

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
CÂMPUS CORNÉLIO PROCÓPIO
ENGENHARIA ELÉTRICA

MARINA SIBIM FÁVARO

**REDES NEURAS ARTIFICIAIS APLICADAS AO PROBLEMA DE
VARIAÇÃO DE TENSÃO DE LONGA DURAÇÃO EM SISTEMAS DE
DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**

TRABALHO DE CONCLUSÃO DE CURSO

CORNÉLIO PROCÓPIO
2017

MARINA SIBIM FÁVARO

**REDES NEURAIS ARTIFICIAIS APLICADAS AO PROBLEMA DE
VARIAÇÃO DE TENSÃO DE LONGA DURAÇÃO EM SISTEMAS DE
DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**

Trabalho de Conclusão de Curso de Engenharia Elétrica da Universidade Tecnológica Federal do Paraná – UTFPR, como requisito parcial para a obtenção do título de Engenheiro Eletricista.

Orientador: Prof. Dr. Murilo da Silva.

CORNÉLIO PROCÓPIO

2017



Universidade Tecnológica Federal do Paraná
Campus Cornélio Procópio
Departamento Acadêmico de Elétrica
Curso de Engenharia Elétrica



FOLHA DE APROVAÇÃO

Marina Sibim Favaro

Redes neurais artificiais aplicadas ao problema de variação de tensão de longa duração em sistemas de distribuição de energia elétrica

Trabalho de conclusão de curso apresentado às 17:40hs do dia 14/03/2017 como requisito parcial para a obtenção do título de Engenheiro Eletricista no programa de Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná. O candidato foi arguido pela Banca Avaliadora composta pelos professores abaixo assinados. Após deliberação, a Banca Avaliadora considerou o trabalho aprovado.

Prof(a). Dr(a). Murilo da Silva - Presidente (Orientador)

Prof(a). Dr(a). Danilo Hernane Spatti - (Membro)

Prof(a). Dr(a). Gabriela Helena Bauab Shiguemoto - (Membro)

A folha de aprovação assinada encontra-se na coordenação do curso.

RESUMO

FÁVARO, Marina Sibim. Redes neurais artificiais aplicadas ao problema de variação de tensão de longa duração em sistemas de distribuição de energia elétrica. 2017. 66 f. Trabalho de Conclusão de Curso em Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2017.

O presente trabalho apresenta uma ferramenta que utiliza Redes Neurais Artificiais (RNAs) para identificar diferentes padrões de problemas que acarretam variações de tensão de longa duração no sistema de distribuição, tendo em vista o impacto financeiro associado à falta de qualidade de energia elétrica tanto do ponto de vista do consumidor, quanto da concessionária fornecedora de energia. A proposta baseia-se no treinamento e teste de uma rede *Perceptron* Multicamadas (PMC), com diferentes padrões de problemas contidos em dados reais de tensão obtidos em campo e fornecidos pela Companhia Paulista de Força e Luz (CPFL). A partir da generalização dos problemas pela RNA, a mesma será capaz de identificar diferentes fontes de problemas relativos a variação de tensão. Esta proposta possibilitará às concessionárias o reestabelecimento do fornecimento adequado de energia elétrica mais rapidamente, diminuindo assim os gastos com compensações financeiras e insatisfação por parte dos consumidores.

Palavras-chave: RNA. Variações de Tensão. Qualidade de Energia Elétrica. PMC.

ABSTRACT

FÁVARO, Marina Sibim. Artificial neural networks applied in the problem of long-term voltage variations in the electrical distribution system. 2017. 66 f. Final Thesis - Electrical Engineering Course. Technological Federal University of Paraná. Cornélio Procópio, 2017.

This study presents a tool that uses Artificial Neural Networks (ANNs) to identify different patterns of problems causing long-term voltage variations on energy supply, having regard to the financial impact associated with the lack of quality in electricity, from the point of view of both the consumer and the supplier. The proposal is based in train and test a Multilayer Perceptron (MLP), with different patterns of problems within real data provided by the Companhia Paulista de Força e Luz (CPFL). Based on the generalization problems from the ANNs, it will be capable of recognize different sources of problems related to voltage level. This proposal will enable the suppliers with a fast re-establishment of electricity supply, decreasing the costs of financial compensation and dissatisfaction among clients.

Key words: ANN. Voltage Variations. Quality of electricity. MLP.

PUBLICAÇÕES

- PUBLICAÇÕES SUBMETIDAS:

MEDEIROS, V. T.; FÁVARO, M. S.; SILVA, M.; SPATTI, D. H.; LEOPOLDINO, R. Identificação e Classificação de Fontes Causadoras de Variações de Tensão de Longa Duração em Sistemas de Distribuição de Energia utilizando Redes Neurais Artificiais. In: Revista IEEE América Latina, 2017. 1ª Revisão.

LISTA DE FIGURAS

Figura 1. Classificação das faixas de tensão em relação à tensão de referência. ...	20
Figura 2. Representação do sistema nervoso humano em diagrama de blocos.	23
Figura 3. Representação de um neurônio humano com suas partes principais.	24
Figura 4. Representação de um neurônio artificial.	25
Figura 5. Etapas de funcionamento de um neurônio artificial.	27
Figura 6. Esquema da rede Perceptron Multicamadas.	31
Figura 7. Esquemático do funcionamento do algoritmo de treinamento da PMC, contemplando as etapas de propagação (forward) e retropropagação (backward). .	32
Figura 8. Fluxograma dos procedimentos realizados com a RNA.	35
Figura 9. Exemplificação do funcionamento da função XOR utilizada para determinar a porcentagem de acerto da RNA.	37
Figura 10. Representação da RNA utilizada para entrada trifásica: 3 entradas e 8 neurônios na saída.	38
Figura 11. Representação da RNA utilizada para entrada monofásica: 1 entrada e 8 neurônios na saída.	40
Figura 12. Representação do arranjo dos dados de entrada e desejados na saída utilizados para a RNA de entrada monofásica.	41
Figura 13. Representação do arranjo dos dados desejados na saída utilizados para a RNA de entrada janelada.	43
Figura 14. Representação da RNA utilizada para entrada janelada: 18 entradas e 1 neurônio na saída.	44
Figura 15. Representação do arranjo dos dados de entrada utilizados para a RNA de entrada janelada.	45

LISTA DE TABELAS

Tabela 1. Especificação dos dados de média tensão.	46
Tabela 2. Relação das topologias testadas na rede com entrada trifásica, erro obtido no melhor treinamento e porcentagem de acerto na fase de teste.	48
Tabela 3. Relação dos percentuais de acerto no teste feito com a rede de entrada trifásica para cada problema separadamente, utilizando a topologia [3 8 8].	49
Tabela 4. Relação das topologias testadas na rede com entrada monofásica, erro obtido no melhor treinamento e porcentagem de acerto no teste individualizada por fase.	51
Tabela 5. Relação dos percentuais de acerto obtidos no teste feito com a rede de entrada monofásica para cada problema separadamente, utilizando a topologia [1 10 8].	52
Tabela 6. Relação das topologias testadas na rede com entrada janelada, erro obtido no melhor treinamento e porcentagem de acerto na fase de teste, utilizando rede especialista para o problema de sobrecarga.	53
Tabela 7. Relação das topologias testadas na rede com entrada janelada, erro obtido no melhor treinamento e porcentagem de acerto na fase de teste, utilizando rede especialista para o problema de trafo avariado.	54
Tabela 8. Relação das topologias testadas na rede com entrada janelada, erro obtido no melhor treinamento e porcentagem de acerto na fase de teste, utilizando rede especialista para o problema de ajuste RT.	55
Tabela 9. Relação das topologias testadas na rede com entrada janelada, erro obtido no melhor treinamento e porcentagem de acerto na fase de teste, utilizando rede especialista para o problema de falha em conexões.	56
Tabela 10. Relação das topologias testadas na rede com entrada janelada, erro obtido no melhor treinamento e porcentagem de acerto na fase de teste, utilizando rede especialista para o problema de ramal de entrada.	57
Tabela 11. Relação das topologias testadas na rede com entrada janelada, erro obtido no melhor treinamento e porcentagem de acerto na fase de teste, utilizando rede especialista para o problema de TAP subdimensionado.	58

Tabela 12. Relação das topologias testadas na rede com entrada janelada, erro obtido no melhor treinamento e porcentagem de acerto na fase de teste, utilizando rede especialista para o problema de TAP sobredimensionado.	59
Tabela 13. Relação da melhor topologia de cada rede especialista, testadas com a rede de entrada janelada, com seu respectivo erro no melhor treinamento e percentual de acerto no teste.....	60
Tabela 14. Relação das melhores topologias de rede, para cada tipo de entrada, e seus respectivos erros dos melhores treinamentos e percentuais de acerto, para os testes feitos com os dados em BT.	61
Tabela 15. Relação dos resultados obtidos testando as melhores topologias de rede com os dados de diferentes níveis de tensão, apresentando os respectivos erros dos melhores treinamentos e percentuais de acerto.....	61

SUMÁRIO

1. INTRODUÇÃO	12
1.1. DELIMITAÇÃO DO TEMA.....	12
1.2. PROBLEMAS E PREMISSAS.....	14
1.3. OBJETIVOS	15
1.3.1. Objetivo Geral	15
1.3.2. Objetivos Específicos	15
1.4. JUSTIFICATIVA	16
2. FUNDAMENTAÇÃO TEÓRICA	18
2.1. QUALIDADE DE ENERGIA	18
2.2. VARIAÇÃO DE TENSÃO DE LONGA DURAÇÃO.....	19
2.3. MÓDULO 8 – PRODIST.....	19
2.4. REDES NEURAIS.....	22
2.4.1. Sistema Nervoso Humano	23
2.4.2. Neurônios Artificiais	25
2.4.3. Função de Ativação	27
2.4.4. Arquitetura e Treinamento das RNAs	29
2.4.5. Perceptron Multicamadas (PMC)	30
3. PROCEDIMENTOS METODOLÓGICOS	33
3.1. ENTRADA TRIFÁSICA	38
3.2. ENTRADA MONOFÁSICA	39
3.3. ENTRADA JANELADA.....	42
3.4. DIFERENTES NÍVEIS DE TENSÃO	45
4. RESULTADOS E DISCUSSÕES	48
4.1. ENTRADA TRIFÁSICA	48

4.2. ENTRADA MONOFÁSICA	50
4.3. ENTRADA JANELADA.....	52
4.4. DIFERENTES NÍVEIS DE TENSÃO	60
5. CONSIDERAÇÕES FINAIS	63
REFERÊNCIAS.....	65

1. INTRODUÇÃO

1.1. DELIMITAÇÃO DO TEMA

A energia elétrica é uma das formas de energia mais utilizadas no mundo e é considerada item fundamental para mensurar o desenvolvimento de uma sociedade (DOROCHE; ANSCHAU, 2015). Um sistema físico de energia elétrica é composto pelos subsistemas de geração, transmissão e distribuição, que tem como função básica fornecer a todos os consumidores em diferentes níveis de tensão, com a qualidade adequada e no momento em que for solicitada.

Para avaliar a qualidade de energia pode-se considerar dois pontos importantes: a qualidade do produto e a qualidade do serviço. A qualidade do produto diz respeito à conformidade do produto, o que pode ser definido como a capacidade de o sistema elétrico fornecer energia com tensões equilibradas e sem deformações de forma de onda. Enquanto a qualidade do serviço é medida segundo a continuidade do fornecimento da energia elétrica (BARROS et al., 2010).

Dentre os subsistemas citados anteriormente, a distribuição é o segmento dedicado à entrega de energia elétrica a um usuário final, considerando como partes integrantes do mesmo todas as instalações e equipamentos elétricos que operam em tensões inferiores a 230 kV (ANEEL, 2015). O sistema de distribuição de energia elétrica no Brasil é regulado por resoluções da Agência Nacional de Energia Elétrica (ANEEL). Além disso, o documento denominado Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST), em seus 9 módulos, dispõe conceitos, disciplinas, condições, responsabilidades e penalidades relativas à conexão, planejamento da expansão, operação e medição de energia elétrica. Estabelece ainda critérios e indicadores de qualidade para consumidores e produtores, distribuidores e agentes importadores e exportadores de energia.

O Módulo 8 do PRODIST tem como objetivo estabelecer os procedimentos relativos à Qualidade da Energia Elétrica (QEE), abordando a qualidade do produto e a qualidade do serviço prestado.

Os parâmetros de qualidade do produto abordados pelo Módulo 8 são:

- Tensão em regime permanente;

- Fator de potência;
- Harmônicos;
- Desequilíbrio de tensão;
- Flutuação de tensão;
- Variações de tensão de curta duração;
- Variação de frequência.

Dentre estes parâmetros, atualmente, somente a tensão em regime permanente e o fator de potência são penalizados pela ANEEL (Módulo 8, PRODIST, 2017).

Para a tensão em regime permanente são estabelecidos os limites adequados, precários e críticos para os níveis de tensão, os indicadores individuais e coletivos de conformidade de tensão elétrica, os critérios de medição, de registro e dos prazos para compensação ao consumidor, caso as medições de tensão excedam os limites determinados. A tensão em regime permanente deve ser avaliada por meio de um conjunto de leituras obtidas por medição apropriada, podendo ser requerida pelo consumidor ou feita de forma amostral a cada trimestre por determinação da ANEEL (Módulo 8, PRODIST, 2017). Caso os valores medidos estejam fora dos padrões estabelecidos a distribuidora deverá tomar providências para regularizar a tensão de atendimento, devendo pagar uma compensação financeira ao consumidor prejudicado até que o problema seja resolvido e comprovado por uma nova medição.

Na Revisão 6 do Módulo 8 do PRODIST, vigente do dia primeiro de janeiro de 2015 a 31 de dezembro de 2015, foi determinada a extinção do prazo de regularização do nível de tensão por parte das concessionárias, devendo essas pagarem compensações financeiras aos consumidores a partir da detecção do problema. Esta extinção vem sendo mantida até a recente revisão (Revisão 8), vigente a partir de primeiro de janeiro de 2017 e, com isso, as concessionárias sofreram um aumento significativo de gastos referentes a indenizações.

Sendo assim, este trabalho busca uma alternativa para a análise e classificação das causas dos problemas que levam a variações de tensão de longa duração, tendo como objetivo identificar as causas destes problemas a partir dos valores medidos, para que com essa ferramenta as concessionárias possam corrigir o problema de

forma mais rápida e efetiva, trazendo assim benefícios financeiros, além de melhorias no processo e no atendimento ao cliente.

Este trabalho propõe utilizar Redes Neurais Artificiais (RNAs) para identificar os diferentes padrões de problemas que acarretam variações de tensão de longa duração. Estas redes serão treinadas e testadas com dados reais de tensão obtidos em campo e fornecidos pela Companhia Paulista de Força e Luz (CPFL).

1.2. PROBLEMAS E PREMISSAS

Atualmente existe uma grande preocupação em se manter a qualidade de energia devido as perdas financeiras a ela associadas, tanto do ponto de vista do consumidor, quanto da distribuidora de energia elétrica.

No caso das variações de tensão de longa duração, a ANEEL estabelece através do PRODIST limites adequados, precários e críticos de tensão, indicadores de conformidade de tensão e procedimentos para medição, além de critérios para compensação aos consumidores.

O conjunto de leituras gerado pelo processo de medição estabelecido pela ANEEL compreende o registro de 1008 leituras válidas obtidas em intervalos consecutivos de 10 minutos cada e a partir desses dados tem-se gráficos do comportamento da tensão nesse período.

Percebe-se, porém, que a partir dessas medições é possível verificar apenas a existência ou não de transgressão dos níveis adequados de tensão através do cálculo dos indicadores. A identificação dos problemas que causam essas variações de tensão é feita partindo-se da premissa de sobrecarga no sistema. Entretanto, problemas oriundos de outras causas, tais como: de avaria de transformadores, ramal de entrega parcialmente rompido, conexões com mal contato, transformador com relação de transformação errada e problemas com reguladores de tensão, são de difícil identificação, pois as concessionárias não dispõem de ferramentas para este tipo de análise.

A dificuldade em se identificar a fonte causadora do problema acaba por elevar o tempo para restabelecimento do padrão adequado de nível de tensão, acarretando períodos de ressarcimento mais longos para a concessionária e exposição do

consumidor ao problema. Além disso, um simples problema de transformador com relação de transformação errada, pode ser tratado como uma sobrecarga no setor, levando a uma tomada de decisão errônea para o problema, elevando os custos para solução do mesmo.

A principal dificuldade aparece, portanto, durante o diagnóstico do problema, uma vez que a análise visual dos gráficos gerados pelas medições não permite uma classificação clara do mesmo, bem como, requer muita experiência do profissional que está analisando os dados para definição do problema. Dessa forma, percebe-se a necessidade de uma ferramenta que possibilite a identificação do problema de forma rápida e eficiente, para que as concessionárias possam reduzir o tempo de solução, garantindo um melhor atendimento ao cliente, além de menores gastos com compensações financeiras.

1.3. OBJETIVOS

1.3.1. Objetivo Geral

Propor uma ferramenta para identificação das fontes causadoras de problemas de variação de tensão de longa duração fundamentada no reconhecimento de padrões utilizando Redes Neurais Artificiais.

1.3.2. Objetivos Específicos

- Realizar pesquisas bibliográficas relacionadas à qualidade de energia elétrica, problemas de variação de tensão de longa duração e as respectivas normativas vigentes;
- Realizar estudos referentes a Redes Neurais Artificiais (RNAs), contemplando conceitos, tipos de RNAs, técnicas de treinamento e aplicabilidade ao problema proposto;

- Avaliar diferentes metodologias de tratamento dos dados no que tange a formatação de entrada e saída dos dados para apresentação à RNA:
 - Apresentar dados por fase individualizado;
 - Apresentar entradas de forma janelada;
 - Apresentar dados de diferentes níveis de tensão.
- Realizar treinamentos e testes com as RNAs para validação da proposta, prezando sempre por modelos compactos e eficientes;
- Analisar e discutir os resultados obtidos e a aplicabilidade ao problema proposto.

1.4. JUSTIFICATIVA

A recente revisão (Revisão 8) do Módulo 8 do PRODIST, documento que regulamenta os procedimentos de distribuição de energia elétrica no Brasil, objetivando estabelecer as práticas relativas à Qualidade da Energia Elétrica, válida a partir do dia primeiro de janeiro de 2017, manteve algumas mudanças presentes a partir da Revisão 6. Dentre estas mudanças, a principal motivadora deste trabalho foi a que extingue o prazo para regularização dos níveis de tensão por parte das concessionárias caso estes estejam fora dos padrões estabelecidos.

Na Revisão 4, vigente até 31 de dezembro de 2014, a ANEEL definia que, em caso de comprovação de transgressão de nível de tensão no consumidor, a concessionária dispunha do prazo de 90 dias para regularizar o problema devido a transgressão do indicador DRP (Índice de Duração Relativa da Transgressão para Tensão Precária) e 15 dias caso fosse constatada transgressão por DRC (Índice de Duração Relativa da Transgressão para Tensão Crítica), sem que houvesse penalização ou ressarcimento por parte da concessionária casos os prazos de regularização fossem atendidos.

A partir da Revisão 6 do Módulo 8 do PRODIST, com a extinção dos prazos de regularização da transgressão de nível de tensão, houve um significativo aumento de gastos por parte da concessionária, no que se refere à compensação financeira dos consumidores que apresentam níveis de tensão inadequado em suas instalações, quando comparado com os gastos deste tipo até a vigência da Revisão 4.

Além das mudanças regulatórias ressalta-se também a necessidade de criação de ferramentas que auxiliem os técnicos e engenheiros responsáveis pelo processo de análise do nível de tensão, visto que um diagnóstico simples tomando como base somente a transgressão de limites pode conduzir a tomadas de decisão que não sejam ótimas, elevando custos e tempos para regularização.

Como exemplo, um transformador instalado com relação de transformação fora do padrão pode causar uma transgressão por nível de tensão cuja análise simples pelos indicadores pode desencadear o projeto e execução de um melhoramento de um setor sem a devida necessidade, visto que uma simples alteração da relação resolveria o problema.

Dado o exposto, justifica-se a importância de uma identificação rápida e eficiente dos problemas que causam variação significativa na tensão entregue ao consumidor. Sendo assim, a ferramenta proposta neste trabalho poderá auxiliar na análise e identificação das causas dos problemas relacionados à variação de tensão, contribuindo, dessa forma, com as concessionárias na correção dos problemas de forma mais rápida e efetiva, trazendo assim benefícios financeiros, além de melhorias no processo e no atendimento ao cliente.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. QUALIDADE DE ENERGIA

Segundo *Dugan, McGranaghan, Beaty e Santoso (2003)*, a falta de qualidade de energia pode ser definida como qualquer problema de energia manifestado na tensão, corrente ou nas variações de frequência que resultem em falha ou má operação de equipamentos de consumidores. O crescente interesse em se estudar a qualidade de energia está diretamente relacionado aos impactos econômicos a ela associados.

A qualidade de energia pode ser dividida em qualidade do produto e qualidade do serviço. A qualidade do produto diz respeito à forma de onda da tensão fornecida pela distribuidora, levando em consideração a simetria entre as fases, a magnitude das tensões e a frequência da onda. Enquanto a qualidade do serviço analisa a continuidade no fornecimento de energia elétrica, o tempo e a qualidade do atendimento ao cliente.

No Brasil, a Qualidade da Energia Elétrica (QEE) é regulamentada por meio do Módulo 8 do PRODIST (Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional) da Agência Nacional de Energia Elétrica (ANEEL), o qual padroniza e normatiza as atividades técnicas relativas ao funcionamento e desempenho dos sistemas de distribuição de energia elétrica, abordando a qualidade do produto e do serviço prestado.

Dentre os aspectos considerados da qualidade do produto, este trabalho aborda mais especificamente os relacionados à tensão em regime permanente, levando em consideração as variações de tensão de longa duração, tema que será abordado em seguida.

2.2. VARIAÇÃO DE TENSÃO DE LONGA DURAÇÃO

As variações de tensão de longa duração são caracterizadas pela alteração do valor *rms* (do inglês *Root Mean Square*), ou seja, do valor eficaz da tensão, por um período igual ou maior que três minutos, conforme PRODIST. Estas alterações geralmente são causadas por variações de carga e operações de chaveamento no sistema (FERREIRA, 2010).

São alocadas à classe das variações de tensão de longa duração os fenômenos de subtensão, sobretensão e interrupção sustentada (Módulo 8, PRODIST, 2017).

A subtensão é a diminuição do valor eficaz da tensão para menos de 90% do valor nominal. Pode ser causada por instalação mal dimensionada, taps incorretos de transformadores, reguladores de tensão desajustados ou sobrecarga não intencional na rede elétrica. A subtensão pode resultar em má operação ou baixa performance dos equipamentos da instalação (ALDABÓ, 2001).

A sobretensão é o aumento do valor eficaz da tensão para 110% do valor nominal. Pode ser causada por regulador desajustado ou por flutuação nas cargas demandadas. A sobretensão pode causar falhas e até mesmo avarias a equipamentos (ALDABÓ, 2001).

Já a interrupção é caracterizada quando o valor eficaz da tensão é menor que 10% do valor nominal. Pode ser causada por falha de disjuntores e curtos-circuitos, tendo como consequência perdas econômicas e insatisfação do consumidor.

2.3. MÓDULO 8 – PRODIST

O Módulo 8 do PRODIST tem como objetivo estabelecer os procedimentos relativos à Qualidade da Energia Elétrica (QEE), abordando a qualidade do produto e a qualidade do serviço prestado, segundo as regulamentações da ANEEL.

Para a tensão em regime permanente são estabelecidos os limites adequados, precários e críticos para os níveis de tensão, como mostrado na Figura 1. Estes

valores são definidos em relação ao valor de referência, o qual deve ser a tensão nominal ou a contratada.

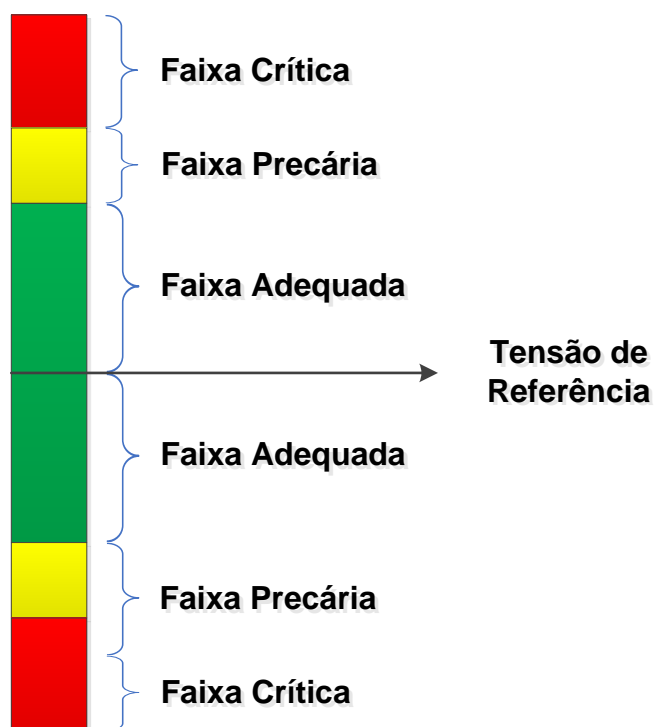


Figura 1. Classificação das faixas de tensão em relação à tensão de referência.

Fonte: Próprio autor. Adaptada de Módulo 8, PRODIST, 2017.

Os limites dos intervalos de cada faixa (adequada, precária e crítica) são apresentados no Módulo 8 em forma de tabelas, e seus valores variam de acordo com a tensão nominal do ponto de conexão do consumidor. São estabelecidos os intervalos para tensões nominais iguais ou superiores a 230 kV, entre 69 kV e 230 kV, entre 1 kV e 69 kV e também inferiores a 1 kV. Para o último caso divide-se ainda em subníveis de tensão de atendimento: 220/127 V, 380/220 V, 254/127 V, 440/220 V, 208/120 V, 230/115 V, 240/120 V e 200/110 V.

A tensão em regime permanente deve ser avaliada por meio de um conjunto de leituras obtidas por medição apropriada, de acordo com a metodologia descrita para os indicadores individuais e coletivos. A Revisão 8 do Módulo 8 do PRODIST determina as seguintes modalidades:

- **Eventual:** por reclamação do consumidor ou por determinação da ANEEL;
- **Amostrai:** por determinação da ANEEL, de acordo com sorteio realizado para cada trimestre;
- **Permanente:** por meio do sistema de medição de que trata a Resolução Normativa nº 502/2012;

Estas medições devem ser feitas no ponto de conexão entre as redes da distribuidora e o acessante, por um período de 7 dias com intervalos de 10 minutos entre cada leitura, totalizando 1008 leituras válidas (quando houver interrupção o intervalo deve ser desconsiderado).

Após a obtenção do conjunto de leituras válidas, devem ser calculados os indicadores individuais de conformidade de tensão elétrica, sendo eles:

- **DRP** – índice de duração relativa da transgressão para tensão precária;
- **DRC** – índice de duração relativa da transgressão para tensão crítica.

A Revisão 8 do Módulo 8 do PRODIST estabelece a duração relativa da transgressão máxima para os índices em 3% para o DRP e 0,5% para o DRC. Caso estes limites sejam ultrapassados, a distribuidora deverá regularizar a tensão de atendimento, realizando o pagamento das compensações e das sanções cabíveis pela fiscalização da ANEEL.

O cálculo do indicador DRP se dá através da equação (1), enquanto o cálculo do DRC é feito através da equação (2).

$$DRP = \frac{nlp}{1008} \cdot 100 \quad [\%] \quad (1)$$

$$DRC = \frac{nlc}{1008} \cdot 100 \quad [\%] \quad (2)$$

Nessas equações, *nlp* representa o número de leituras situadas na faixa precária e *nlc* representa o número de leituras situadas na faixa crítica.

2.4. REDES NEURAIS

Os Sistemas Inteligentes (SIs) são técnicas baseadas nos conceitos, princípios e mecanismos fundamentais dos sistemas naturais (BRUMATTI). Têm como objetivo capacitar o computador a executar funções que são desempenhadas pelo ser humano usando conhecimento e raciocínio (REZENDE, 2005).

Para um sistema ser considerado inteligente ele precisa possuir pelo menos um subconjunto de habilidades (por exemplo, armazenar e recuperar eficientemente grande quantidade de informação, para resolver problemas ou tomar decisões) e saber como elas modelam tarefas específicas (REZENDE, 2005).

Dentre as técnicas e metodologias utilizadas para desenvolver um sistema inteligente estão as Redes Neurais Artificiais, as quais podem ser empregadas em diversos problemas relacionados às engenharias e ciências.

As Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso de seres vivos (SILVA et al., 2010). A principal propriedade de uma RNA é sua habilidade de aprender a partir de seu ambiente e de melhorar seu desempenho através de aprendizagem (HAYKIN, 2001).

As RNAs podem ser definidas como um conjunto de unidades de processamento (neurônios artificiais), que são interligados por um grande número de interconexões (sinapses artificiais) (SILVA et al., 2010). Cada neurônio artificial efetua um certo número de operações simples e transmite seus resultados aos neurônios vizinhos com os quais possui conexão (BRUMATTI).

Segundo Silva, Spatti e Flauzino (2010), as características mais relevantes envolvidas com a aplicação de RNAs são:

- Adaptação por experiência;
- Capacidade de aprendizado;
- Habilidade de generalização;
- Organização de dados;
- Tolerância a falhas;
- Armazenamento distribuído;
- Facilidade de prototipagem.

Em seguida serão apresentados mais detalhadamente o sistema nervoso humano (base para o desenvolvimento das redes neurais artificiais) e o neurônio artificial, bem como informações importantes para a implementação de uma RNA (funções de ativação, arquitetura e treinamento e a rede que será utilizada).

2.4.1. Sistema Nervoso Humano

O sistema nervoso humano pode ser visto como um sistema de três estágios, como é apresentado na Figura 2.

O centro do sistema é o cérebro (rede neural) que recebe continuamente informação, percebe-a e toma decisões apropriadas. Os demais componentes são os receptores e os atuadores. Os receptores convertem os estímulos do corpo humano ou do ambiente externo em impulsos elétricos e transmitem informação ao cérebro. Já os atuadores convertem os impulsos elétricos gerados pela rede neural em respostas discerníveis como saídas do sistema (HAYKIN, 2001).




Figura 2. Representação do sistema nervoso humano em diagrama de blocos.

Fonte: Próprio autor, adaptado de HAYKIN, (2001).

O processamento de informações no cérebro humano é regido por elementos processadores biológicos que operam em paralelo, tendo como objetivo a produção de ações apropriadas para cada uma de suas funcionalidades (SILVA et al., 2010).

O neurônio é a principal célula do sistema nervoso cerebral. Pode ser dividido em três partes principais: dendritos, corpo celular (ou soma) e axônio, os quais são apresentados na Figura 3. Sua função é conduzir os estímulos elétricos sob determinadas condições de operação (SILVA et al., 2010).




Figura 3. Representação de um neurônio humano com suas partes principais.

Fonte: PET ENGENHARIA CIVIL UFJF (2013).

Os dendritos de um neurônio são conectados ao axônio de outros neurônios e, através desta conexão, são transmitidos sinais entre eles. Os dendritos captam continuamente os sinais advindos dos axônios enquanto o corpo celular processa essas informações. Quando o sinal recebido na entrada (dendritos) excede um limiar, o neurônio é ativado, ou seja, ocorre uma reação química que resulta em um pulso elétrico, conhecido como potencial de ação (ou ativação), o qual será enviado às terminações do axônio, em direção às sinapses que conectam um neurônio a outros neurônios (COPPIN, 2012).

É importante ressaltar que não existem conexões físicas entre os neurônios. A transferência de sinais entre os dendritos e axônios ocorre por meio de sinapses, as quais são conexões controladas por impulsos elétricos e por reações químicas devidas a substâncias chamadas neurotransmissores (BITTENCOURT, 2006).

Além disso, a propriedade chamada de plasticidade, torna possível ao cérebro se adaptar ao meio ambiente e aprender, por meio da criação de novas conexões sinápticas entre neurônios e a modificação das sinapses existentes (HAYKIN, 2001).

2.4.2. Neurônios Artificiais

Os neurônios artificiais são fundamentados nos neurônios biológicos e são a base para o projeto de redes neurais artificiais. O modelo proposto por *McCulloch* e *Pitts* (1943) é simples e engloba as principais características de uma rede neural biológica (COPPIN, 2012).

A Figura 4 apresenta esquematicamente um neurônio artificial e os elementos básicos que o constituem. Silva, Spatti e Flauzino (2010) apresentam detalhadamente cada um desses elementos:




Figura 4. Representação de um neurônio artificial.

Fonte: Barra (2013).

- **Sinais de entrada** $\{x_1, x_2, \dots, x_n\}$
São os sinais ou medidas advindas do meio externo e que representam os valores assumidos pelas variáveis de uma aplicação específica;
- **Pesos sinápticos** $\{w_1, w_2, \dots, w_n\}$
São os valores que servem para ponderar cada uma das variáveis de entrada da rede;
- **Combinador linear** $\{\Sigma\}$
Agrega todos os sinais de entrada que foram ponderados pelos respectivos pesos sinápticos e produz um valor de potencial de ativação;

- **Limiar de ativação $\{\theta\}$**

Variável que especifica qual será o patamar apropriado para que o resultado produzido pelo combinador linear possa gerar um valor de disparo em direção à saída do neurônio;

- **Potencial de ativação $\{u\}$**

Resultado obtido pela diferença do valor produzido entre o combinador linear e o limiar de ativação. Se tal valor é positivo, então o neurônio produz um potencial excitatório; caso contrário, o potencial será inibitório;

- **Função de ativação $\{g\}$**

Limita a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela sua própria imagem funcional;

- **Sinal de saída $\{y\}$**

Valor final produzido pelo neurônio em relação a um determinado conjunto de sinais de entrada, podendo ser também utilizado por outros neurônios que estão sequencialmente interligados.

Pode-se também, segundo o modelo de neurônio artificial proposto por *McCulloch* e *Pitts*, expressar o potencial de ativação (u) através da equação (3) enquanto a saída do neurônio pode ser expressa pela equação (4).

$$u = \sum_{i=1}^n w_i \cdot x_i - \theta \quad (3)$$

$$y = g(u) \quad (4)$$

De forma geral, pode-se resumir o funcionamento de um neurônio artificial por meio dos passos apresentados na Figura 5.

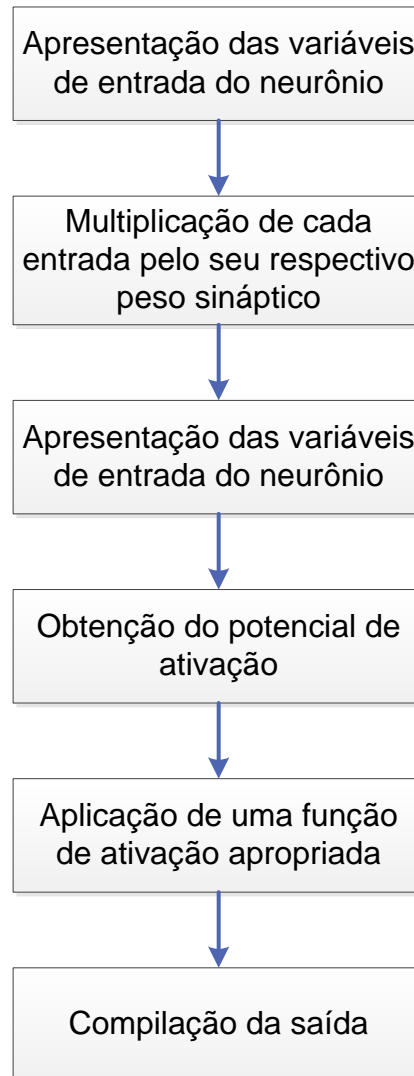


Figura 5. Etapas de funcionamento de um neurônio artificial.

Fonte: Próprio autor.

Para que as redes neurais aprendam, o peso associado a cada conexão (equivalente a uma sinapse no cérebro humano) pode ser alterado em resposta a conjuntos específicos de entradas e de eventos (COPPIN, 2012). O ajuste dos pesos é feito na etapa de treinamento da rede, a qual será tratada mais adiante.

2.4.3. Função de Ativação

As funções de ativação são classificadas em dois grupos (SILVA et al., 2010):

- **Funções parcialmente diferenciáveis:** funções que possuem pontos cujas derivadas de primeira ordem são inexistentes;
- **Funções totalmente diferenciáveis:** funções cujas derivadas de primeira ordem existem e são conhecidas em todos os pontos de seu domínio de definição.

Como exemplo de funções parcialmente diferenciáveis tem-se a função Degrau e a função Degrau Bipolar.

A função Degrau é definida em (5) e seu resultado de saída sempre assume valores reais entre 0 e 1.

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases} \quad (5)$$

Já a função Degrau Bipolar é definida em (6) onde seu resultado de saída assume valores reais entre -1 e 1 e em (7) onde seu resultado de saída assume valores reais entre -1, 0 e 1.

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ -1, & \text{se } u < 0 \end{cases} \quad (6)$$

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u = 0 \\ -1, & \text{se } u < 0 \end{cases} \quad (7)$$

Para as funções totalmente diferenciáveis tem-se como exemplo a função Logística e a função Tangente Hiperbólica.

A função Logística é dada pela equação (8) e seu resultado de saída sempre assume valores reais entre 0 e 1.

$$g(u) = \frac{1}{1 + e^{-\beta \cdot u}} \quad (8)$$

Já a função Tangente Hiperbólica é dada pela equação (9) e seu resultado de saída sempre assume valores reais entre -1 e 1.

$$g(u) = \frac{1 - e^{-\beta \cdot u}}{1 + e^{-\beta \cdot u}} \quad (9)$$

Para ambas as funções β é uma constante real associada ao nível de inclinação da função.

A escolha do tipo de função de ativação a ser utilizada depende do tipo de rede que será utilizado e do resultado que se espera na saída.

2.4.4. Arquitetura e Treinamento das RNAs

A forma como os diversos neurônios de uma rede neural estão arranjados determina o tipo de arquitetura da rede. Esses arranjos são essencialmente estruturados através do direcionamento das conexões sinápticas dos neurônios. Cada arquitetura pode possuir diversas topologias, sendo estas as diferentes formas de composições estruturais que a arquitetura pode assumir (SILVA et al., 2010).

Uma rede neural artificial (RNA) é composta por três diferentes camadas: camada de entrada (responsável pelo recebimento de informações), camadas intermediárias (responsáveis por extrair as características associadas ao processo) e camada de saída (responsável pela produção e apresentação dos resultados finais da rede) (SILVA et al., 2010). Quanto maior o número de neurônios nas camadas intermediárias, mais complexas são as funções mapeadas com a RNA. Porém, um número muito grande de neurônios nestas camadas pode levar a resultados indesejados (REZENDE, 2005).

As principais arquiteturas de RNAs, considerando a disposição de seus neurônios, assim como as formas de interligação entre eles e a constituição de suas camadas, podem ser divididas em: redes *feedforward* (alimentação à frente) de camada simples (*Perceptron* e *Adaline*), redes *feedforward* de camadas múltiplas (*Perceptron* multicamadas (PMC) e redes de base radial (RBF)), redes recorrentes e redes reticuladas (SILVA et al., 2010).

O treinamento de uma rede neural consiste em ajustar seus pesos sinápticos de forma que a saída coincida com um certo valor desejado, respectivo a uma determinada entrada. O treinamento pode ser de dois tipos: supervisionado e não

supervisionado. O treinamento supervisionado exige a disponibilidade de um conjunto de treinamento composto por entradas e suas respectivas saídas desejadas. Já no treinamento não supervisionado, o conjunto de treinamento é formado apenas pelas entradas (BITTENCOURT, 2006).

2.4.5. *Perceptron* Multicamadas (PMC)

Dentre as arquiteturas de redes neurais artificiais citadas anteriormente, a *Perceptron* Multicamadas (PMC) ou *Multilayer Perceptron* (MLP) será a utilizada neste trabalho. Esse tipo de rede é muito versátil e possui, para as mais diversas áreas de conhecimento, um alto potencial de aplicação em vários tipos de problemas. Entre essas potenciais áreas, Silva, Spatti e Flauzino (2010), apresentam os seguintes destaques:

- Aproximação universal de funções;
- Reconhecimento de padrões;
- Identificação e controle de processos;
- Previsão de séries temporais;
- Otimização de sistemas.

As redes *Perceptron* Multicamadas apresentam como principal característica a existência de pelo menos uma camada intermediária (escondida) entre a camada de entrada e a camada de saída, como pode ser visto na Figura 6.




Figura 6. Esquema da rede *Perceptron* Multicamadas.

Fonte: BARBON, Sylvio. (2013).

Independentemente do número de camadas intermediárias da rede, a propagação dos sinais recebidos na entrada das PMC é feita sempre em direção a saída, ou seja, em um único sentido. Além disso, o treinamento dessa rede é do tipo supervisionado, necessitando, portanto, apresentar para a rede dados de entradas e suas respectivas saídas desejadas para que dessa forma os pesos sinápticos e limiares da rede sejam ajustados.

Ao apresentar os dados de entrada para a rede, estes são transmitidos para as camadas intermediárias que extraem e codificam as informações através dos pesos sinápticos e limiares de seus neurônios. A camada de saída, por sua vez, recebe os estímulos vindos da última camada intermediária, e produz uma resposta na saída da rede (SILVA et al., 2010).

O algoritmo de aprendizado utilizado no processo de treinamento das redes MLP é conhecido como algoritmo de retropropagação de erro (*error backpropagation*), conhecido também como regra Delta generalizada. Este algoritmo é baseado na regra de aprendizagem por correção de erro e consiste basicamente em duas etapas: a propagação e a retropropagação. (HAYKIN, 2001).

Na primeira etapa, a propagação (*forward*), um conjunto de dados de treinamento são apresentados à camada de entrada e propagados, através das demais camadas intermediárias, até chegar à camada de saída, a qual produz uma

resposta real da rede. Durante esta etapa todos os pesos sinápticos são fixos. A partir da resposta obtida na saída da rede, faz-se a comparação desta com a resposta desejada previamente estabelecida, obtendo-se assim um valor de erro. Em função desse valor de erro, aplica-se então a segunda etapa, a retropropagação (*backward*). Nesta etapa todos os pesos sinápticos e limiares são ajustados de acordo com uma regra de correção de erro. O ajuste dos pesos sinápticos faz com que a resposta real da rede se encaminhe, de forma estatística, para a resposta desejada (HAYKIN, 2001).

O processo de treinamento da rede PMC citado anteriormente é apresentado na Figura 7, onde são demonstradas pelas setas as etapas de propagação (*forward*) e retropropagação (*backward*) do algoritmo de aprendizado, considerando uma PMC com duas camadas intermediárias como exemplo.




Figura 7. Esquemático do funcionamento do algoritmo de treinamento da PMC, contemplando as etapas de *propagação (forward)* e *retropropagação (backward)*.

Fonte: (SILVA et al., 2010).

Na próxima seção serão apresentados os procedimentos metodológicos realizados nas etapas em que o trabalho foi dividido, abordando de forma geral todas elas, bem como detalhando posteriormente cada uma em suas especificidades.

3. PROCEDIMENTOS METODOLÓGICOS

Como já citado anteriormente, este trabalho utilizou dados reais de tensão obtidos em campo e fornecidos pela CPFL. Estes dados foram obtidos seguindo os requisitos de medição propostos pelo PRODIST e fornecem valores eficazes de tensão medidos entre cada fase e o neutro do consumidor.

Os testes feitos com a rede foram divididos em quatro etapas. Primeiramente apresentaram-se os dados das três fases simultaneamente, uma vez que os dados que foram fornecidos pela CPFL são trifásicos.

Na segunda etapa, fez-se a apresentação individualizada por fase, tendo em vista que as medições podem ser monofásicas, bifásicas ou trifásicas, dependendo do tipo de consumidor, a fim de possibilitar a caracterização de problemas mesmo quando não se tem transgressão de tensão em todas as fases.

Na terceira etapa buscou-se apresentar um intervalo maior de dados para a RNA utilizando-se de dados na forma janelada, com o objetivo de caracterizar melhor mudanças nos padrões.

Por fim, na última etapa, utilizou-se de dados de diferentes níveis de tensão, visto que em sistemas de distribuição pode-se encontrar diferentes níveis de tensão nominal. Nesta etapa, além de dados de baixa tensão, foram apresentados também dados de média tensão.

A arquitetura de rede utilizada foi a *Perceptron* Multicamadas (PMC) devido a sua grande capacidade de classificação de padrões. A implementação da rede PMC foi feita utilizando linhas de comando e a ferramenta de interface gráfica da *toolbox nntool* do *Matlab*®.

Para todas as etapas foram feitos testes variando a topologia da rede, ou seja, variando o número de camadas intermediárias e o número de neurônios nestas camadas. O treinamento foi feito de forma supervisionada, sendo assim, para cada entrada apresentada à rede, apresentou-se também a respectiva saída desejada. Em cada treinamento os pesos sinápticos são inicializados de forma aleatória e isso interfere na performance final. Dessa forma, para evitar que se tenha um treinamento ruim e, conseqüentemente, uma rede mal treinada devido aos valores dos pesos sinápticos, fez-se para cada topologia em análise, 10 treinamentos consecutivos antes de prosseguir para a fase de teste. O algoritmo usado para o treinamento foi o

Levenberg-Marquardt. Este algoritmo é uma variação do já citado *error backpropagation*, que possui maior velocidade de convergência, sendo assim considerado um dos algoritmos de treinamento mais eficientes (YU; WILAMOWSKI, 2010).

Na etapa de teste, utilizou-se apenas a rede com as configurações obtidas após o melhor treinamento dentre todos os realizados, classificando como melhor treinamento aquele que possuía o menor erro quadrático médio, ou *Mean Square Error* (MSE). Nesta fase, são apresentados novos dados à rede, ou seja, dados diferentes dos utilizados durante o treinamento. O resultado esperado na saída não é mostrado para a rede, mas sim comparado com o resultado real da rede a fim de determinar a porcentagem de acerto obtido. A Figura 8 ilustra de forma simplificada os procedimentos realizados com a RNA.

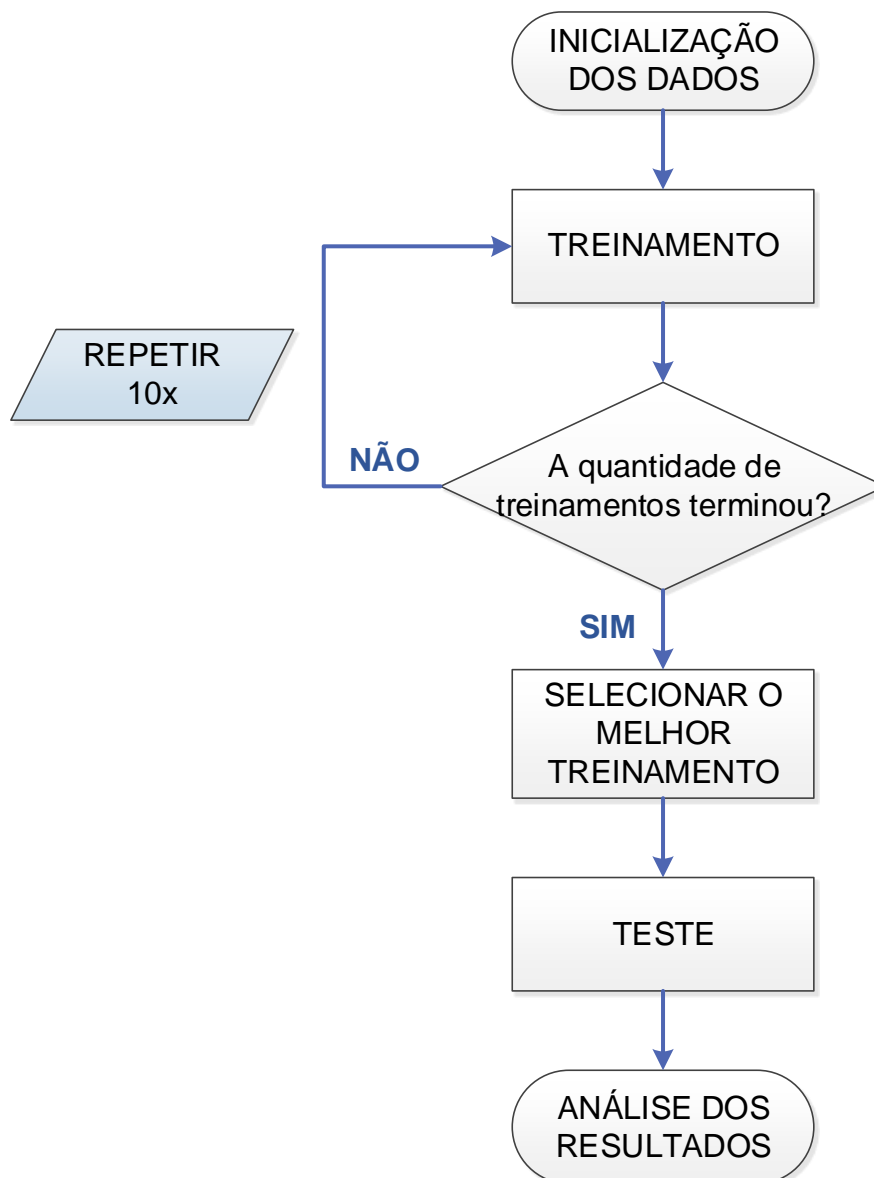


Figura 8. Fluxograma dos procedimentos realizados com a RNA.

Fonte: Próprio autor.

Para analisar a capacidade da RNA de classificar os padrões, foram considerados 7 problemas que frequentemente causam variação de tensão na rede de distribuição, sendo eles: sobrecarga, transformador avariado (trafo avariado), ajuste do regulador de tensão (ajuste RT), falha em conexões, ramal de entrada com problema, tap do transformador subdimensionado e tap do transformador sobredimensionado. Cada um destes problemas é representado por um padrão de saída para a rede, como mostrado no Quadro 1. Vale ressaltar que a condição normal,

ou seja, quando o valor da amostra de tensão está dentro dos limites estabelecidos, também é considerado um padrão.

Problema	Padrão de Saída
Normal	[1; 0; 0; 0; 0; 0; 0; 0; 0]
Sobrecarga	[0; 1; 0; 0; 0; 0; 0; 0; 0]
Trafo Avariado	[0; 0; 1; 0; 0; 0; 0; 0; 0]
Ajuste RT	[0; 0; 0; 1; 0; 0; 0; 0; 0]
Falha em Conexões	[0; 0; 0; 0; 1; 0; 0; 0; 0]
Ramal de Entrada	[0; 0; 0; 0; 0; 1; 0; 0; 0]
Tap – Subdimensionado	[0; 0; 0; 0; 0; 0; 1; 0; 0]
Tap – Sobredimensionado	[0; 0; 0; 0; 0; 0; 0; 1; 0]

Quadro 1. Padrão de saída relativo a cada problema causador de variação de tensão.

Fonte: Próprio autor.

É possível observar que o número de elementos dos vetores é igual ao número de padrões estabelecidos e que, além disso, é a posição do número 1 que caracteriza o padrão. A escolha por representar os padrões com vetores utilizando 0 ou 1, determina também o tipo de função de ativação a ser utilizada, pois como pode ser visto na seção 2.4.3, somente a função degrau e a função logística apresentam valores de saída entre 0 e 1. Para a arquitetura de rede utilizada (PMC), é necessário que se utilize a função logística.

O intervalo de tensão que caracteriza as amostras como normais foi definido a partir de testes empíricos. Sua faixa de atuação compreende amostras com tensões entre 120 e 133 V. Vale ressaltar que para as amostras trifásicas, caso uma das fases apresente valor fora desse intervalo, toda a mostra é considerada anormal.

Para determinar a porcentagem de acerto da rede, comparou-se os vetores através da função XOR (ou exclusivo). Com esta função, as células dos vetores que tem a mesma posição são comparadas, de forma que um outro vetor de tamanho igual aos vetores de padrão é gerado com a resposta da XOR usando a seguinte regra: se os valores das células forem iguais é retornado 0 (zero) e se os valores forem

diferentes é retornado 1, representando assim o acerto ou não da rede. Ao final desse processo, soma-se os elementos do vetor de resposta, tendo como resultado sempre um zero quando os vetores forem exatamente iguais. Isso é feito para cada amostra apresentada à rede e, para calcular a porcentagem final de acerto, verifica-se a quantidade de zeros obtidos e faz-se o cálculo através da equação (10).

$$\% \text{ Acerto} = \left(\frac{\text{quantidade de zeros}}{\text{quantidade total de amostras}} \right) \cdot 100 \quad (10)$$

O percentual de acerto é o que irá determinar qual topologia de rede obteve melhor resultado. O processo de comparação feito pela função XOR é exemplificado na Figura 9.

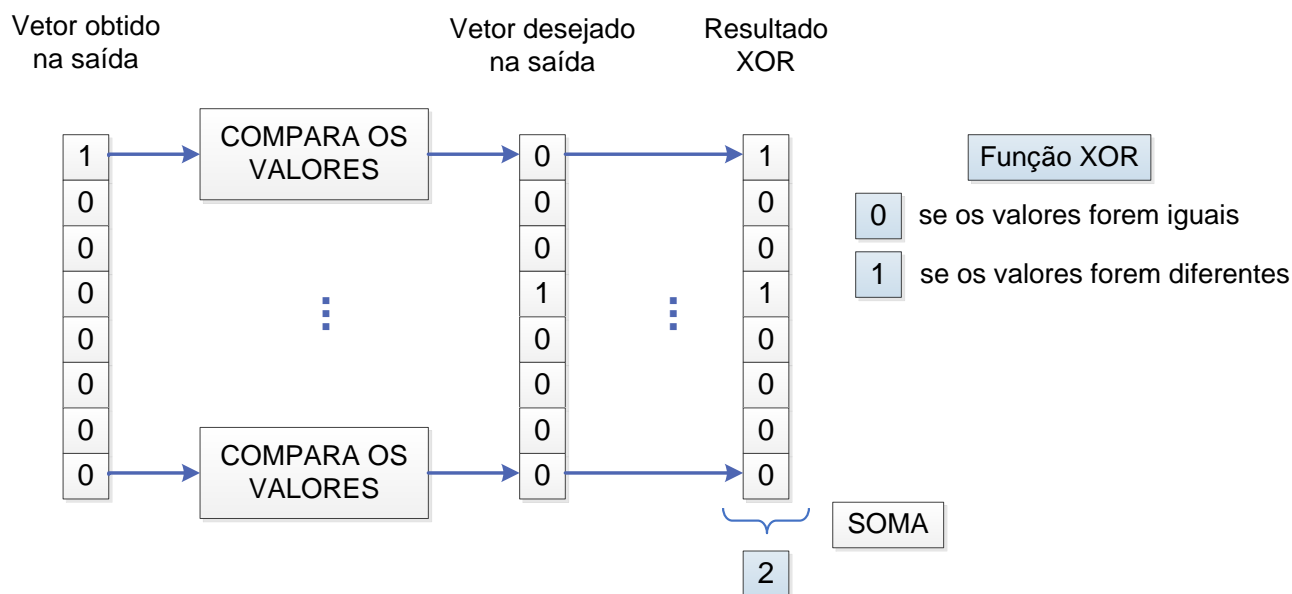


Figura 9. Exemplificação do funcionamento da função XOR utilizada para determinar a porcentagem de acerto da RNA.

Fonte: Próprio autor.

Os procedimentos citados anteriormente são comuns a todas as etapas realizadas. Em seguida serão apresentadas de forma mais específica cada uma delas, dentre as quais a principal diferença é a forma de apresentação dos dados na entrada da rede.

3.1. ENTRADA TRIFÁSICA

Para o modelo de rede com entrada trifásica, assim como em MEDEIROS (2015), utilizou-se três entradas, cada uma correspondendo a uma fase. Na saída foram usados 8 neurônios, correspondendo ao número de elementos dos vetores de padrão de saída, como mostrado no Quadro 1. O número de camadas intermediárias variou entre 1 e 2, enquanto que o número de neurônios nessas camadas variou de 1 a 10. Essas mudanças possibilitam uma análise de qual topologia apresenta melhor performance, mas vale ressaltar que neste trabalho prezou-se por utilizar redes mais compactas possíveis. A Figura 10 apresenta a topologia generalizada da RNA utilizada nesta etapa.

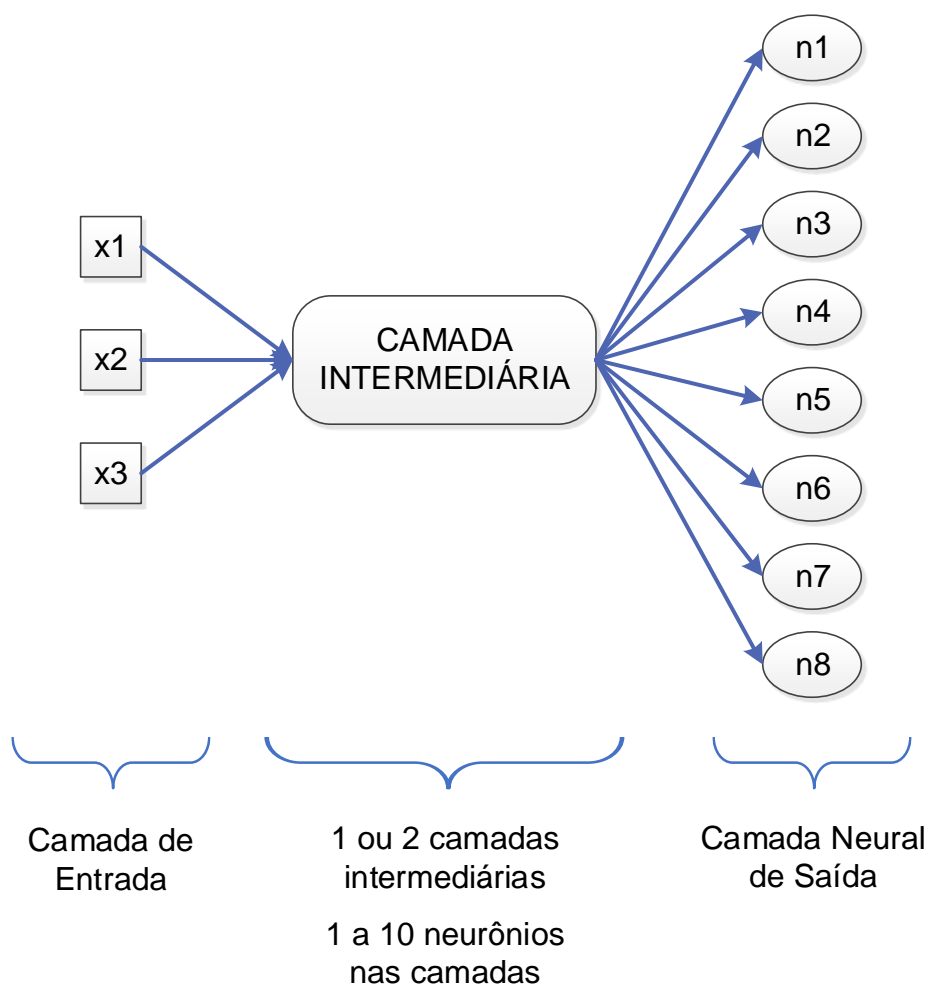


Figura 10. Representação da RNA utilizada para entrada trifásica: 3 entradas e 8 neurônios na saída.

Fonte: Próprio autor.

Após a obtenção da melhor topologia, testou-se essa rede com os dados de cada problema separadamente, a fim de verificar o comportamento individual de cada um deles.

Durante o treinamento a quantidade de amostras de tensão utilizadas para cada fase foi de 13624, enquanto que para o teste a quantidade total de amostras foi de 1480. A quantidade de amostras utilizadas no teste individual de cada problema é apresentada na seção Resultados e Discussões, bem como os resultados obtidos para cada teste realizado nesta etapa.

3.2. ENTRADA MONOFÁSICA

Para o modelo de rede com entrada monofásica alterou-se a forma de apresentação dos dados na entrada. Passou-se a utilizar apenas 1 entrada, enquanto o número de neurônios na saída continuou sendo 8. Manteve-se as alterações na quantidade de camadas intermediárias e de neurônios nessas camadas como feito para a entrada trifásica. A Figura 11 apresenta a topologia generalizada da rede utilizada nesta etapa.

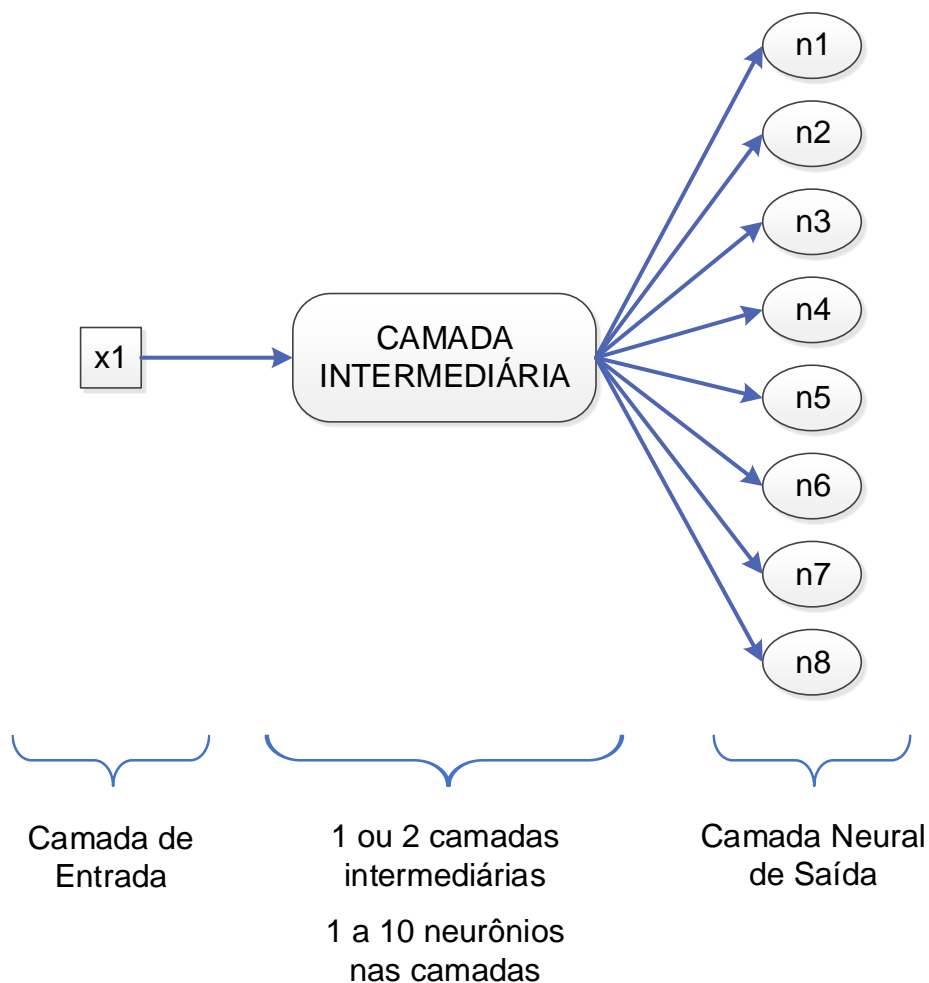


Figura 11. Representação da RNA utilizada para entrada monofásica: 1 entrada e 8 neurônios na saída.

Fonte: Próprio autor.

Para a entrada monofásica a apresentação dos dados para a rede é feita de forma individual para cada fase, diferentemente da entrada trifásica, onde os dados referentes a cada fase eram apresentados de forma simultânea. Para esta forma de apresentação individual, as amostras de treinamento de cada uma das fases foram agrupadas em um único vetor, tendo-se, dessa forma, todas as amostras da fase A, seguidas das amostras da fase B e fase C, respectivamente. Os dados desejados na saída são repetidos de forma a estarem alinhados com suas respectivas amostras de entrada. O modo que os dados utilizados tanto na entrada, quanto os desejados na saída, foram dispostos, é apresentado na Figura 12.

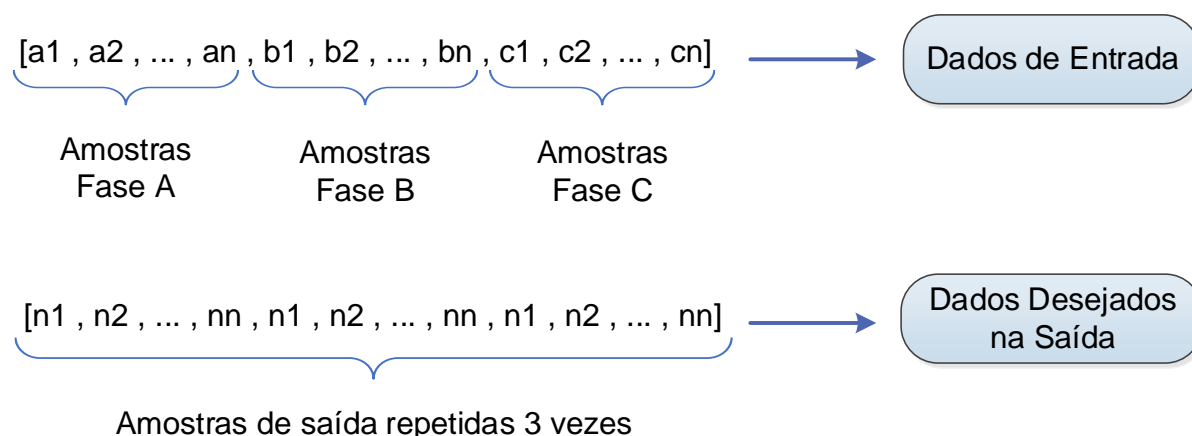


Figura 12. Representação do arranjo dos dados de entrada e desejados na saída utilizados para a RNA de entrada monofásica.

Fonte: Próprio autor.

Outra diferença entre a entrada trifásica e a monofásica é que, para a entrada trifásica, quando uma das fases da amostra apresentava valor fora da faixa de tensão estabelecida como normal, a amostra toda era considerada como anormal. Já para a entrada monofásica, como se está analisando separadamente cada fase, fez-se uma restrição após carregar os dados. Tanto para os dados de treinamento, quanto para os dados de teste, se o valor da amostra de entrada estiver dentro da faixa de tensão estabelecida como normal, sua respectiva saída desejada recebe o vetor correspondente à condição normal, caso contrário, mantém o vetor original de problema.

Nesta etapa, portanto, o treinamento é feito com os dados das três fases de uma única vez. O teste, entretanto, é realizado separadamente para cada uma das fases. São carregados os dados de teste de cada uma delas e faz-se a restrição que leva em consideração a faixa de tensão atribuída como normal. Vale ressaltar que, neste caso, o vetor referente à condição normal é alocado, quando necessário, nos dados desejados de saída e não na saída real da rede. Tem-se, dessa forma, ao final do teste, três porcentagens de acerto, cada uma referente a uma das fases, o que possibilita uma análise particular da influência de cada uma nos problemas.

Dado o exposto anteriormente, é possível verificar que a quantidade de amostras utilizadas durante o treinamento para a entrada monofásica é três vezes maior que a quantidade utilizada para a entrada trifásica, já para o teste a quantidade

de amostras se mantem a mesma. Sendo assim, a quantidade de amostras de tensão utilizadas no treinamento foi de 40872 e no teste 1480 por fase.

Após a obtenção da melhor topologia para este tipo de entrada, testou-se essa rede com os dados de cada problema separadamente, a fim de verificar de forma individual como a rede classifica padrões apresentados a ela.

Os resultados obtidos para cada teste realizado nesta etapa são apresentados na seção Resultados e Discussões.

3.3. ENTRADA JANELADA

Para o modelo de rede com entrada janelada utilizou-se redes especialistas, uma para cada problema citado no Quadro 1. A escolha por utilizar redes especialistas justifica-se por diminuir a complexidade da rede, uma vez que esta é aumentada pelo janelamento dos dados de entrada.

Usando o mesmo conjunto de dados das etapas anteriores, fez-se, primeiramente, uma alteração nos vetores desejados na saída, a fim de adequar os padrões às redes especialistas, ou seja, tratando especificamente de apenas um problema. Alterou-se a saída desejada respectiva a cada amostra, tanto para os dados de treinamento, quanto para os dados de teste. Ao invés de utilizar um vetor de 8 posições para determinar os padrões de saída, utilizou-se somente um valor:

- 1 – Se o vetor de saída corresponder ao problema da rede especialista;
- 0 – Se o vetor de saída corresponder a qualquer outro problema ou à condição normal.

Dessa forma, tem-se uma rede com apenas 1 neurônio na saída. Após essa fase, fez-se o janelamento dos dados, com janelas de 6 amostras e passo de 1 amostra. Para cada janela, verifica-se pelo vetor de saída, se as amostras correspondem à condição normal (amostras que não pertencem ao problema que a rede especialista aborda) ou anormal (amostras que pertencem ao problema que a rede especialista aborda), como apresentado na Figura 13. Se uma das 6 amostras da janela apresentar condição anormal, a janela toda é considerada anormal e o vetor desejado na saída correspondente àquela janela recebe o valor 1. Se todas as 6

amostras da janela apresentarem condição normal, o vetor desejado na saída correspondente à janela recebe valor 0.

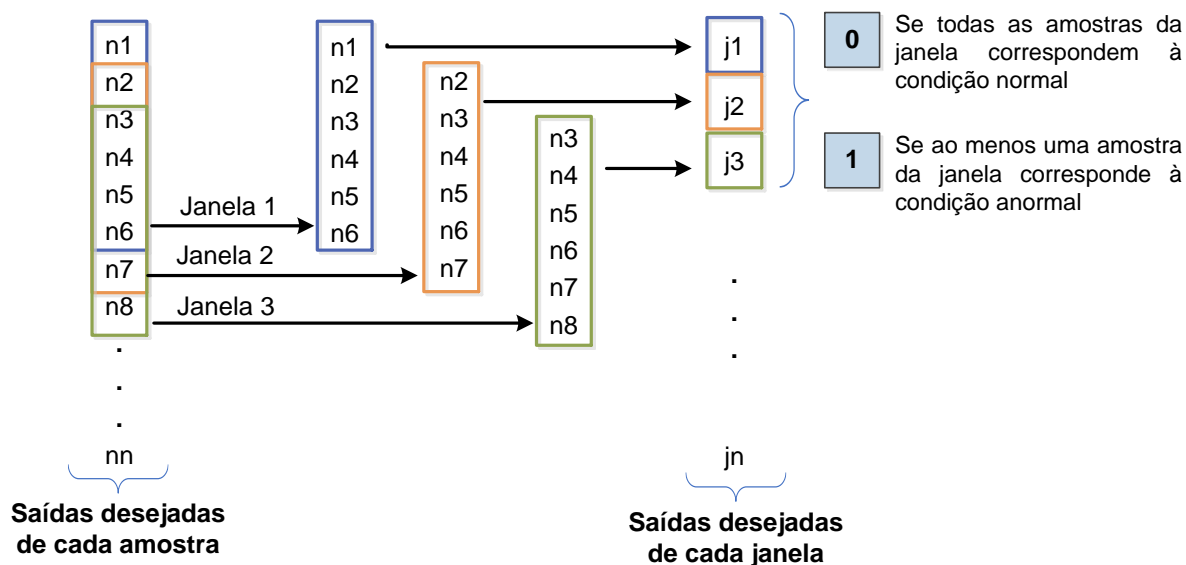


Figura 13. Representação do arranjo dos dados desejados na saída utilizados para a RNA de entrada janelada.

Fonte: Próprio autor.

O janelamento traz também alterações na forma de apresentação dos dados na entrada da rede. Ao invés de apenas 1 ou 3 entradas, como era feito nas etapas anteriores, a rede passa a ter 18 entradas, pois apresenta-se de forma simultânea 6 amostras de cada fase, o que corresponde a um intervalo de 60 minutos de medição. A Figura 14 apresenta a topologia generalizada da rede utilizada nesta etapa.

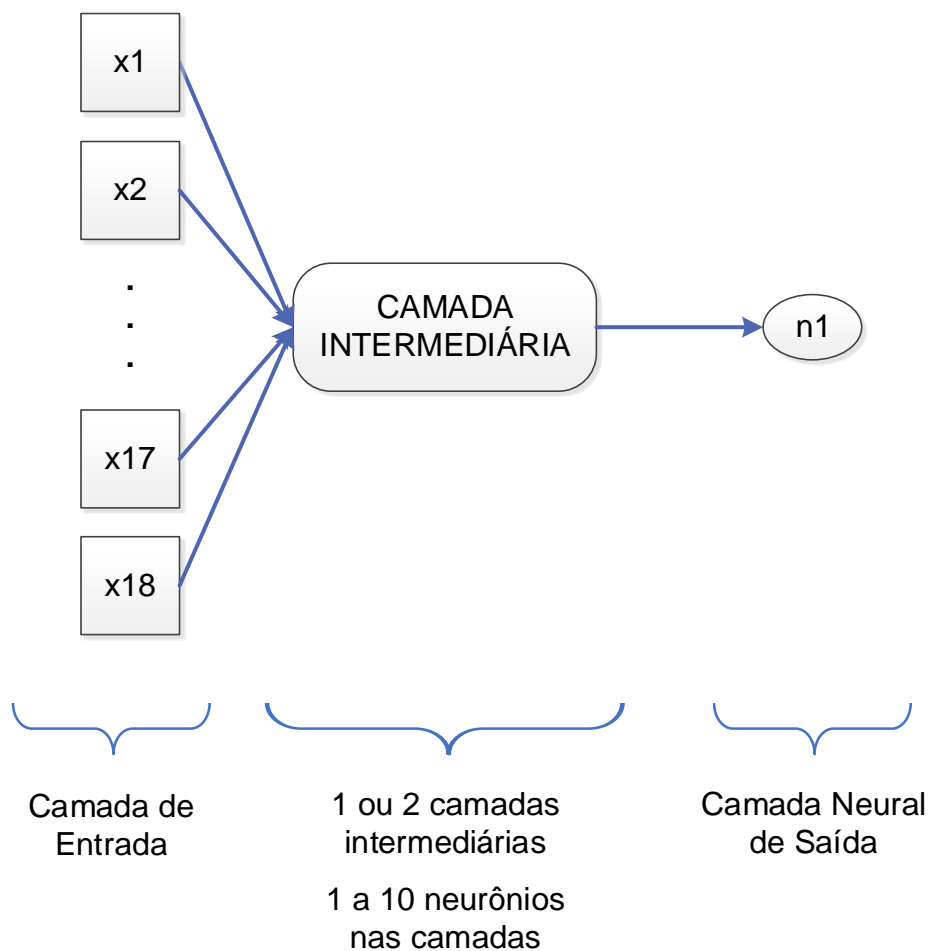


Figura 14. Representação da RNA utilizada para entrada janelada: 18 entradas e 1 neurônio na saída.

Fonte: Próprio autor.

Como pode ser visto mais detalhadamente na Figura 15, a entrada da rede é composta por 6 amostras da fase A, seguidas de 6 amostras da fase B e 6 amostras da fase C, correspondendo à uma janela de cada fase e somando assim 18 entradas. Pela Figura 14 observa-se que a saída apresenta apenas um neurônio, uma vez que as redes especialistas tratam os dados somente como normais ou anormais. Assim, como para os demais tipos de entrada, o número de camadas intermediárias variou entre 1 e 2, enquanto o número de neurônios nessas camadas variou de 1 a 10.

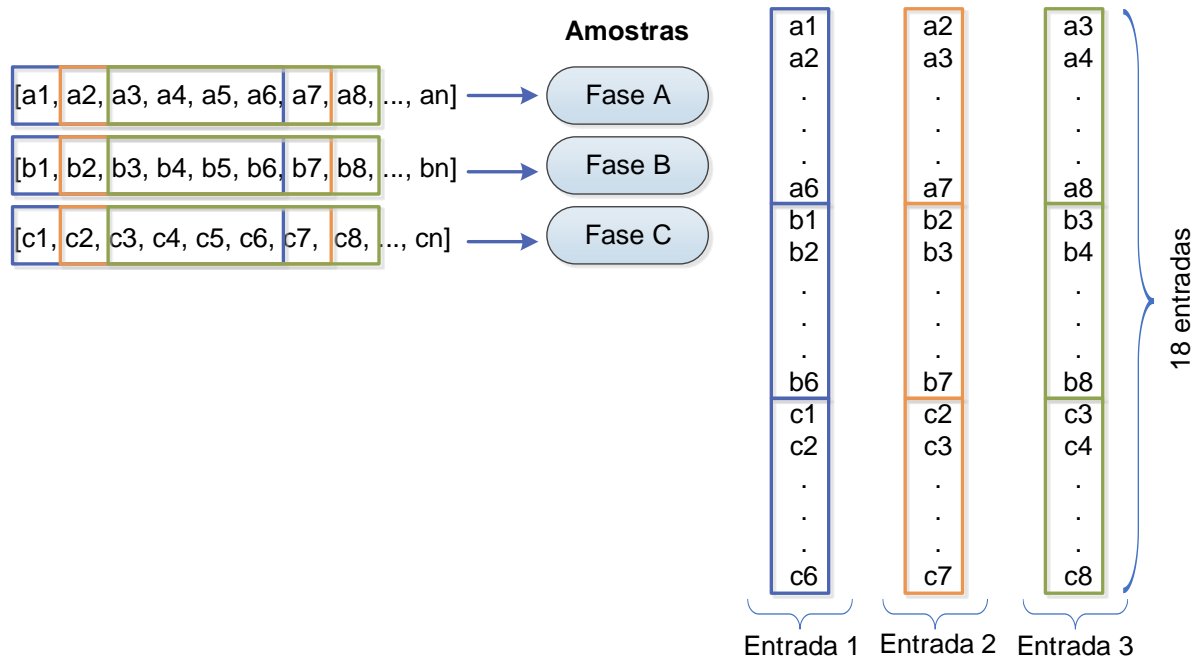


Figura 15. Representação do arranjo dos dados de entrada utilizados para a RNA de entrada janelada.
Fonte: Próprio autor.

Com o janelamento dos dados, a quantidade de amostras utilizadas no treinamento foi de 13619, enquanto que a quantidade utilizada no teste foi de 1475.

Estes procedimentos foram repetidos para cada rede especialista e os resultados obtidos para cada teste realizado nesta etapa são apresentados na seção Resultados e Discussões.

3.4. DIFERENTES NÍVEIS DE TENSÃO

As redes com entrada trifásica, monofásica e janelada foram testadas com dados de tensão em baixa tensão (BT). A fim de verificar a aplicabilidade dessas redes com diferentes níveis de tensão, adicionou-se ao conjunto de dados utilizado anteriormente valores de tensão em média tensão (MT).

Os dados em MT também foram fornecidos pela CPFL e correspondem à diferentes problemas, com tensões de ligação diversas. As amostras desses dados

foram separadas de forma a utilizar dados distintos no treinamento e no teste. A Tabela 1 apresenta as especificações dos dados em MT.

Tabela 1. Especificação dos dados de média tensão.

	Padrão	Tensão Nominal (V_N) [V]	Quantidade de Amostras
Treinamento	Sobrecarga	13800	1176
	Ajuste RT	11400	1087
	Normal	12000	1840
Teste	Sobrecarga	13200	1033
	Ajuste RT	11400	1087
	Normal	13800	1033

Para que a rede possa processar os diferentes dados corretamente, todos eles foram passados para o sistema pu. Nesse sistema os valores das amostras de tensão são normalizados em relação a valores base (V_{base}) pré-estabelecidos e, assim, todos eles passam a apresentar um mesmo nível de tensão. O cálculo utilizado para a obtenção dos valores em pu (V_{pu}) é apresentado na equação (11).

$$V_{pu} = \frac{\text{amostra de tensão}}{V_{base}} \quad (11)$$

Os dados em BT utilizam como base o valor eficaz de tensão, medido entre fase e neutro, que deve ser entregue ao consumidor (127 V). Já os dados em MT utilizam bases diferentes, uma vez que apresentam valores nominais diversos, como pode ser visto na Tabela 1. Esses valores nominais são valores de tensão de linha (V_L), ou seja, medidos entre fases. Para normalizar corretamente esses dados, utilizou-se como base a tensão de fase (V_F), ou seja, tensão entre fase e neutro, calculada por $V_L/\sqrt{3}$. Sendo assim, a obtenção dos valores de base para cada tensão nominal é feita pela equação (12).

$$V_{base} = \frac{V_N}{\sqrt{3}} \quad (12)$$

Dessa forma, para cada amostra de tensão, foi calculado seu valor em pu, levando em consideração sua respectiva base e, além disso, analisou-se se os valores estavam dentro da faixa estabelecida como normal. Esta faixa foi definida considerando o intervalo determinado para BT (120 a 133 V). Este intervalo também foi transformado para pu utilizando sua base (127 V) e, dessa forma, todas as demais amostras foram classificadas como normais ou anormais de acordo com o intervalo 0,9449 a 1,0472 pu.

Se a amostra for classificada como normal, o vetor desejado na saída recebe o vetor correspondente ao padrão normal. Caso contrário, recebe o vetor relativo ao problema ao qual a amostra pertence. Vale ressaltar que para os casos em que se utiliza as 3 fases simultaneamente, se uma das fases da amostra for classificada como anormal, a amostra toda é considerada anormal. Para os casos em que se utiliza separadamente cada fase, essa classificação é feita de forma individual.

Após a transformação para pu e a classificação da amostra quanto à faixa considerada normal, agrupou-se todos os dados (BT e MT) em um único arquivo. Dessa forma, a quantidade final de amostras utilizadas no treinamento foi de 17727 e a quantidade de amostras utilizadas no teste foi de 4633.

Os testes utilizando dados de diferentes níveis de tensão foram feitos com a melhor topologia de cada tipo de rede, a qual foi definida a partir dos testes feitos anteriormente onde tem-se a porcentagem de acerto de cada configuração. A topologia com maior porcentagem de acerto é a que foi considerada como melhor.

Os resultados obtidos para cada teste realizado nesta etapa são apresentados na seção Resultados e Discussões.

4. RESULTADOS E DISCUSSÕES

4.1. ENTRADA TRIFÁSICA

Após realizar os 10 treinamentos com cada topologia de rede, analisou-se qual deles apresentava menor erro quadrático médio (MSE) e, assim, determinou-se a melhor configuração de rede para realizar os testes.

A Tabela 2 apresenta o percentual de acerto obtido no teste para cada topologia testada, demonstrando a quantidade de entradas, de camadas intermediárias e o número de neurônios nessas camadas, bem como o número de neurônios na saída. A topologia [3 1 1 8], por exemplo, apresenta três entradas, duas camadas intermediárias, cada uma com um neurônio e 8 neurônios na saída.

Tabela 2. Relação das topologias testadas na rede com entrada trifásica e porcentagem de acerto obtida na fase de teste.

Topologia	Acerto no Teste (%)
[3 1 8]	70,1351
[3 2 8]	70,7432
[3 3 8]	90,5405
[3 4 8]	96,1486
[3 5 8]	96,1486
[3 6 8]	94,1216
[3 7 8]	95,7432
[3 8 8]	97,0946
[3 9 8]	95,0676
[3 10 8]	94,9324
[3 1 1 8]	70,0676
[3 1 8 8]	90,9459

É possível observar que a topologia [3 8 8], com 97,0946% de acerto, é a que apresenta melhor resultado dentre todas as configurações testadas. Esta topologia foi utilizada para testar a rede separadamente para cada problema, além da verificação feita com os dados de diferentes níveis de tensão.

Pela Tabela 2 percebe-se que ao aumentar a complexidade da rede (aumentar de 1 para 2 o número de camadas intermediárias), o percentual de acerto diminui consideravelmente em relação a topologias mais compactas, só voltando a aumentar quando aumentou-se também o número de neurônios nas camadas intermediárias, o que não é o indicado, uma vez que este trabalho visa utilizar redes mais compactas possíveis.

A Tabela 3 apresenta os resultados obtidos na simulação feita com a rede de entrada trifásica, apresentando os dados de teste de cada problema separadamente, utilizando a topologia que obteve o melhor resultado no teste geral ([3 8 8]), além de expor o número de amostras utilizadas para cada caso.

Tabela 3. Relação dos percentuais de acerto no teste feito com a rede de entrada trifásica para cada problema separadamente, utilizando a topologia [3 8 8].

Topologia	Número de Amostras	Acerto no Teste (%)
Sobrecarga	250	99,2000
Trafo Avariado	100	81,0000
Ajuste RT	340	99,4118
Falha em Conex.	100	91,0000
Ramal de Entr.	120	100,0000
TAP Subdim.	230	99,5652
TAP Sobredim.	340	97,0588

Observa-se que a rede obteve percentuais de acerto consideravelmente bons variando entre 81% e 100% de acerto para todos os problemas, apresentando um valor baixo apenas para o trafo avariado, 81% de acerto. Possivelmente, isso se deve ao fato do padrão apresentado por este problema ser muito aleatório, podendo se confundir com os demais padrões existentes. Além disso, têm-se poucas amostras de

tensão para este tipo de problema o que pode dificultar a generalização do mesmo e, conseqüentemente, a classificação do padrão.

De forma geral, os resultados obtidos nos testes feitos com a rede de entrada trifásica foram satisfatórios, comprovando a viabilidade de aplicação deste tipo de entrada na RNA, além de demonstrar a capacidade da rede em diferenciar os padrões de problema individualmente, como também a partir de um único teste.

4.2. ENTRADA MONOFÁSICA

Assim como para a rede de entrada trifásica, para a rede de entrada monofásica realizou-se 10 treinamentos com cada topologia e determinou-se a melhor configuração para realizar o teste, a partir do menor erro quadrático médio (MSE) dentre todos os treinamentos.

A Tabela 4 apresenta as topologias testadas para este tipo de rede e o percentual de acerto individual para cada fase obtido no teste, pois como já foi citado na seção 3.2, embora durante o treinamento sejam apresentados os dados de todas as fases para a rede, na etapa de testes, as amostras de cada fase são analisadas separadamente, a fim de se obter uma verificação particular de cada uma nos problemas.

A forma como as topologias são apresentadas nas tabelas seguem o mesmo padrão demonstrado na seção 4.1 para a entrada trifásica.

Tabela 4. Relação das topologias testadas na rede com entrada monofásica e porcentagem de acerto obtida no teste individualizado por fase.

Topologia	Acerto no Teste (%)		
	Fase A	Fase B	Fase C
[1 1 8]	73,3794	86,1486	92,8378
[1 2 8]	86,4189	91,8919	97,4324
[1 3 8]	86,3514	91,8919	97,4324
[1 4 8]	86,6892	91,9595	97,5000
[1 5 8]	86,9595	92,1622	97,7027
[1 6 8]	86,9595	92,1622	97,7027
[1 7 8]	94,1216	92,1622	93,0665
[1 8 8]	93,9189	92,0946	92,6141
[1 9 8]	93,4459	92,0946	97,7027
[1 10 8]	94,0541	92,2297	97,8378
[1 1 1 8]	73,3784	86,1486	92,8378
[1 1 8 8]	93,6486	92,2297	97,8378

Analisando a Tabela 4, é possível perceber que a configuração com melhor resultado é a [1 10 8], apresentando no teste 94,0541% de acerto para a fase A, 92,2297% de acerto para a fase B e 97,8378% de acerto para a fase C. Sendo assim, esta topologia foi utilizada para os testes individuais com cada problema, além da verificação feita com os dados de diferentes níveis de tensão. Assim como para a rede de entrada trifásica, não houve melhora significativa no percentual de acerto ao se aumentar o número de camadas intermediárias.

A Tabela 5 apresenta os resultados obtidos na simulação feita com a rede de entrada monofásica, apresentando os dados de teste de cada problema separadamente, utilizando a topologia que obteve o melhor resultado no teste geral ([1 10 8]). A quantidade de amostras utilizadas para cada problema são as mesmas apresentadas para a rede de entrada trifásica.

Tabela 5. Relação dos percentuais de acerto obtidos no teste feito com a rede de entrada monofásica para cada problema separadamente, utilizando a topologia [1 10 8].

Topologia	Acerto no Teste (%)		
	Fase A	Fase B	Fase C
Sobrecarga	76,4000	60,4000	92,4000
Trafo Avariado	95,0000	94,0000	94,0000
Ajuste RT	100,0000	99,4118	100,0000
Falha em Conexões	93,0000	93,0000	93,0000
Ramal de Entrada	86,6667	100,0000	100,0000
TAP Subdim.	99,5652	99,5652	100,0000
TAP Sobredim.	100,0000	100,0000	100,0000

Para as verificações feitas com a rede de entrada monofásica, observa-se percentuais de acerto consideravelmente bons, ficando, na maioria dos casos, acima dos 92% de acerto. Destaca-se também a melhora obtida no resultado do problema de trafo avariado em relação ao conseguido para a rede de entrada trifásica. Isso comprova a viabilidade de aplicação desse tipo de entrada em RNAs para classificação dos problemas propostos. Além disso, atende a solicitação da ANEEL de se fazer análises individuais por fase.

4.3. ENTRADA JANELADA

Da mesma forma que para as redes de entrada trifásica e monofásica, para a rede de entrada janelada realizou-se 10 treinamentos com cada topologia, verificou-se qual treinamento apresenta o menor erro quadrático médio (MSE) e assim, selecionou-se a melhor configuração de rede para realizar o teste.

A principal diferença deste tipo de rede em relação aos anteriores, é que se utilizaram redes especialistas, a fim de se diminuir a complexidade da rede e possibilitar resultados individuais para cada problema, os quais são apresentados da Tabela 6 a Tabela 12.

Tabela 6. Relação das topologias testadas na rede com entrada janelada e porcentagem de acerto obtida na fase de teste, utilizando rede especialista para o problema de sobrecarga.

SOBRECARGA	
Topologia	Acerto no Teste (%)
[18 1 1]	98,4407
[18 2 1]	98,4407
[18 3 1]	96,0678
[18 4 1]	95,7288
[18 5 1]	96,8814
[18 6 1]	96,6102
[18 7 1]	95,7966
[18 8 1]	96,4068
[18 9 1]	96,5424
[18 10 1]	96,8814
[18 1 1 1]	98,4407
[18 1 8 1]	95,9322

Na Tabela 6 é possível observar que a topologia [18 1 1] é a que apresenta melhor resultado, com um percentual de acerto de 98,4407%. Embora outras topologias tenham tido o mesmo resultado, assume-se essa como a melhor dentre elas, seguindo a regra de escolha da rede mais compacta possível. Sendo assim, essa será a topologia utilizada para a posterior verificação com os dados de diferentes níveis de tensão.

Tabela 7. Relação das topologias testadas na rede com entrada janelada e porcentagem de acerto obtida na fase de teste, utilizando rede especialista para o problema de trafo avariado.

TRAFO AVARIADO	
Topologia	Acerto no Teste (%)
[18 1 1]	95,7288
[18 2 1]	96,5424
[18 3 1]	98,2373
[18 4 1]	96,8814
[18 5 1]	96,8136
[18 6 1]	97,1525
[18 7 1]	96,8814
[18 8 1]	97,0169
[18 9 1]	98,7119
[18 10 1]	97,1525
[18 1 1 1]	96,0000
[18 1 8 1]	94,9153

Analisando a Tabela 7 percebe-se que a topologia [18 9 1] é a que apresenta melhor resultado, com um percentual de acerto de 98,7119%, sendo, portanto, a utilizada na verificação com os dados de diferentes níveis de tensão.

Tabela 8. Relação das topologias testadas na rede com entrada janelada e porcentagem de acerto obtida na fase de teste, utilizando rede especialista para o problema de ajuste RT.

AJUSTE RT	
Topologia	Acerto no Teste (%)
[18 1 1]	86,8475
[18 2 1]	86,4407
[18 3 1]	86,4407
[18 4 1]	82,2373
[18 5 1]	82,3051
[18 6 1]	84,4746
[18 7 1]	82,9831
[18 8 1]	80,8814
[18 9 1]	81,7627
[18 10 1]	81,8983
[18 1 1 1]	86,9831
[18 1 8 1]	73,6271

Pela Tabela 8 observa-se que a topologia [18 1 1 1] é a que apresenta melhor resultado, com um percentual de acerto de 86,9831%, porém, como a topologia [18 1 1] apresenta resultado muito similar (86,8475%), foi a escolhida a posterior verificação com os dados de diferentes níveis de tensão, por apresentar menor complexidade.

Tabela 9. Relação das topologias testadas na rede com entrada janelada e porcentagem de acerto obtida na fase de teste, utilizando rede especialista para o problema de falha em conexões.

FALHA EM CONEXÕES	
Topologia	Acerto no Teste (%)
[18 1 1]	64,0000
[18 2 1]	64,8814
[18 3 1]	84,9492
[18 4 1]	84,6102
[18 5 1]	87,3898
[18 6 1]	88,2034
[18 7 1]	88,6102
[18 8 1]	89,2203
[18 9 1]	88,8136
[18 10 1]	88,8136
[18 1 1 1]	63,5254
[18 1 8 1]	73,3559

Pelos dados obtidos na Tabela 9, é possível observar que a topologia [18 8 1] é a que apresenta melhor resultado, com um percentual de acerto de 89,2203%, sendo, portanto, a utilizada para posterior verificação com os dados de diferentes níveis de tensão.

Tabela 10. Relação das topologias testadas na rede com entrada janelada e porcentagem de acerto obtida na fase de teste, utilizando rede especialista para o problema de ramal de entrada.

RAMAL DE ENTRADA	
Topologia	Acerto no Teste (%)
[18 1 1]	76,5424
[18 2 1]	95,1864
[18 3 1]	97,1525
[18 4 1]	93,0847
[18 5 1]	97,5593
[18 6 1]	97,3559
[18 7 1]	97,8983
[18 8 1]	97,4915
[18 9 1]	96,8136
[18 10 1]	95,5932
[18 1 1 1]	76,5424
[18 1 8 1]	93,3559

Analisando os dados da Tabela 10, percebe-se que a topologia [18 7 1] é a que apresenta melhor resultado, com um percentual de acerto de 97,8983%, sendo a escolhida para verificar posteriormente os dados de diferentes níveis de tensão.

Tabela 11. Relação das topologias testadas na rede com entrada janelada e porcentagem de acerto obtida na fase de teste, utilizando rede especialista para o problema de TAP subdimensionado.

TAP SUBDIMENSIONADO	
Topologia	Acerto no Teste (%)
[18 1 1]	95,9322
[18 2 1]	98,2373
[18 3 1]	97,2881
[18 4 1]	97,1525
[18 5 1]	97,1525
[18 6 1]	97,5593
[18 7 1]	98,1695
[18 8 1]	97,9661
[18 9 1]	97,6271
[18 10 1]	97,6949
[18 1 1 1]	95,8644
[18 1 8 1]	97,9661

Na Tabela 11 é possível observar que a topologia [18 2 1] é a que apresenta melhor resultado, com um percentual de acerto de 98,2373%, sendo, portanto, utilizada para a verificação com os dados de diferentes níveis de tensão. Para este caso, a maioria das topologias apresentam percentuais de acerto similares, mas percebe-se que aumentar a complexidade da rede não melhora significativamente os resultados.

Tabela 12. Relação das topologias testadas na rede com entrada janelada e porcentagem de acerto obtida na fase de teste, utilizando rede especialista para o problema de TAP sobredimensionado.

TAP SOBREDIMENSIONADO	
Topologia	Acerto no Teste (%)
[18 1 1]	66,5085
[18 2 1]	83,8644
[18 3 1]	82,6441
[18 4 1]	97,8983
[18 5 1]	97,5593
[18 6 1]	97,0169
[18 7 1]	96,9492
[18 8 1]	97,1525
[18 9 1]	97,4915
[18 10 1]	97,2203
[18 1 1 1]	66,5085
[18 1 8 1]	91,6610

Os resultados da Tabela 12 demonstram que a topologia [18 4 1] é a que apresenta melhor resultado, com um percentual de acerto de 97,8983%, sendo a escolhida para a posterior verificação com os dados de diferentes níveis de tensão.

A Tabela 13 relaciona a melhor topologia de cada rede especialista, possibilitando uma análise geral dos melhores resultados obtidos pela rede de entrada janelada.

Tabela 13. Relação da melhor topologia de cada rede especialista, testadas com a rede de entrada janelada, com seu respectivo percentual de acerto no teste.

Rede Especialista	Melhor Topologia	Acerto no Teste (%)
Sobrecarga	[18 1 1]	98,4407
Trafo Avariado	[18 9 1]	98,7119
Ajuste RT	[18 1 1]	86,8475
Falha em Conex.	[18 8 1]	89,2203
Ramal de Entr.	[18 7 1]	97,8983
TAP Subdim.	[18 2 1]	98,2373
TAP Sobredim.	[18 4 1]	97,8983

Dentre todos os casos abordados na Tabela 13, o melhor resultado foi obtido para o problema de trafo avariado, com 98,7119% de acerto no teste, enquanto que o pior caso foi o do problema de ajuste RT, que apresentou 86,8475% de acerto. De forma geral, as redes especialistas apresentaram excelentes resultados, demonstrando que elas responderam bem aos dados janelados e comprovando a viabilidade de aplicação deste tipo de rede.

4.4. DIFERENTES NÍVEIS DE TENSÃO

Após realizar os testes com as redes de entrada trifásica, monofásica e janelada com dados de tensão em BT, variando o número de camadas intermediárias e o número de neurônios nessas camadas, selecionou-se as topologias com maior percentual de acerto de cada caso para realizar testes com dados de diferentes níveis de tensão. A Tabela 14 relaciona, para todos os casos abordados anteriormente, essas melhores topologias, seus respectivos erros obtidos no melhor treinamento e os percentuais de acerto no teste.

Tabela 14. Relação das melhores topologias de rede, para cada tipo de entrada, e seus respectivos percentuais de acerto, para os testes feitos com os dados em BT.

Tipo de Entrada		Melhor Topologia	Acerto no Teste (%)		
	Trifásica	[3 8 8]	97,0946		
	Monofásica	[1 10 8]	94,0541	92,2297	97,8378
	Sobrecarga	[18 1 1]	98,4407		
	Trafo Avariado	[18 9 1]	98,7119		
	Ajuste RT	[18 1 1]	86,8475		
Janelada	Falha em Conex.	[18 8 1]	89,2203		
	Ramal de Entr.	[18 7 1]	97,8983		
	TAP Subdim.	[18 2 1]	98,2373		
	TAP Sobredim.	[18 4 1]	97,8983		

Com todos os dados de tensão transformados para o sistema pu, utilizando o mesmo código das etapas anteriores, fez-se os testes para cada tipo de entrada com os dados de diferentes níveis de tensão. Os resultados obtidos estão apresentados na Tabela 15.

Tabela 15. Relação dos resultados obtidos testando as melhores topologias de rede com os dados de diferentes níveis de tensão, apresentando os respectivos percentuais de acerto no teste.

Tipo de Entrada		Melhor Topologia	Acerto no Teste (%)		
	Trifásica	[3 8 8]	94,6675		
	Monofásica	[1 10 8]	89,2055	92,0337	92,3575
	Sobrecarga	[18 1 1]	100,0000		
	Trafo Avariado	[18 9 1]	71,4070		
	Ajuste RT	[18 1 1]	77,7826		
Janelada	Falha em Conex.	[18 8 1]	80,5490		
	Ramal de Entr.	[18 7 1]	95,9585		
	TAP Subdim.	[18 2 1]	98,5736		
	TAP Sobredim.	[18 4 1]	94,2079		

Os resultados apresentados na Tabela 15 são bastante satisfatórios e permitem comprovar que é possível analisar amostras de diferentes níveis de tensão simultaneamente a partir de uma mesma rede, utilizando-se o sistema pu para normalizar os dados. Os percentuais de acerto mais baixos demonstrados neste caso podem ser justificados pela pouca quantidade de amostras que se dispõe atualmente para os dados em MT, necessitando, portanto, de uma quantidade maior para testes futuros.

Sugere-se também que em trabalhos futuros sejam feitos testes com redes especializadas para cada nível de tensão.

5. CONSIDERAÇÕES FINAIS

Os estudos realizados sobre qualidade de energia demonstram que as perdas financeiras a ela associadas são motivo de grande interesse na melhoria contínua do fornecimento de energia elétrica. Por parte dos consumidores, com a utilização de equipamentos cada vez mais sensíveis, essas perdas se tornam importantes quando interrupções, ou até mesmo variações na tensão durante o fornecimento de energia, começam a acarretar grandes prejuízos nos processos de produção em indústrias, falhas no atendimento ou má operação dos equipamentos de clientes comerciais. Por parte das concessionárias, no Brasil, as regulamentações propostas pela ANEEL a partir de 2015, as quais extinguem o prazo de regularização dos níveis de tensão quando estes forem inadequados, aplicando penalizações até que o problema seja resolvido, reforçam a busca por um maior controle do sistema elétrico e uma resposta mais rápida aos problemas inerentes ao fornecimento de energia.

A ferramenta proposta nesse trabalho é uma alternativa para as distribuidoras de energia elétrica, a ser utilizada como auxiliar no diagnóstico dos problemas que causam variação de tensão, uma vez que o sistema de análise utilizado atualmente não fornece uma classificação clara dos problemas, além de exigir muita experiência do profissional que avalia os dados para definição dos mesmos.

Os resultados obtidos foram bastante satisfatórios, o que demonstra a viabilidade da aplicação de redes neurais artificiais para análise de dados que apresentam problemas no nível de tensão em regime permanente, permitindo, assim, auxiliar as concessionárias de energia no processo de detecção desses problemas, proporcionando uma solução mais rápida e eficiente dos mesmos, diminuindo, dessa forma, os gastos com penalizações pagas a ANEEL, ressarcimentos aos consumidores e até mesmo manutenções desnecessárias.

Os objetivos propostos para este trabalho foram atendidos, conseguindo treinar e testar diferentes topologias de redes com entradas do tipo trifásica, monofásica e janelada, além das verificações feitas com dados de diferentes níveis de tensão. Com base nos resultados obtidos, observa-se que a rede de entrada trifásica obteve, em média, um percentual de acerto no teste de 88,4741%, enquanto que para a rede de entrada monofásica, esse percentual médio, considerando-se todas as fases juntas, foi de 91,5279%. Já para a rede com entrada janelada, a média de acerto atingida no

teste, considerando-se todas as redes especialistas, foi de 95,3220%, sendo, portanto, o melhor resultado obtidos dentre todos os tipos de entrada testados. Para a verificação dessas redes com os dados de diferentes níveis de tensão, levando-se em consideração que esses dados foram testados com a melhor topologia de cada tipo de entrada, obteve-se uma média de acerto de 89,3717%. De forma geral, os resultados obtidos para os dados de diferentes níveis de tensão apresentaram percentuais de acerto mais baixos que para os testes feitos somente com os dados em BT, possivelmente pela pouca quantidade de amostras para esse caso.

Como perspectiva para trabalhos futuros, pretende-se conseguir mais amostras de tensão para realizar outros testes e verificar o comportamento das redes, como por exemplo, aplicar redes especialistas para diferentes níveis de tensão. Além disso, visa-se desenvolver um *software* ou *hardware* para aplicação profissional da ferramenta proposta neste trabalho.

REFERÊNCIAS

ALDABÓ, Ricardo. **Qualidade na energia elétrica**. São Paulo: Artliber Editora, 2001.

ANEEL (2015). **Distribuição de Energia Elétrica**. Disponível em:
<<http://www.aneel.gov.br/area.cfm?idArea=77>> Acesso em: 25 out 2015.

BARBON, Sylvio. (2013). **RNA – Perceptron Multicamadas**. Disponível em:
<http://www.barbon.com.br/wp-content/uploads/2013/08/RNA_Aula5.pdf> Acesso em: 08 nov 2015.

BARRA, Fernanda. (2013). **Redes neurais artificiais**. Disponível em:
<<http://blogdopetcivil.com/2013/07/05/redes-neurais-artificiais/>>. Acesso em: 7 nov 2015.

BARROS, Benjamin F.; BORELLI, Reinaldo; GEDRA, Ricardo L. **Gerenciamento de Energia: ações administrativas e técnicas de uso adequado da energia elétrica**. 1 ed. São Paulo: Érica, 2010.

BITTENCOURT, Guilherme. **Inteligência artificial: ferramentas e teorias**. 3 ed. Florianópolis: Ed. da UFSC, 2006.

BRUMATTI, Marcos. **Redes Neurais Artificiais**. Departamento de Engenharia Elétrica - Universidade Federal do Espírito Santo.

COPPIN, Ben. **Inteligência Artificial**. Traduzido e revisão por Jorge Duarte Pires Valério. Rio de Janeiro: LTC, 2012.

DOROCHE, M. R.; ANSCHAU, C. T. **Oferta de energia elétrica no Brasil**. Tecnológica: Revista Científica UCEFF. Chapecó, 2015.

DUGAN, Roger C.; MCGRANAGHAN, Mark F.; BEATY, Wayne H.; SANTOSO Surya. **Electrical power systems quality**. 2. ed. New York: McGraw-Hill, 2003.

FERREIRA, Danton Diego. **Análise de Distúrbios Elétricos em Sistemas de Potência**. Rio de Janeiro: UFRJ/COPPE, 2010.

HAYKIN, Simon. **Redes neurais: princípios e práticas**. 2. ed. Porto Alegre: Bookman, 2001.

MEDEIROS, Vinícios Thomaz. **Identificação das fontes geradoras dos problemas que causam variações de tensão de longa duração utilizando redes neurais artificiais**. 2015. 64 f. Trabalho de Conclusão de Curso em Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2015.

PET ENGENHARIA CIVIL UFJF (2013). Redes Neurais Artificiais. Disponível em: <<https://blogdopetcivil.com/2013/07/05/redes-neurais-artificiais/>> Acesso em: 07 nov 2015.

PROCEDIMENTOS DE DISTRIBUIÇÃO. **PRODIST**. Módulo 8, ANEEL, Revisão 4, 2012.

PROCEDIMENTOS DE DISTRIBUIÇÃO. **PRODIST**. Módulo 8, ANEEL, Revisão 6, 2015.

PROCEDIMENTOS DE DISTRIBUIÇÃO. **PRODIST**. Módulo 8, ANEEL, Revisão 7, 2016.

PROCEDIMENTOS DE DISTRIBUIÇÃO. **PRODIST**. Módulo 8, ANEEL, Revisão 8, 2017.

REZENDE, Solange O. **Sistemas Inteligentes: Fundamentos e Aplicações**. Barueri: Manole, 2005.

SILVA, Ivan. N.; SPATTI, Danilo. H; FLAUZINO, Rogério. A. **Redes Neurais Artificiais: para Engenharia e Ciências Aplicadas**. 1. ed. São Paulo: Artliber Editora Ltda, 2010.

YU, H. WILAMOWSKI, B. M. **Levenberg–Marquardt Training**. Auburn University, 2010.