. 12, n. 8, Dez. 2014.
- [47] SILVA, R. A. C., “Inteligência Artificial Aplicada a Ambientes de Engenharia de Software: Uma Visão Geral”, *INFOCOMP (UFLA)*, Lavras, Minas Gerais, Brasil, v. 4, n.4, p. 27-37, 2005.
- [48] NAVARRO, L. F., 2014, *Redes Neurais Artificiais Aplicadas a Detecção, Classificação e Localização de Faltas em Sistemas de Distribuição de Energia Elétrica*, TCC, USP, São Carlos, SP, Brasil.
- [49] HAYKIN, S., *Neural Networks and Learning Machines*, 3 ed., Pearson, Hamilton, Canadá, 2009.
- [50] CALÔBA, L.P., “Uma Pequena Introdução às Redes Neurais Artificiais e Aplicações”, *XXXVII Simpósio Brasileiro de Pesquisa Operacional – SBPO*, Gramado, Rio Grande do Sul, Brasil, Set. 2005.
- [51] SILVA, I. N., SPATTI, D. H., FLAUZINO, R. A., *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas*, São Paulo, Brasil, Editora Artliber, 2016.
- [52] OLIVEIRA, A. R., 2005, *Redes Neurais Artificiais Aplicadas na Detecção, Classificação e Localização de Defeitos em Linhas de Transmissão*, Dissertação de M. Sc., UFJF, Juiz de Fora, MG, Brasil.
- [53] FERREIRA, V. H., 2008, *Desenvolvimento de Modelos Neurais Autônomos para Previsão de Carga Elétrica*, Tese de D. Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- [54] LEVENBERG, K., “A method for the Solution of Certain Problems in Least Squares”, *Quart. Ap. Math*, 2, pp. 164-168, 1944.

- [55] MARQUARDT, D., “An Algorithm for Least Squares Estimation of Nonlinear Parameters”, *J. Soc. Indust. Ap. Math.*, 11, pp. 431-441, 1963.
- [56] OLIVEIRA, D. S., 2016, *Classificação e Localização de Faltas em Sistemas de Transmissão com Compensação Série Utilizando Redes Neurais Artificiais*, Dissertação de M. Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- [57] MACKAY, D.J.C., 1992, *Bayesian Methods for Adaptive Models*, Tese de D. Sc., California Institute of Technology, Pasadena, Califórnia, Estados Unidos.
- [58] FERREIRA, V. H., 2005, *Técnicas de Regularização de Modelos Neurais Aplicadas à Previsão de Carga a Curto Prazo*, Dissertação de M. Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- [59] MOLLER, M. F., “A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning”, *Neural Networks*, v. 6, n. 4, pp. 525-533, 1993.
- [60] ALMEIDA, L. M., 2007, *Uma Metodologia de Busca por Redes Neurais Artificiais Quase-Ótimas*, Dissertação de M. Sc., UFPE, Recife, PE, Brasil.
- [61] COPPE/UFRJ, *Simulight – Simulador para Redes Elétricas com Geração Distribuída*, [Online, acessado em 27/01/2019]. Disponível: <http://www.coep.ufrj.br/~tarang/Simulight/>.
- [62] TARANTO, G. N., MARINHO, J. M. T., FALCÃO, D. M., ASSIS, T. M. L., ESCALANTE, S. L., RODRIGUEZ, J. I. R., PONTES, C. E. V., “Simulador de Redes de Distribuição Ativas com Modelagem Monofásica/Trifásica”, *XII Simpósio de Especialistas em Planejamento de Operação e Expansão Elétrica*, Rio de Janeiro, Brasil, 20-23, Mai. 2012.
- [63] ANEEL, *Atlas de Energia Elétrica do Brasil*. 3ª edição, Brasília, Brasil, 2008.
- [64] ANEEL – Agência Nacional de Energia Elétrica, Banco de Informações de Geração (BIG), [Online, acessado em 08/02/2019]. Disponível: <http://www2.aneel.gov.br/aplicacoes/ResumoEstadual/ResumoEstadual.cfm>.

Anexo A Código do MATLAB

Código do MATLAB para Primeiro Estágio da RNA

```
% Rede Neural Perceptron Multi-Camadas para Detecção de Falta

% Entradas e Alvos da Rede
input = x';
target = y';

% Escolher a função de treinamento
trainFcn = 'trainbr';

% Criar a rede neural de classificação
hiddenLayerSize = 1;
primeirarna = patternnet(hiddenLayerSize, trainFcn);

% Definir os parâmetros de treinamento
primeirarna.trainParam.epochs=1000000; % Número de épocas
primeirarna.trainParam.max_fail=1000000; % Número de Validation Checks

% Definir as funções de ativação
primeirarna.layers{1}.TransferFcn = 'tansig';
primeirarna.layers{2}.TransferFcn = 'tansig';

% Definir a divisão dos dados de treinamento, validação e teste
primeirarna.divideFcn='divideind';
primeirarna.divideParam.trainInd=( [1:119,200:318,399:517,598:716,797:915,996:1114,
1195:1313,1394:1512,1593:1711,1792:1910,1991:2109,2190:2308,2389:2507,2588:27
06,2787:2905,2986:3104,3185:3303,3384:3502,3583:3701,3782:3900] );
primeirarna.divideParam.valInd=( [120:159,319:358,518:557,717:756,916:955,1115:115
4,1314:1353,1513:1552,1712:1751,1911:1950,2110:2149,2309:2348,2508:2547,2707:2
746,2906:2945,3105:3144,3304:3343,3503:3542,3702:3741,3901:3940] );
primeirarna.divideParam.testInd=( [160:199,359:398,558:597,757:796,956:995,1155:11
94,1354:1393,1553:1592,1752:1791,1951:1990,2150:2189,2349:2388,2548:2587,2747:
2786,2946:2985,3145:3184,3344:3383,3543:3582,3742:3781,3941:3980] );
primeirarna.performFcn='mse';

% Treinamento da rede
[primeirarna,tr]=train(primeirarna,input,target);

% Variáveis de Treinamento da Matriz de Confusão
saidasTrn = primeirarna(input(:,tr.trainInd));
targetTrn = target(:,tr.trainInd);

% Variáveis de Validação da Matriz de Confusão
saidasVal = primeirarna(input(:,tr.valInd));
```

```

targetVal = target(:,tr.valInd);

% Variáveis de Teste da Matriz de Confusão
saidasTst = primeirarna(input(:,tr.testInd));
targetTst = target(:,tr.testInd);

% Total de Variáveis da Matriz de Confusão
saidasTotal = primeirarna(input);
targetTotal = target;

% Plotar a matriz Performance
figure(1)
plotperform(tr)
xlabel([num2str(tr.num_epochs), ' épocas'],'FontWeight','bold')
ylabel('Erro quadrático médio (mse)','FontWeight','bold')
title(['O melhor desempenho da validação é de ', num2str(tr.best_vperf), ' na época ',
num2str(tr.best_epoch)])
legend('Treinamento','Validação','Teste','Melhor')
set(gcf, 'Color', 'w');

% Plotar as matrizes de confusão
figure(2);
plotconfusion(targetTrn, saidasTrn, 'Treinamento -');
xlabel('Classes-Alvo','FontWeight','bold')
ylabel('Classes de Saída','FontWeight','bold')
title('Matriz de Confusão de Treinamento','FontWeight','bold')
set(gca,'xticklabel',{'Defeito' 'Sem Defeito' ''},'yticklabel',{'Defeito' 'Sem Defeito'
''},'FontWeight','bold')
ax=gca;
ax.YTickLabelRotation=90;
set(gcf, 'Color', 'w');

figure(3);
plotconfusion(targetVal, saidasVal);
xlabel('Classes-Alvo','FontWeight','bold')
ylabel('Classes de Saída','FontWeight','bold')
title('Matriz de Confusão de Validação','FontWeight','bold')
set(gca,'xticklabel',{'Defeito' 'Sem Defeito' ''},'yticklabel',{'Defeito' 'Sem Defeito'
''},'FontWeight','bold')
ax=gca;
ax.YTickLabelRotation=90;
set(gcf, 'Color', 'w');

figure(4);
plotconfusion(targetTst, saidasTst);
xlabel('Classes-Alvo','FontWeight','bold')
ylabel('Classes de Saída','FontWeight','bold')
title('Matriz de Confusão de Teste','FontWeight','bold')

```

```

set(gca,'xticklabel',{'Defeito' 'Sem Defeito' ''},'yticklabel',{'Defeito' 'Sem Defeito'
''},'FontWeight','bold')
ax=gca;
ax.YTickLabelRotation=90;
set(gcf, 'Color', 'w');

figure(5);
plotconfusion(targetTotal, saidasTotal);
xlabel('Classes-Alvo','FontWeight','bold')
ylabel('Classes de Saída','FontWeight','bold')
title('Matriz de Confusão Total','FontWeight','bold')
set(gca,'xticklabel',{'Defeito' 'Sem Defeito' ''},'FontWeight','bold','yticklabel',{'Defeito'
'Sem Defeito' ''},'FontWeight','bold')
ax=gca;
ax.YTickLabelRotation=90;
set(gcf, 'Color', 'w');

% Teste da rede
saidas=primeirarna(input);
perform=perform(primeirarna,target,saidas)

% Salvar variáveis do Workspace
save('NIBR1RNA')

```

Código do MATLAB para Segundo Estágio da RNA

```

% Segunda Rede Neural Perceptron Multicamadas para Identificação do Alimentador
% Defeituoso

% Entradas e Alvos da Rede
input = x';
target = y';

% Escolher a função de treinamento
trainFcn = 'trainbr';

% Criar a rede neural de classificação
hiddenLayerSize = 10;
segundarna = patternnet(hiddenLayerSize, trainFcn);

% Definir os parâmetros de treinamento

segundarna.trainParam.epochs=1000000; % Número de épocas
segundarna.trainParam.max_fail=1000000; % Número de Validation Checks

% Definir as funções de ativação
segundarna.layers{1}.TransferFcn = 'tansig';

```

```

segundarna.layers{2}.TransferFcn = 'tansig';

% Definir a divisão dos dados de treinamento, validação e teste
segundarna.divideFcn='divideind';

% Divisão dos índices para 5970 padrões
segundarna.divideParam.trainInd=( [1:119,200:318,399:517,598:716,797:915,996:1114,
1195:1313,1394:1512,1593:1711,1792:1910,1991:2109,2190:2308,2389:2507,2588:27
06,2787:2905,2986:3104,3185:3303,3384:3502,3583:3701,3782:3900,3981:4099,4180:
4298,4379:4497,4578:4696,4777:4895,4976:5094,5175:5293,5374:5492,5573:5691,57
72:5890]);
segundarna.divideParam.valInd=( [120:159,319:358,518:557,717:756,916:955,1115:115
4,1314:1353,1513:1552,1712:1751,1911:1950,2110:2149,2309:2348,2508:2547,2707:2
746,2906:2945,3105:3144,3304:3343,3503:3542,3702:3741,3901:3940,4100:4139,429
9:4338,4498:4537,4697:4736,4896:4935,5095:5134,5294:5333,5493:5532,5692:5731,5
891:5930]);
segundarna.divideParam.testInd=( [160:199,359:398,558:597,757:796,956:995,1155:11
94,1354:1393,1553:1592,1752:1791,1951:1990,2150:2189,2349:2388,2548:2587,2747:
2786,2946:2985,3145:3184,3344:3383,3543:3582,3742:3781,3941:3980,4140:4179,43
39:4378,4538:4577,4737:4776,4936:4975,5135:5174,5334:5373,5533:5572,5732:5771,
5931:5970]);

segundarna.performFcn='mse';

% Treinamento da rede
[segundarna,tr]=train(segundarna,input,target);

% Variáveis de Treinamento da Matriz de Confusão
saidasTrn = segundarna(input(:,tr.trainInd));
targetTrn = target(:,tr.trainInd);

% Variáveis de Validação da Matriz de Confusão
saidasVal = segundarna(input(:,tr.valInd));
targetVal = target(:,tr.valInd);

% Variáveis de Teste da Matriz de Confusão
saidasTst = segundarna(input(:,tr.testInd));
targetTst = target(:,tr.testInd);

% Total de Variáveis da Matriz de Confusão
saidasTotal = segundarna(input);
targetTotal = target;

% Plotar a matriz Performance
figure(1)
plotperform(tr)
xlabel([num2str(tr.num_epochs), ' épocas'],'FontWeight','bold')
ylabel('Erro quadrático médio (mse)','FontWeight','bold')

```

```

title(['O melhor desempenho da validação é de ', num2str(tr.best_vperf), ' na época ',
num2str(tr.best_epoch)])
legend('Treinamento','Validação','Teste','Melhor')
set(gcf, 'Color', 'w');

```

% Plotar as matrizes de confusão

```

figure(2);
plotconfusion(targetTrn, saidasTrn, 'Treinamento -');
xlabel('Classes-Alvo','FontWeight','bold')
ylabel('Classes de Saída','FontWeight','bold')
title('Matriz de Confusão de Treinamento','FontWeight','bold')
set(gca,'xticklabel',{'AL 3' 'AL 2' 'AL1' ''},'yticklabel',{'AL 3' 'AL 2' 'AL1'
''},'FontWeight','bold')
ax=gca;
ax.YTickLabelRotation=90;
set(gcf, 'Color', 'w');

```

```

figure(3);
plotconfusion(targetVal, saidasVal);
xlabel('Classes-Alvo','FontWeight','bold')
ylabel('Classes de Saída','FontWeight','bold')
title('Matriz de Confusão de Validação','FontWeight','bold')
set(gca,'xticklabel',{'AL 3' 'AL 2' 'AL1' ''},'yticklabel',{'AL 3' 'AL 2' 'AL1'
''},'FontWeight','bold')
ax=gca;
ax.YTickLabelRotation=90;
set(gcf, 'Color', 'w');

```

```

figure(4);
plotconfusion(targetTst, saidasTst);
xlabel('Classes-Alvo','FontWeight','bold')
ylabel('Classes de Saída','FontWeight','bold')
title('Matriz de Confusão de Teste','FontWeight','bold')
set(gca,'xticklabel',{'AL 3' 'AL 2' 'AL1' ''},'yticklabel',{'AL 3' 'AL 2' 'AL1'
''},'FontWeight','bold')
ax=gca;
ax.YTickLabelRotation=90;
set(gcf, 'Color', 'w');

```

```

figure(5);
plotconfusion(targetTotal, saidasTotal);
xlabel('Classes-Alvo','FontWeight','bold')
ylabel('Classes de Saída','FontWeight','bold')
title('Matriz de Confusão Total','FontWeight','bold')
set(gca,'xticklabel',{'AL 3' 'AL 2' 'AL1' ''},'yticklabel',{'AL 3' 'AL 2' 'AL1'
''},'FontWeight','bold')
ax=gca;
ax.YTickLabelRotation=90;
set(gcf, 'Color', 'w');

```

```
% Testa da rede
saidas=segundarna(input);
perf=perform(segundarna,target,saidas)
```

```
% Salvar variáveis do Workspace
save('N10BR2RNA')
```

Código do MATLAB para Terceiro Estágio da RNA

```
% Terceira Rede Neural Perceptron Multicamadas para Localização do ponto do
%Defeito
```

```
% Entradas e Alvos da Rede
input = x';
target = y';
```

```
% Escolher a função de treinamento
trainFcn = 'trainscg';
```

```
% Criar a rede neural de classificação
hiddenLayerSize = 1;
terceirarna = fitnet(hiddenLayerSize, trainFcn);
```

```
% Definir os parâmetros de treinamento
```

```
terceirarna.trainParam.epochs=1000000; % Número de épocas
terceirarna.trainParam.max_fail=1000000; % Número de Validation Checks
```

```
% Definir as funções de ativação
terceirarna.layers{1}.TransferFcn = 'tansig';
```

```
% Definir a divisão dos dados de treinamento, validação e teste
terceirarna.divideFcn='divideind';
```

```
% Divisão dos índices para 9950 padrões
```

```
terceirarna.divideParam.trainInd=( [1:119,200:318,399:517,598:716,797:915,996:1114,1
195:1313,1394:1512,1593:1711,1792:1910,1991:2109,2190:2308,2389:2507,2588:270
6,2787:2905,2986:3104,3185:3303,3384:3502,3583:3701,3782:3900,3981:4099,4180:4
298,4379:4497,4578:4696,4777:4895,4976:5094,5175:5293,5374:5492,5573:5691,577
2:5890,5971:6089,6170:6288,6369:6487,6568:6686,6767:6885,6966:7084,7165:7283,7
364:7482,7563:7681,7762:7880,7961:8079,8160:8278,8359:8477,8558:8676,8757:887
5,8956:9074,9155:9273,9354:9472,9553:9671,9752:9870]);
terceirarna.divideParam.valInd=( [120:159,319:358,518:557,717:756,916:955,1115:115
4,1314:1353,1513:1552,1712:1751,1911:1950,2110:2149,2309:2348,2508:2547,2707:2
746,2906:2945,3105:3144,3304:3343,3503:3542,3702:3741,3901:3940,4100:4139,429
9:4338,4498:4537,4697:4736,4896:4935,5095:5134,5294:5333,5493:5532,5692:5731,5
```

```

891:5930,6090:6129,6289:6328,6488:6527,6687:6726,6886:6925,7085:7124,7284:732
3,7483:7522,7682:7721,7881:7920,8080:8119,8279:8318,8478:8517,8677:8716,8876:8
915,9075:9114,9274:9313,9473:9512,9672:9711,9871:9910]);
terceirarna.divideParam.testInd=( [160:199,359:398,558:597,757:796,956:995,1155:119
4,1354:1393,1553:1592,1752:1791,1951:1990,2150:2189,2349:2388,2548:2587,2747:2
786,2946:2985,3145:3184,3344:3383,3543:3582,3742:3781,3941:3980,4140:4179,433
9:4378,4538:4577,4737:4776,4936:4975,5135:5174,5334:5373,5533:5572,5732:5771,5
931:5970,6130:6169,6329:6368,6528:6567,6727:6766,6926:6965,7125:7164,7324:736
3,7523:7562,7722:7761,7921:7960,8120:8159,8319:8358,8518:8557,8717:8756,8916:8
955,9115:9154,9314:9353,9513:9552,9712:9751,9911:9950]);

```

```

terceirarna.performFcn='mse';

```

```

% Treinamento da rede

```

```

[terceirarna,tr]=train(terceirarna,input,target);

```

```

% Variáveis de Treinamento da Matriz de Confusão

```

```

saidasTrn = terceirarna(input(:,tr.trainInd));
targetTrn = target(:,tr.trainInd);

```

```

% Variáveis de Validação da Matriz de Confusão

```

```

saidasVal = terceirarna(input(:,tr.valInd));
targetVal = target(:,tr.valInd);

```

```

% Variáveis de Teste da Matriz de Confusão

```

```

saidasTst = terceirarna(input(:,tr.testInd));
targetTst = target(:,tr.testInd);

```

```

% Total de Variáveis da Matriz de Confusão

```

```

saidasTotal = terceirarna(input);
targetTotal = target;

```

```

% Plotar a matriz Performance

```

```

figure(1)
plotperform(tr)
xlabel([num2str(tr.num_epochs), ' épocas'],'FontWeight','bold')
ylabel('Erro quadrático médio (mse)','FontWeight','bold')
title(['O melhor desempenho da validação é de ', num2str(tr.best_vperf), ' na época ',
num2str(tr.best_epoch)])
legend('Treinamento','Validação','Teste','Melhor')
set(gcf, 'Color', 'w');

```

```

% Salvar variáveis do Workspace

```

```

save('NISCG3RNAAL3')

```