

UNIVERSIDADE DE SÃO PAULO - USP
ESCOLA DE ENGENHARIA DE SÃO CARLOS - EESC
DEPARTAMENTO DE ENG. ELÉTRICA E DE COMPUTAÇÃO - SEL
LABORATÓRIO DE SISTEMAS DE ENERGIA ELÉTRICA - LSEE

Rodolfo Takeshi Ota

**O monitoramento remoto das situações de curtos-circuitos
em um sistema de distribuição via redes neurais artificiais
considerando diferentes topologias e perfis de carga**

São Carlos

2017

RODOLFO TAKESHI OTA

**O monitoramento remoto das situações de
curtos-circuitos em um sistema de
distribuição via redes neurais artificiais
considerando diferentes topologias e perfis
de carga**

Trabalho de Conclusão de Curso apresentado à
Escola de Engenharia de São Carlos, da
Universidade de São Paulo

Curso de Engenharia Elétrica com Ênfase em
Sistemas de Energia e Automação

ORIENTADOR: Prof. Dr. Mário Oleskovicz

São Carlos

2017

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

087o

Ota, Rodolfo Takeshi

O monitoramento remoto das situações de curtos-circuitos em um sistema de distribuição via redes neurais artificiais considerando diferentes topologias e perfis de carga / Rodolfo Takeshi Ota; orientador Mário Oleskovicz. São Carlos, 2017.

Monografia (Graduação em Engenharia Elétrica com ênfase em Sistemas de Energia e Automação) -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2017.

1. Sistemas de distribuição. 2. Qualidade da energia elétrica. 3. Redes neurais artificiais. 4. Monitoramento remoto. I. Título.

FOLHA DE APROVAÇÃO

Nome: Rodolfo Takeshi Ota

Título: "O monitoramento remoto das situações de curtos-circuitos em um sistema de distribuição via redes neurais artificiais considerando diferentes topologias e perfis de carga"

Trabalho de Conclusão de Curso defendido e aprovado
em 23/11/2017,

com NOTA 9,25 (nove vínte e cinco), pela Comissão Julgadora:

Prof. Associado Mário Oleskovicz - Orientador - SEL/EEESC/USP

Mestre Carlos Henrique Beuter - Doutorando - SEL/EEESC/USP

Mestre Daniel Ferreira Lima - Doutorando - SEL/EEESC/USP

Coordenador da CoC-Engenharia Elétrica - EEESC/USP:
Prof. Associado Rogério Andrade Flauzino

Aos meus pais, Aparecida e Paulo e
à minha irmã Luciana por sempre me
apoarem nos momentos difíceis.

Agradecimentos

Ao Professor Dr. Mário Oleskovicz, por todo o apoio e incentivo durante a realização deste trabalho de conclusão de curso.

Ao Fernando Bambozzi Bottura, por todo o auxílio prestado durante a realização desta pesquisa e por mostrar-se disponível para ajudar.

Ao Daniel Lima, por todas as sugestões e dúvidas sanadas no decorrer desta pesquisa.

A todos os professores do Departamento de Engenharia Elétrica e de Computação pelo profissionalismo e dedicação, contribuindo de maneira significativa para minha formação.

SUMÁRIO

RESUMO	17
1 INTRODUÇÃO.....	21
1.1 JUSTIFICATIVA DO TRABALHO	22
1.2 OBJETIVOS DA PESQUISA	23
1.3 APRESENTAÇÃO DO DOCUMENTO	23
2 ESTUDOS CORRELATOS	25
3 METODOLOGIA DE PESQUISA	33
4 PERFIS DE CARGA CONSIDERADOS	35
5 REDES NEURAIS ARTIFICIAIS	43
5.1 SISTEMA NERVOSO HUMANO	43
5.2 O NEURÔNIO ARTIFICIAL	44
5.3 REDE PMC	45
5.4 UTILIZAÇÃO DAS RNAs VIA SOFTWARE	45
6 A SIMULAÇÃO COMPUTACIONAL.....	49
6.1 ANÁLISE DAS CONDIÇÕES DE SIMULAÇÃO	49
6.1.1 ASSOCIAÇÃO SÉRIE	49
6.1.2 ASSOCIAÇÃO PARALELO	50
6.1.3 FATOR DE POTÊNCIA	52
6.2 MODELAGEM DO SISTEMA DE DISTRIBUIÇÃO	53
6.2.1 CARGAS PREVIAMENTE MODELADAS.....	53
6.2.2 ANÁLISE DO SEP PREVIAMENTE MODELADO	56
6.2.3 CARGAS A SEREM MODELADAS.....	57
6.3 SIMULAÇÕES VIA O SOFTWARE ATP	59
7 APLICAÇÃO E TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS.....	65
7.1 O BANCO DE DADOS GERADO	65
7.2 A FASE DE TREINAMENTO DAS RNAs	67
7.2.1 MÉTODOS DE ABORDAGEM.....	68
8 A FASE DE TESTE DAS RNAs	75
8.1 TESTE ATRAVÉS DO MÉTODO ZERO	75
8.1.1 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 1 (M1)	75
8.2 TESTE ATRAVÉS DO MÉTODO 1	76
8.2.1 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 1 (M1)	76
8.2.2 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 2 (M2)	76
8.2.3 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 3 (M3)	77
8.2.4 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 4 (M4)	77

8.2.5 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 5 (M5)	78
8.2.6 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 6 (M6)	78
8.2.7 CONCLUSÕES PARCIAIS	79
8.3 TESTE DAS REDES ATRAVÉS DO MÉTODO 2	79
8.3.1 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 1 (M1)	79
8.3.2 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 2 (M2)	80
8.3.3 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 3 (M3)	80
8.3.4 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 4 (M4)	80
8.3.5 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 5 (M5)	81
8.3.6 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 6 (M6)	81
8.3.7 CONCLUSÕES PARCIAIS	81
8.4 TESTE DAS REDES ATRAVÉS DO MÉTODO 2 MODIFICADO	82
8.4.1 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 1 (M1)	82
8.5. TESTE DAS REDES ATRAVÉS DO MÉTODO 3	83
8.5.1 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 1 (M1)	83
8.5.2 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 2 (M2)	84
8.5.3 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 3 (M3)	84
8.5.4 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 4 (M4)	84
8.5.5 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 5 (M5)	84
8.5.6 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 6 (M6)	85
9. ANÁLISE DE DIFERENTES TOPOLOGIAS DE RNAs	87
9.1 TOPOLOGIA 6-20-25-1	87
9.2 TOPOLOGIA 6-25-25-1	87
9.3 TOPOLOGIA 6-25-30-1	87
9.4 TOPOLOGIA 6-30-30-1	87
9.5 TOPOLOGIA 6-30-35-1	88
9.6 TOPOLOGIA 6-35-35-1	88
9.7 TOPOLOGIA 6-50-50-1	88
9.8 ANÁLISE DOS RESULTADOS	89
10. CONCLUSÕES	93
10.1 TRABALHOS FUTUROS	94
REFERÊNCIAS BIBLIOGRÁFICAS	97
APÊNDICE A – Algoritmo para conversão dos arquivos .pl4 para .mat	101
CONVERSÃO DOS ARQUIVOS .PL4 PARA .MAT	101
APÊNDICE B - Algoritmo para coleta aleatória dos dados.....	102
APÊNDICE C – Tabelas complementares	103

LISTA DE FIGURAS

Figura 1 - Diagrama esquemático para o monitoramento da QEE.....	27
Figura 2 - Etapas seguidas para a metodologia de pesquisa.....	33
Figura 3 - Detalhes de execução das Etapas 4 e 5.....	34
Figura 4 - Consumo de energia elétrica de um consumidor residencial dividida por aparelho	36
Figura 5 - Consumo final na carga residencial.....	36
Figura 6 - Curva de carga diária média no Brasil.....	37
Figura 7 - Curva de carga de um consumidor residencial	37
Figura 8 - Curva de carga de um consumidor comercial	38
Figura 9 - Curva de carga de um consumidor residencial nos dias úteis	38
Figura 10 - Curva de carga de um consumidor residencial aos sábados	39
Figura 11 - Curva de carga de um consumidor residencial aos domingos	39
Figura 12 - Curva de carga de um consumidor comercial em dias úteis.....	39
Figura 13 - Curva de carga de um consumidor comercial aos sábados.....	40
Figura 14 - Curva de carga de um consumidor comercial aos domingos	40
Figura 15 - Curvas de carga do setor industrial.....	40
Figura 16 - Modelo matemático simplificado de um neurônio artificial.....	44
Figura 17 - Associação série de resistores e indutores.....	49
Figura 18 - Associação paralela de resistores e indutores.....	51
Figura 19 - Triângulo de potências.	52
Figura 20 - Distribuição geográfica do alimentador 1.	54
Figura 21 - Distribuição geográfica do alimentador 2.	54
Figura 22 - Modelo do diagrama unifilar do SD previamente modelado no ATP.....	55
Figura 23 - Divergências encontradas na modelagem previamente realizada.....	57
Figura 24 - Modelo do regulador de tensão implementado via ATP	59
Figura 25 - Posicionamento dos pontos de aplicação das situações de faltas, monitoramento e da subestação de energia no SD.....	61
Figura 26 - Exemplo de falta monofásica envolvendo a fase A com conexão a terra.....	61
Figura 27 - Exemplo de falta monofásica envolvendo a fase B com conexão a terra.....	62
Figura 28 - Exemplo de falta monofásica envolvendo a fase C com conexão a terra.....	62
Figura 29 - Parcelsa da forma de onda da tensão da fase A na subestação para o ponto de falta 1 (PF1), ângulo de incidência zero graus e falta franca.	66
Figura 30 - Janela deslizante aplicada sobre os sinais.....	66
Figura 31 - Rede neural do tipo 6-20-20-1 para a fase A. Fonte: Autoria própria, 2017	68
Figura 32 - Tensão eficaz da fase A da subestação para os diferentes tipos de curtos-circuitos considerados.....	70

Figura 33 - Banco de dados para o treinamento embaralhado, referente a tensão eficaz da fase A da subestação para o método 1.....	71
Figura 34 - Tensão eficaz da fase A da subestação para as cargas leve e pesada.	72
Figura 35 - Banco de dados de treinamento embaralhado, referente a tensão eficaz da fase A da subestação para o método 2.....	72
Figura 36 - Tensão eficaz da fase A da subestação para o método 3.	73
Figura 37 - Banco de dados de treinamento embaralhado, referente à tensão eficaz da fase A da subestação para o método 3.....	73
Figura 38 - Taxas de acertos de cada topologia de RNA para um erro < 0,01 p.u.....	89
Figura 39 - Taxas de acertos de cada topologia de RNA para um erro < 0,03 p.u.....	90
Figura 40 - Taxas de acertos de cada topologia de RNA para um erro < 0,05 p.u.....	90
Figura 41 - Taxas de acertos de cada topologia de RNA para um erro < 0,07 p.u.....	91
Figura 42 - Evolução das taxas de acertos das RNA para cada perfil de erro.....	91

LISTA DE TABELAS

Tabela 1 - Consumo de energia de consumidores residenciais	41
Tabela 2 - Consumo de energia de consumidores comerciais.....	41
Tabela 3 – Consumo de energia de consumidores industriais.....	42
Tabela 4 – Comandos para a criação de uma RNA via Matlab®.....	46
Tabela 5 - Principais funções utilizadas na implementação de RNAs via Matlab®.....	46
Tabela 6 - Principais algoritmos de treinamento das RNAs.....	47
Tabela 7 - Descrição dos parâmetros de treinamento das RNAs via Matlab®.	47
Tabela 8 – Critérios de modelagem das novas cargas	58
Tabela 9 - Tempos de abertura e fechamento das chaves.....	63
Tabela 10 - Quantidade de casos por ponto de falta.....	63
Tabela 11 - RNAs utilizadas em cada ponto de monitoramento.	68
Tabela 12 – Banco de dados de treinamento e teste utilizados em cada método.	69
Tabela 13 - Parâmetros de treinamento das RNAs.....	71
Tabela 14 - Erro das fases A, B e C do ponto de monitoramento 1 para as cargas média, leve e pesada do método zero.	75
Tabela 15 - Erro das fases A, B e C do ponto de monitoramento 1 para as carga média, leve e pesada do método 2 modificado.	82
Tabela 16 - Erro das fases A, B e C do ponto de monitoramento 1 das carga média, leve e pesada do método 3.	83
Tabela 17 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-50-50-1.	88
Tabela 18 – Dados das cargas modeladas	103
Tabela 19 – Potência ativa e reativa modeladas.	104
Tabela 20 – Valores médios das cargas.....	106
Tabela 21 – Valores máximos das cargas.....	107
Tabela 22 – Valores mínimos das cargas	109
Tabela 23 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-20-25-1.	110
Tabela 24 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-25-25-1.	112
Tabela 25 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-25-30-1	113

Tabela 26 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-30-30-1	115
Tabela 27 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-30-35-1	117
Tabela 28 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-35-35-1	118

RESUMO

OTA, R. T. O monitoramento remoto das situações de curtos-circuitos em um sistema de distribuição via redes neurais artificiais, considerando diferentes topologias e perfis de carga. 2017. 120f. Trabalho de Conclusão de Curso, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, Brasil, 2017.

A crescente preocupação com a eficiência energética, a automatização e integração dos processos no cenário atual vem sendo caracterizado por um considerável aumento no número de equipamentos sensíveis e propícios a gerar problemas de qualidade da energia elétrica. Dessa forma, é essencial assegurar o fornecimento de energia elétrica dentro dos padrões de qualidade, que somente poderá ser garantida através de um monitoramento eficaz e contínuo das grandezas de interesse, dentre as quais a tensão trifásica do sistema de distribuição em diversos pontos. Nesse contexto, o presente trabalho de conclusão de curso visa apresentar um método alternativo de monitoramento remoto utilizando redes neurais artificiais para estimar os valores das tensões trifásicas em diversos pontos de um sistema de distribuição, levando em consideração diferentes perfis de carga que o sistema possa vir a apresentar, além da proposta de diferentes topologias e análise de desempenho das redes modeladas, a fim de se obter resultados cada vez mais precisos. A obtenção das redes neurais artificiais será possibilitada pela modelagem de um sistema de distribuição real que fornecerá os dados necessários para o treinamento e validação dos resultados obtidos durante a pesquisa. Os resultados observados foram satisfatórios e definem a metodologia de treinamento e topologia ótima das redes neurais frente ao problema de qualidade da energia elétrica abordado, demonstrando a viabilidade da aplicação desta tecnologia.

Palavras chave: Sistemas de distribuição. Qualidade da energia elétrica. Redes neurais artificiais. Monitoramento remoto.

ABSTRACT

OTA, R. T. Remote monitoring of short circuits situations in a power distribution system by using artificial neural networks and considering different topologies and load profiles. 2017. 120p. Term paper. São Carlos School of Engineering, University of São Paulo, São Carlos, Brazil, 2017.

The growing concern about energy efficiency, automation and integration of processes in the current scenario has been characterized by a considerable increase in the number of sensitive equipment and propitious to generate problems of power quality. Thus, it is essential to keep the power quality within the pre-set standards, which can only be guaranteed through an effective and continuous monitoring of some physical quantities, like the three-phase voltage of the power distribution system at various points. In this context, the present research aims to present an alternative method of remote monitoring by using an artificial neural network (ANN). This system aims to estimate the value of the three-phase voltage at several points of a power distribution system, considering different load profiles that the system may present daytime, besides of the proposal of different topologies of ANNs in order to obtain more accurate results. This research got all the data for the ANNs by the modeling of a power distribution system, enabling the training and validation of this work. The results were satisfactory and define the training methodology and optimum topology of the when used in problems of power quality, showing the possibility of using this technology in the future.

Keywords: Power distribution system. Power quality. Artificial neural networks. Remote monitoring.

1 INTRODUÇÃO

O contexto da Qualidade da Energia Elétrica (QEE) engloba qualquer assunto relacionado com problemas manifestados na tensão, corrente ou desvio de frequência, que resultam em má operação ou falha de equipamentos dos consumidores (DUGAN *et al.*, 2002). Da prática, tem-se que as concessionárias devem entregar energia atendendo padrões de qualidade que visam regular a conformidade da onda, o atendimento ao consumidor e a continuidade do fornecimento de energia (BELISÁRIO *et al.*, 2003).

A conformidade ocorre quando a forma de onda da tensão trifásica é entregue da maneira correta, isto é, uma onda puramente senoidal sem variações em sua amplitude e frequência. O atendimento ao consumidor é a relação comercial entre as concessionárias e os clientes, considerando a cortesia, o tempo de atendimento e o respeito aos direitos do consumidor. A continuidade é o quanto a energia elétrica está disponível para o consumidor, neste sentido, a menor quantidade de interrupções deve ser almejada (BELISÁRIO *et al.*, 2003).

A falta da QEE pode ser caracterizada pela presença de distúrbios (descontinuidades) nos sinais das tensões e correntes trifásicas e/ou na frequência em observação, decorrentes da interrupção da energia, transitórios oscilatórios e impulsivos, Variações de Tensão de Curta Duração (VTCD) e Variações de Tensão de Longa Duração (VTLD), e distorção harmônica, dentre outros fenômenos (OLESKOVICZ, 2007).

Estes problemas podem ter como efeito, dentre outros, a parada de equipamentos, oscilações luminosas, perda de memória em microprocessadores ou controladores lógicos programáveis, mau funcionamento e diminuição da vida útil de motores. Destas situações, sabe-se da prática que os prejuízos para os consumidores finais podem ser elevados, principalmente no comércio e indústria.

Uma maneira de minimizar os distúrbios, ou entende-los melhor, é tendo mais medidas sobre o Sistema de Distribuição (SD) de interesse, garantindo assim mais conhecimento sobre seu comportamento e podendo se precaver para evitar que tais distúrbios ocorram ou se propaguem. Entretanto, existem várias dificuldades em se fazer um monitoramento contínuo e representativo sobre um SD. Deve-se escolher o que monitorar, o equipamento adequado para medição, o local de monitoramento, o número de medidores, a taxa de amostragem e como armazenar e processar os dados obtidos. Para levantar um histórico frente às VTCD, por exemplo, é necessário um longo período de monitoramento para a obtenção de análises representativas (DUGAN *et al.*, 2002), fazendo-se necessária a constante evolução dos métodos de medição e análise do SD.

1.1 JUSTIFICATIVA DO TRABALHO

Frente ao cenário delineado, um monitoramento remoto via Redes Neurais Artificiais (RNAs), realizado a partir da Subestação de Energia (SE) do sistema, permitirá a concessionária uma grande economia de recursos humanos e financeiros, visto que não será necessária a instalação de novos equipamentos em campo, sendo possível a fácil obtenção das medições, processamento e armazenamento dos dados. Contudo, a dificuldade desse monitoramento via RNA consiste na obtenção de uma RNA que indique com precisão a tensão eficaz em um ponto remoto e genérico sobre o SD escolhido e, que, dentre os objetivos desta pesquisa, venha a responder adequadamente frente à influência dos diferentes perfis de carga dos consumidores.

Neste sentido, a presente proposta de pesquisa em análise tem como principal justificativa a continuidade dos trabalhos de BOTTURA *et al.* (2010), CAMARGO (2012) e LIMA (2014), os quais já retrataram a possibilidade e os promissores resultados obtidos no monitoramento remoto das tensões trifásicas em diferentes pontos de um SD via RNA. Tomando por base a metodologia, procedimentos e a comprovação da generalização observada sobre os modelos neurais já testados, para a continuidade da pesquisa, busca-se refinar o contexto de aplicação das RNA considerando perfis distintos de cargas dos consumidores.

Desta maneira, pela consideração de diferentes perfis de cargas na metodologia de monitoramento remoto das tensões trifásicas a partir da SE via RNA e a investigação de diferentes topologias de rede, acredita-se imprimir a pesquisa até então realizada, uma melhor aproximação dos modelos às situações reais encontradas nos SD.

1.2 OBJETIVOS DA PESQUISA

O objetivo da pesquisa é utilizar uma RNA do tipo PMC (*Perceptron Multicamadas*), devido a fortes indícios de sua efetividade já constatados por BOTTURA *et al.* (2010), CAMARGO (2012) e LIMA (2014), na obtenção da tensão eficaz em um ponto de monitoramento remoto qualquer de um SD, submetido a diferentes perfis de cargas. Além disso, a presente pesquisa busca investigar a relação do índice de acertos das RNA com sua topologia.

Pela proposição, a RNA deve ser robusta e operar adequadamente mesmo na presença de diferentes perfis de carga (leve, médio e/ou pesado), frente às possíveis situações de curtos-circuitos monofásicos, bifásicos, com ou sem o envolvimento da terra, ou trifásicos, que possam vir a ser observados sobre o SD. Como para os trabalhos anteriormente referenciados, espera-se obter uma única arquitetura de RNA que possa vir a ser replicada sobre os diversos pontos de monitoramento remotos no SD e que venha a adequadamente atender as premissas levantadas.

Para isso, diferentes topologias de RNA serão treinadas com um banco de dados gerado via simulações computacionais dispondo do software *Alternative Transients Program* (ATP). Por fim, deseja-se a obtenção de um procedimento padrão e a verificação da eficácia de diferentes topologias de RNAs frente sua utilização no monitoranto remoto de um SD abrangendo diferentes tipos de faltas e perfis de carga. Este procedimento deverá atender a todas as fases do processo passando pela análise do sistema e do(s) ponto(s) de monitoramento remoto(s), formatação de um banco de dados representativo, treinamento e teste das mesmas frente às situações de curtos circuitos evidenciadas sobre o SD, conclusões e encaminhamentos finais para atender a qualquer outro SD.

1.3 APRESENTAÇÃO DO DOCUMENTO

O presente trabalho de conclusão de curso possui mais nove capítulos. O capítulo dois conta com a apresentação do estado da arte das pesquisas sobre redes inteligentes e inteligência artificial aplicadas no setor elétrico. O capítulo três traz um breve resumo de todo o documento, apresentando a metodologia utilizada nesta pesquisa. Já o capítulo quatro inicia um estudo sobre a variação dos perfis de carga durante o dia, segregados por tipos de consumidores. O capítulo cinco introduz os principais conceitos sobre o funcionamento das redes neurais artificiais. Já o capítulo seis faz uma profunda análise sobre circuitos elétricos, de forma a definir o melhor método de modelagem das cargas via o software ATP. O capítulo sete define os parâmetros utilizados nesta pesquisa para a realização das simulações computacionais, além de definir os métodos de abordagem do problema e iniciar o treinamento das redes neurais. O capítulo oito introduz a etapa de teste das redes neurais de forma a definir o método de treinamento mais efetivo. Definido o método de abordagem, o capítulo nove inicia a verificação do desempenho das redes frente ao aumento do número de neurônios.

Por fim, o capítulo dez resume todos os resultados obtidos neste trabalho de conclusão de curso, definindo então a melhor topologia e metodologia de treinamento para as RNAs quando utilizadas para estimar remotamente as tensões trifásicas no sistema de distribuição analisado.

2 ESTUDOS CORRELATOS

Dentro de um SD, o quesito segurança sempre foi essencial para a manutenção e operação do sistema como um todo. Para isso, o constante desenvolvimento de técnicas de medição, monitoramento, procedimentos e políticas que previnam acidentes e a danificação dos equipamentos são de suma importância. Este desenvolvimento vem ao encontro com a concepção das *Smart Grids* (redes inteligentes), caracterizando a próxima geração do SD de energia. Sua utilização, dentre outros quesitos, torna-se possível através da instalação de sensores e medidores inteligentes, proporcionando a realização do monitoramento do sistema de forma digital e, consequentemente, uma melhor conectividade entre a concessionária e os consumidores, maior automação dos sistemas e processos, aumento da eficiência energética, e confiabilidade do sistema de distribuição (SINGH *et al.*, 2013).

Entretanto deve-se, antes, entender a complexidade do SD nacional e obter/apontar ferramentas que possam lidar de forma aceitável com os problemas já existentes para a plena evolução do SD atual e a real incorporação e aceitação das redes inteligentes. Neste sentido, a literatura recente conta com diversas pesquisas que exploram conceitos no contexto das redes elétricas inteligentes e propõem alternativas para a realização das medições das tensões trifásicas em um SD, as quais fazem parte do escopo desta pesquisa.

No artigo de KNAUSS, WARREN e KEARNS (2012) foi abordado o desenvolvimento de um projeto piloto para testar a eficácia da implantação da automação inteligente em um sistema de distribuição. Pela pesquisa, os autores buscaram demonstrar os benefícios da utilização da tecnologia baseada nas redes elétricas inteligentes. Os sistemas de hardware e software foram desenvolvidos em laboratório, sendo automatizados reguladores de tensão, banco de capacitores, o monitoramento da qualidade da energia, dispositivos e sensores associados, medidores inteligentes e sistemas de comunicação. Do ponto de vista de software, foram utilizados sistemas como: Sistema de Supervisão e Aquisição de Dados (SCADA), *Distribution Management System (DMS)*, *Meter Data Management System (MDMS)* e *Outage Management System (OMS)*. Foi projetado e desenvolvido um sistema analógico que possibilita a simulação em laboratório e a eliminação automática de faltas e esquemas de restauração do sistema. Os resultados dos testes realizados demonstraram que investimentos de larga escala em redes inteligentes podem trazer grandes benefícios para os consumidores e para as concessionárias, pois os picos de demanda energética podem ser drasticamente reduzidos com a implementação de tecnologias que forneçam informações sobre o consumo de energia e de diversos planos de tarifas em tempo real que fazem com que os consumidores mudem seus hábitos. Além disso, os autores comentam que a confiança no SD pode ser aumentada através do monitoramento constante e eficiente da tensão entregue aos consumidores, pois além da questão relacionada com a falta da QEE, os mesmos destacam também o problema do crescimento da demanda energética e a complexidade do SD, ocasionados devido à maior disseminação e aderência da geração distribuída,

proporcionadas pela Resolução Normativa número 482 da ANEEL (ANEEL, 2012-a). A integração do SD a essa nova forma de produção de energia contribui de forma significativa para o aumento das correntes de faltas (FANG *et al.*, 2012). Pelo trabalho, os autores ressaltam que as situações de falta (curtos-circuitos) compõem um dos principais obstáculos para a completa análise do SD e a implementação das redes elétricas inteligentes. Dessa forma, destaca-se a importância da utilização de um método robusto para a realização do monitoramento remoto da tensão trifásica frente às situações de faltas.

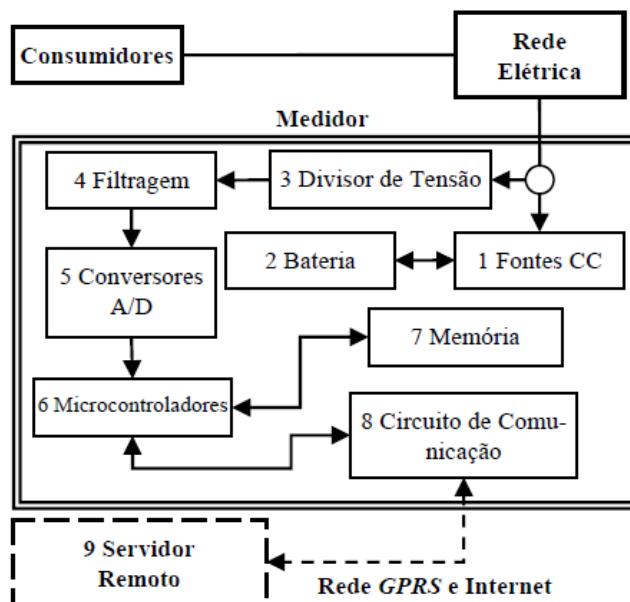
Neste contexto, apresenta-se abaixo uma revisão bibliográfica sobre os principais métodos já propostos e encontrados até o momento para a realização do monitoramento remoto da QEE, com foco nas tensões trifásicas, utilizando RNAs.

Em BEZERRA *et al.* (2001a) foi discutido o desenvolvimento de um protótipo de um instrumento para o monitoramento da QEE de uma concessionária de energia. Este instrumento consiste em um microcontrolador 68HC11 que fornece os índices de continuidade de um conjunto de consumidores. Os dados finais são transmitidos através da porta serial do microcontrolador, possibilitando a análise da tensão fornecida para verificação de sua conformidade com os padrões de qualidade conforme Resolução nº24 de 27/01/2000 da ANEEL. Para a validação dos resultados obtidos, foi construída uma bancada de laboratório para a simulação do sistema de distribuição real. Assim, os autores propõem a implementação de um microcontrolador dotado de um programa para análise da QEE, salvo em sua memória não volátil. Entretanto, não foram apresentados os métodos utilizados para obtenção dos valores de tensão da rede usados para análise.

No artigo de BEZERRA *et al.* (2001b) é abordado o monitoramento da QEE em redes de distribuição urbanas. O sistema analisado é constituído de unidades monitoradoras, instaladas nas entradas dos consumidores classe *B* mono, bi e trifásica com o intuito de avaliar os índices de continuidade estabelecidos pela Resolução 024/2000 da ANEEL (ANEEL, 2000). Para isso, foram utilizados computadores, circuitos e enlaces de comunicação, bem como softwares responsáveis pela aquisição, tratamento e transmissão remota de todas as informações. Para realizar a medição da QEE foi utilizado um conjunto de instrumentos, cada um deles ligado a uma única unidade consumidora de energia elétrica. Cada um desses instrumentos foi ligado a um dispositivo concentrador através da interface RS-485, que por sua vez estava ligado ao computador que possui o software SOFTCOM (software desenvolvido em *Visual Basic 5.0* pela NESC – Núcleo de Engenharia em Supervisão e Controle de Sistemas de Energia, do Departamento de Engenharia Elétrica da UFPA – Universidade Federal do Pará). A principal função do SOFTCOM é a comunicação dos dados entre dois computadores, determinando quando cada um dos instrumentos deve iniciar o monitoramento ou transmitir seus registros. Assim, os autores propõem a criação de uma rede de informações interligada entre os instrumentos medidores e a central de processamento de dados para controle e monitoramento da QEE em uma rede de distribuição urbana.

Além do trabalho de BEZERRA *et al.* (2001 - a), o desenvolvimento de instrumentos para o monitoramento remoto da tensão trifásica do sistema elétrico também foi tema abordado por COLGANO *et al.* (2009). Neste trabalho, os autores salientaram que os medidores de QEE possuem duas características principais: possuem baixo custo e não atendem às especificações da ANEEL (ANEEL, 2009), ou possuem alto custo e precisão elevada. Assim, foi proposto o desenvolvimento de um medidor de baixo custo, como ilustrado na **Figura 1**, que atendesse às especificações vigentes de medição de QEE. Para isso, a medição de corrente do sistema foi suprimida, mantendo-se apenas os indicadores mais importantes, sendo monitorados os indicadores de tensão em regime permanente, os harmônicos, a flutuação de tensão, o desequilíbrio de tensão, a variação de tensão de curta duração e as interrupções de energia.

Figura 1 - Diagrama esquemático para o monitoramento da QEE.



Fonte: Colgano (2009).

Os componentes do medidor proposto pelos autores são:

- Fontes CC: utilizam a energia da rede para alimentar o sistema;
- Bateria: alimenta o sistema durante as interrupções e afundamentos severos de tensão;
- Filtragem: conjunto de três filtros ativos que removem as altas frequências do espectro e eliminam o efeito de *aliasing*;
- Conversores A/D: conjunto de três conversores A/D de 12 bits que digitalizam o sinal filtrado para o processador de sinais;
- Microcontroladores: conjunto de dois micros controladores de baixo custo responsáveis

pelo processamento dos sinais, cálculo dos indicadores em tempo real, gerenciamento do sistema e comunicação com o servidor remoto;

- Memória: cartão de memória do tipo *flash* responsável por armazenar os dados medidos para envio ao servidor remoto; e
- Circuito de comunicação: composto por um módulo de celular que permite a comunicação entre o servidor remoto e o medidor através da rede *General Packet Radio Services (GPRS)* e internet.

O medidor foi submetido a um conjunto de testes determinados pelos autores com o intuito de verificar o desempenho do aparelho desenvolvido. Como resultado, o medidor apresentou resultados satisfatórios, atendendo aos principais requisitos da norma brasileira, principal objetivo dos autores. Além disso, o baixo custo, quando comparado com outros medidores de QEE existentes, foi alcançado devido a simplificação do *hardware* do dispositivo. Dessa forma, os autores salientam a possibilidade de utilização em escala comercial devido a adequação dos resultados à norma e o custo inferior aos outros dispositivos existentes no mercado.

Logo, é possível observar, conforme os trabalhos citados acima, que a atual literatura conta com diversos projetos de novos medidores de QEE, cada um com sua característica própria. Entretanto, o desenvolvimento de novos medidores não exclui o fato de que para sua utilização, será necessária sua instalação em diferentes pontos do SD, decorrendo em esforços e gastos financeiros. Dessa forma, reforça-se aqui a importância do desenvolvimento de um método robusto para a medição da tensão trifásica frente aos diferentes tipos de curtos-circuitos que não necessitem da instalação de novos medidores. Para isso, assim como mencionado na justificativa desta pesquisa, será dada continuidade aos trabalhos de BOTTURA *et al.* (2010), CAMARGO (2012) e LIMA (2014), os quais verificaram a efetividade da rede do tipo PMC. Entretanto, faz-se necessário uma pesquisa bibliográfica mais profunda sobre os diferentes tipos de redes utilizadas em sistemas de potência.

A existência e aplicação de diversos tipos e modelos de RNAs são ressaltados pelas pesquisas de AGGARWAL *et al.* (1998), trabalho no qual são realizadas análises de aspectos práticos do desempenho de RNAs em sistemas de potência, considerando as diversas arquiteturas, métodos de treinamento, seleção dos dados de entrada das RNAs e algoritmos de aprendizagem. Dentre os tipos de RNAs mais utilizadas na literatura, os autores citam as do tipo PMC rede Kohonen e rede Hopfield, sendo destacada, de forma geral, a eficiência da aplicação das redes PMC em sistemas de potência, quando comparada com os demais modelos, devido a alta precisão associada ao aprendizado supervisionado. Os autores analisaram o comportamento das RNAs quando submetidas a testes relacionados às suas aplicações em previsões de carga, classificação de faltas, estabilidade de tensão trifásica, entre outros. É necessário ressaltar que, dentre as diversas aplicações citadas anteriormente, serão discutidas somente aquelas das quais os autores consideraram o uso da rede PMC como mais

vantajosa, no caso, a aplicação em previsão de carga. Dessa forma, será possível observar os aspectos gerais e benefícios que a rede PMC proporciona. Rede esta que será utilizada durante o desenvolvimento desta pesquisa.

A utilização de RNAs, mais especificamente, da rede do tipo PMC, para a previsão de carga possibilita o mapeamento de relações não lineares entre os dados de entrada e saída do sistema. Seu funcionamento consiste em traçar previamente um padrão das cargas do sistema e prevê outros padrões baseado em dados inseridos no sistema, sendo que o tempo necessário para a realização dos treinamentos varia em função da complexidade do problema, volume de dados, estrutura da rede e parâmetros utilizados no treinamento. Assim, é possível ter uma ideia geral do funcionamento da rede PMC e seus benefícios quando utilizada em sistemas de potência, criando mais um motivo para sua utilização nesta pesquisa.

As pesquisas de POPOVIĆ *et al.* (1998) propõem uma nova metodologia para o monitoramento remoto da tensão e avaliação das margens de estabilidade do sistema elétrico. O trabalho é desenvolvido utilizando-se quatro estágios de redes do tipo PMC, a saber: (1) Configuração e modelagem do procedimento; (2) Análise de estabilidade; (3) Redução do modelo utilizado; e (4) Monitoramento e avaliação das margens de estabilidade do sistema. Durante o estágio de aprendizagem das redes, são utilizados quatro diferentes tipos de RNAs, nomeadas pelos autores de: UR, NT, NY e NR. A primeira RNA (UR) é do tipo auto organizada e possui a finalidade de reduzir o vetor de variáveis do sistema. Já a rede NT é do tipo PMC e visa realizar a detecção da topologia do sistema. NY é uma rede unificada multicamada utilizada para a determinação das margens de estabilidade do sistema, possuindo como entrada o vetor completo de variáveis do sistema. Por fim, NR é uma rede do tipo PMC que também determina as margens de estabilidade do sistema, com a diferença de que nesta última rede é utilizado como entrada do sistema, um vetor reduzido.

Quanto ao método de aprendizagem utilizado, os autores consideraram dois algoritmos globais durante o projeto, nomeados de AY e AR, baseados em uma combinação das redes NT com NY e NT com UR e NR, respectivamente. Vale ressaltar que foi constatado pelos autores que o aumento do número de camadas intermediárias das RNAs aumentava significativamente o tempo de aprendizagem, mas este mesmo aumento não foi constatado no quesito de precisão dos resultados.

O algoritmo AR consiste em seis etapas, sendo que o algoritmo AY consiste das mesmas etapas descritas no que segue, com exceção da etapa três:

- Etapa 1: consideração do valor mínimo de carga como valor inicial de entrada do sistema, determinando o ponto estacionário (x^0, y^0);
- Etapa 2: linearização do modelo dinâmico usando o ponto estacionário obtido na Etapa 1;
- Etapa 3: redução do sistema através da utilização de uma rede auto-organizada,

obtendo-se o vetor (x_R, y_R) e, em seguida, aplicando-se o algoritmo *Aesops*;

- Etapa 4: aplicação do algoritmo *Qr* nos modelos estático e dinâmico reduzidos para determinação dos autovalores (λ_i, v_i);
- Etapa 5: determinação dos menores autovalores (Ψ_j); e
- Etapa 6: verificação se o valor de carga crítico foi atingido para, em seguida, obter a estabilidade do sistema.

Durante o projeto de pesquisa, o autor utilizou uma rede para a realização da redução do número de variáveis do vetor de entrada do sistema. Esta característica torna-se interessante por diminuir o tempo de aprendizagem das outras redes e pode ser visto como um problema de extração de características das variáveis. Assim, o método consiste no agrupamento de variáveis suficientemente semelhantes e separação das demais. A variável de estado mais próxima do centro de seu grupo é considerada como representante. Finalmente, ao se agrupar todos os representantes dos grupos formados, obtém-se o vetor reduzido do sistema (y_R). Em testes realizados pelos autores, verificou-se que o vetor reduzido representa somente 5% do vetor completo de variáveis do sistema.

Para a verificação dos resultados, POPOVIĆ *et al.* (1998) consideraram um sistema elétrico real, obtendo os seguintes resultados:

- As simulações que continham apenas variáveis de estado do sistema (Θ, V) como entrada das redes apresentaram maior precisão quando foi utilizado o vetor de entrada do sistema completo (algoritmo AY) do que o vetor reduzido (método AR);
- Quando utilizado o vetor contendo as potências ativa e reativa do sistema (P, Q), a precisão adquirida pelos resultados foi semelhante para ambos os métodos; e
- Utilizando-se os vetores de entrada com dados suficientes (V, P e Q) e (Θ, V, P e Q), o algoritmo AR, que utiliza o vetor de entrada reduzido, obteve maior precisão quando comparado ao algoritmo AY.

Por fim, a análise do tempo de aprendizagem mostrou que a utilização do algoritmo AR, que considera o vetor de entrada reduzido, é uma ordem de magnitude (em termos de ms) mais rápido do que o algoritmo AY.

O trabalho de NAKAWIRO *et al.* (2008) também aborda o problema do monitoramento remoto da estabilidade da tensão trifásica com a utilização de RNAs. Entretanto, antes de estudar um tipo de rede e simplesmente comparar os resultados obtidos, os autores optaram por trabalhar primeiramente com o banco de dados procurando gerar informações abrangentes (representativos) e com a redução do vetor de entrada da rede.

Para a formação do banco de dados que será utilizado no treinamento da RNA, NAKAWIRO

et al. (2008) variaram aleatoriamente as partes real e imaginária das cargas presentes na simulação do SD de 60% a 120% de seus valores base. Dessa forma, o banco de dados formado considera diferentes situações do SD, pois os consumidores não constituem cargas constantes para o sistema no decorrer do dia.

Já a redução do vetor de entrada foi realizada através do agrupamento de informações repetitivas e pela escolha dos dados que representam seu grupo como um todo. Segundo os autores, esta abordagem auxiliou na redução do esforço computacional necessário e foi realizada com o auxílio de algoritmos de agrupamento de dados, tais como agrupamento baseado na distância, agrupamento hierárquico e aprendizado competitivo. Também foram utilizadas técnicas de extração de dados, como a análise de componentes fundamentais.

Realizados os devidos tratamentos com o banco de dado, NAKAWIRO *et al.* (2008) optaram pela utilização de uma rede multicamada devido a sua grande utilização em sistemas de potência, sendo construída com uma camada de entrada, uma camada intermediária e uma camada de saída. A rede foi treinada com um algoritmo do tipo *back-propagation* com otimização de Levenberg-Marquardt. Durante a realização dos treinamentos, sempre foi considerado um tempo de parada precoce com o intuito de evitar que ocorresse o excesso de treinamento da rede, conforme indicam os estudos de TETKO *et al.* (1995). Vale ressaltar que o excesso de treinamento afeta de forma negativa os resultados finais da rede, pois faz com que o aumento do número de iterações do treinamento não diminua o erro contido na saída do sistema.

Como resultado, os autores salientaram que o tempo de resposta do modelo proposto é extremamente rápido e os resultados fornecidos pela rede estão bem próximos dos valores reais, destacando-se, dessa forma, como um método promissor para aplicações em situações reais.

Em BOTTURA *et al.* (2010), apresentou-se a aplicação de RNAs como um método alternativo para o monitoramento da tensão trifásica em determinado ponto de interesse frente a dois tipos de curtos-circuitos no SD com o intuito de avaliar a QEE. Para isso, os autores utilizaram três RNAs do tipo PMC, aplicadas de forma independente nas fases do sistema trifásico. As tensões e correntes trifásicas registradas na SE foram utilizadas como pares de entrada e saída das RNAs, sendo que 70% dos dados foram utilizados para treinamento e os 30% restantes para validação dos resultados. Para a determinação do número de neurônios presentes em cada RNA foi considerado o melhor custo benefício em relação ao esforço computacional para possível aplicação do trabalho proposto pelos autores em uma operação *online*. Os autores optaram por utilizar uma RNA composta por 15 neurônios na primeira camada oculta, 10 neurônios na segunda camada oculta e 1 neurônio na camada de saída. A modelagem do SD foi realizada através do software ATP com parâmetros reais fornecidos por uma concessionária local. Com a realização dos treinamentos das RNAs, validações e simulações necessárias, os autores chegaram ao resultado de um índice de precisão superior a 97% com uma magnitude de erro inferior a 0,05 p.u. Assim, foi determinada uma RNA para análise da

tensão trifásica frente a dois casos de curto-círcuito com bom custo-benefício.

O trabalho de CAMARGO (2012) segue os mesmos objetivos de BOTTURA *et al.* (2010), buscando a determinação da tensão fornecida a uma determinada carga do SD monitorado. Para isso, o autor também utilizou o software ATP para a modelagem do SD e formatação de um banco de dados, além de três RNAs para a medição da tensão trifásica fornecida a determinada carga, sendo uma para cada fase. Vale comentar que o trabalho de CAMARGO (2012) também demonstrou que uma mesma topologia pode ser utilizada em diferentes pontos de monitoramento de um mesmo SD. Além disso, foram utilizados 70% dos dados obtidos através de simulações no ATP para treinamento das RNAs e os 30% restantes para validação dos resultados. Como conclusão, o autor chegou ao resultado de que em média 95,24% dos casos apresentam erros inferiores a 0,01 p.u. e 99,14% dos casos apresentam erros inferiores a 0,05 p.u., implicando em um índice médio de acerto consideravelmente elevado.

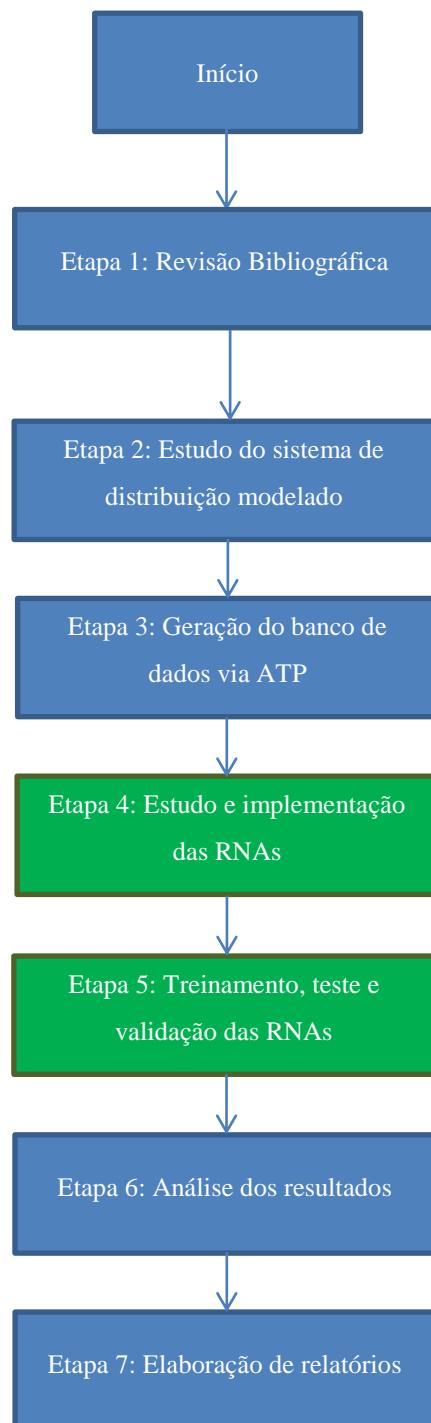
Vale colocar que em LIMA (2014) também foi dado continuidade aos dois trabalhos anteriores, utilizando redes do tipo PMC e o mesmo software para simulação. O principal diferencial da pesquisa foi o estudo da generalização do sistema de medição remoto, objetivando sua utilização mesmo quando o SD está submetido a quaisquer tipos de faltas, ou seja, foi formado um banco de dados considerando onze tipos diferentes de faltas, diferentemente dos trabalhos de BOTTURA *et al.* (2010) e CAMARGO (2012), onde foram consideradas apenas faltas monofásicas envolvendo a fase A. Como resultado, o autor concluiu que os erros das saídas das RNA mostraram-se baixos para todos os pontos de monitoramento, sendo que de 88,2% a 99,2% dos casos de teste apresentaram erros inferiores a 0,03 p.u..

Assim como encontrado na literatura até o momento consultada, RNAs são comumente utilizadas para a solução de diversos problemas, entre eles, o monitoramento da tensão trifásica e das margens de estabilidade do SD. Em sistemas de potência, foi verificado o destaque das redes do tipo PMC por diversos autores, reforçando sua importância no contexto desta pesquisa. Dessa forma, frente ao atual cenário vislumbrado na presença das redes inteligentes e aos principais métodos encontrados na literatura para o monitoramento da tensão trifásica nos SD, o desenvolvimento desta pesquisa tem como objetivo dar continuidade aos trabalhos de BOTTURA *et al.* (2010), CAMARGO (2012) e LIMA (2014), analisando o uso de RNAs do tipo PMC para o monitoramento da tensão trifásica no SD frente a diferentes curtos-circuitos e perfis de carga. A composição destes cenários será utilizada para a simulação do SD teste e obtenção de uma representativa base de dados. Características estas que aproximam ao máximo o modelo proposto para um método que possa ser aplicado em situações reais, possibilitando assim o monitoramento eficiente da tensão do SD de forma pouco custosa e, consequentemente, impactando de forma direta nos índices que retratam o fornecimento da energia com qualidade.

3 METODOLOGIA DE PESQUISA

As etapas seguidas para a pesquisa como um todo podem ser observadas na **Figura 2**.

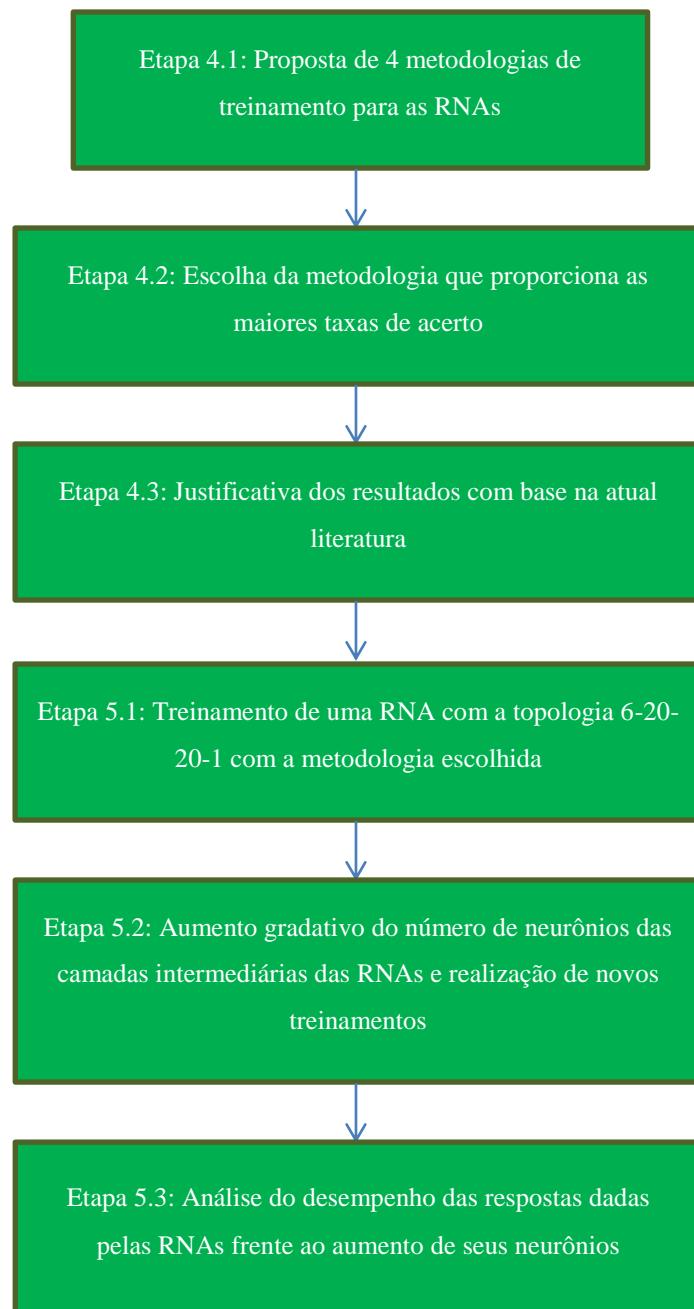
Figura 2 - Etapas seguidas para a metodologia de pesquisa.



Fonte: Autoria própria (2017).

É importante ressaltar que as Etapas 4 e 5 mencionadas acima possuem diversos sub itens de análise, sendo estes importantes para a caracterização da presente pesquisa. Dessa forma, os detalhes de execução destas etapas podem ser verificados na **Figura 3**.

Figura 3 - Detalhes de execução das Etapas 4 e 5.



Fonte: Autoria própria (2017).

Sendo assim, os capítulos subsequentes a este descrevem de forma detalhada cada etapa da metodologia definida nas **Figuras 2 e 3**.

4 PERFIS DE CARGA CONSIDERADOS

O conhecimento da demanda energética dos consumidores do sistema elétrico brasileiro é fator de extrema importância tanto em questões investigativas em relação ao investimento e planejamento da tarifação (BRASIL, 1985), quanto para uso em simulações para melhor representar a efetividade do projeto desenvolvido e aproximar-las de casos reais, sendo este último parte desta pesquisa.

Como fato, da operação do Sistema Elétrico de Potência (SEP), tem-se que a potência fornecida pelas distribuidoras de energia é consumida de forma descontínua durante o dia. Dessa forma, as cargas envolvidas no SD não são estáticas, fazendo-se necessário o conhecimento dos perfis de carga dos consumidores. Tais curvas podem ser utilizadas para estimar, por exemplo, o aumento das cargas envolvidas no SD nos horários de pico para obtenção dos valores mínimos e máximos a serem utilizados em simulações e análises da efetividade do modelo proposto em diversas situações.

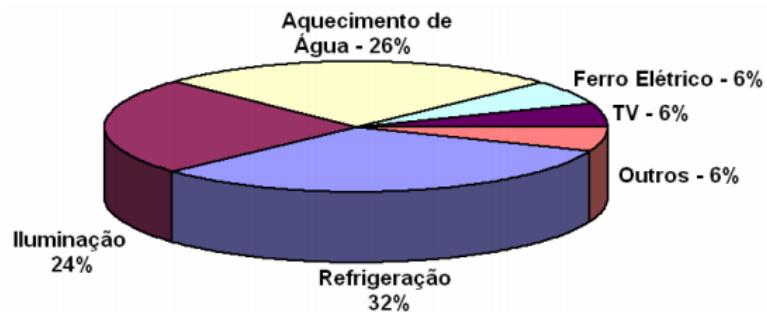
Neste sentido, de posse de perfis de cargas característicos, pretende-se aprimorar os trabalhos já desenvolvidos (BOTTURA *et al.* (2010), CAMARGO (2012) e LIMA (2014)), considerando-se neste, todas as situações de curtos-circuitos em diferentes situações de operação do sistema.

Como principal objetivo deste tópico, está o desenvolvimento de estimativas do consumo máximo, mínimo e médio de energia elétrica dos consumidores (clientes finais) conectados à rede. Dessa forma, será possível a realização de simulações que considerem situações mais próximas das reais. Além disso, serão consideradas as principais pesquisas presentes na literatura sobre este tópico.

FRANCISQUINI (2006), por exemplo, leva em consideração principalmente a análise dos consumidores residenciais e comerciais, respondendo por aproximadamente por 25% e 10% do consumo de energia elétrica do país, respectivamente.

Os dados disponibilizados pelo Ministério da Ciência e Tecnologia (MCT), apresentados por FRANCISQUINI (2006), apontam que 80% das residências possuem refrigeradores, estes responsáveis por grande parte do consumo total de energia elétrica das residências. Além disso, o aquecimento de água realizado através de chuveiros elétricos está presente em 80% das residências. A potência nominal dos chuveiros está entre 2 e 6kW, responsáveis, também, por grande parte do consumo total dos consumidores residenciais, conforme pode ser observado na **Figura 4**.

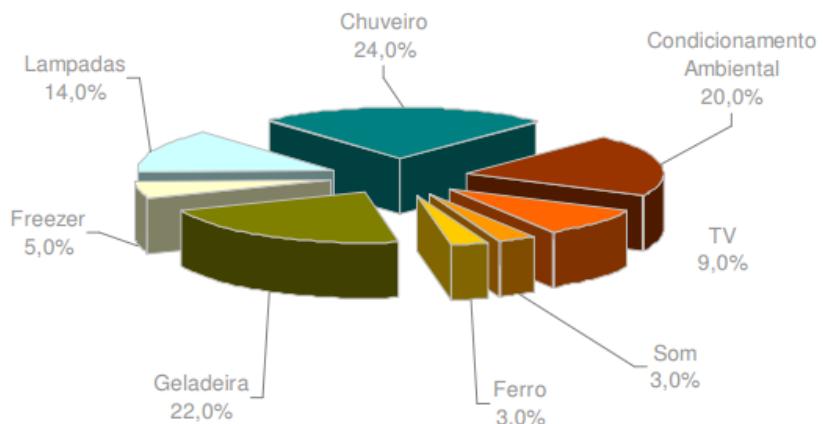
Figura 4 – Consumo de energia elétrica de um consumidor residencial especificada por aparelho.



Fonte: Francisquini (2006).

Já os dados do relatório da ELETROBRÁS (2009) apontam que a refrigeração é responsável por 47% do consumo residencial, considerando o condicionamento ambiental, geladeira e freezer, conforme mostra a **Figura 5** abaixo.

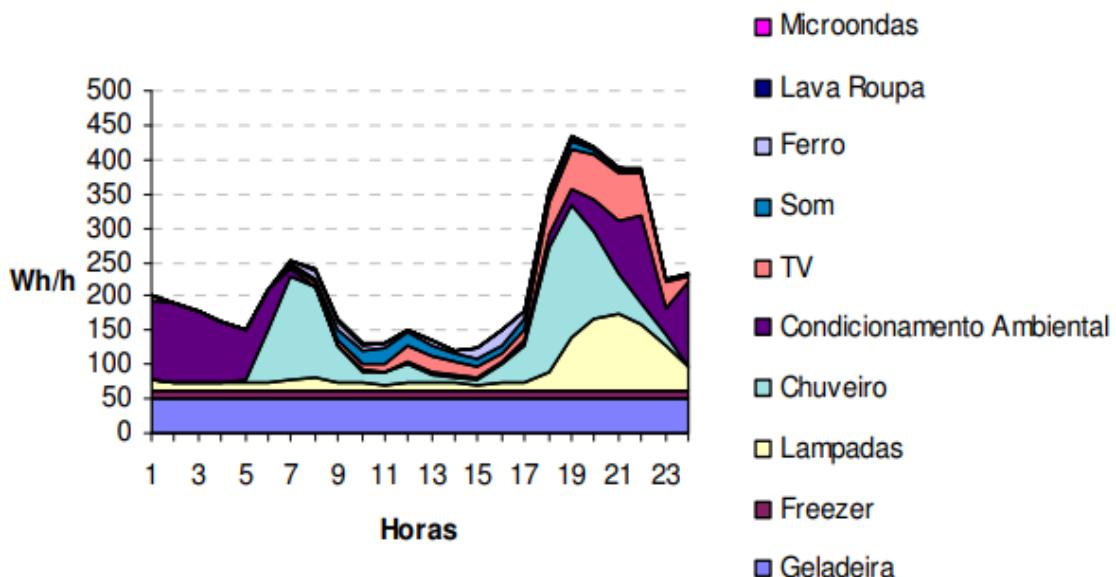
Figura 5 – Consumo final na carga residencial.



Fonte: Eletrobrás (2009).

Esta diferença é resultado do ano de referência utilizado para a aquisição dos dados de consumo residencial. Segundo ELETROBRÁS (2009), as curvas de carga média para estes tipos de consumidores possuem as características apresentadas na **Figura 6**.

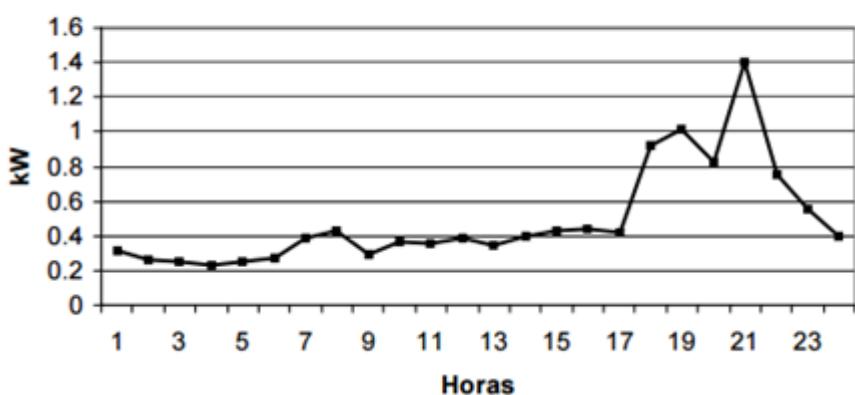
Figura 6 – Curva de carga diária média no Brasil.



Fonte: Eletrobrás (2009).

Já segundo FRANCISQUINI (2006), a curva de carga de um consumidor residencial é caracterizada pela constância do consumo de energia elétrica no decorrer do dia, elevando-se somente no fim da tarde, apresentando um pico de demanda, provocado pelo uso do chuveiro elétrico, conforme apresenta a **Figura 7**.

Figura 7 – Curva de carga de um consumidor residencial.

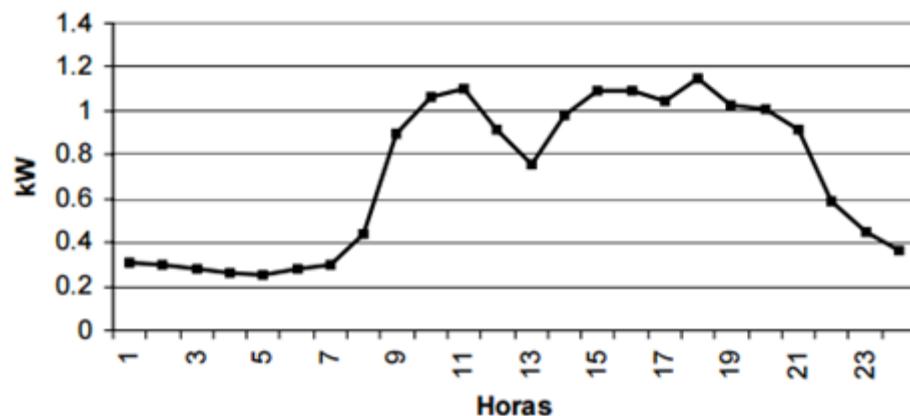


Fonte: Francisquini (2006).

Para os consumidores comerciais, o autor caracteriza a curva desta categoria como sendo constante durante o horário comercial, com uma leve diminuição durante o horário de almoço e relativamente baixa fora do horário comercial. Um exemplo de uma curva de carga para um

consumidor comercial real pode ser verificada na **Figura 8**.

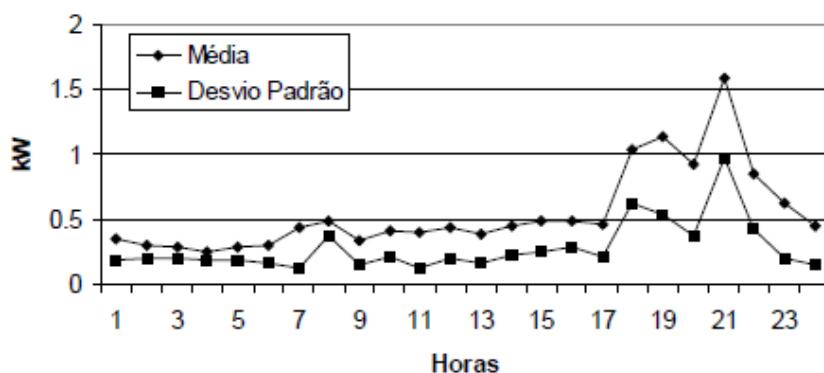
Figura 8 - Curva de carga de um consumidor comercial.



Fonte: Francisquini (2006).

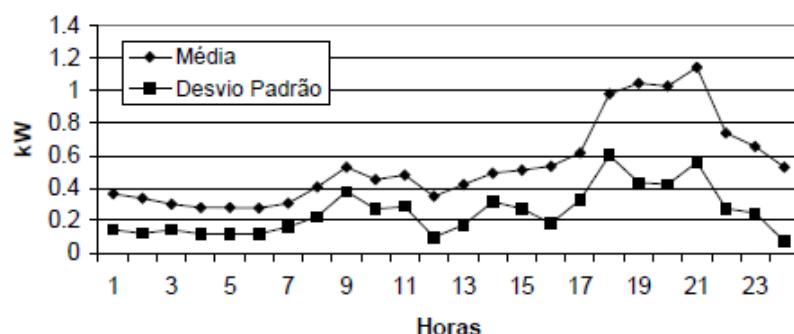
Através da análise estatística das curvas de carga obtidas pelas concessionárias de energia, o autor gerou diversos outros gráficos indicando a média de consumo de energia elétrica para os consumidores residenciais e comerciais nos dias úteis, sábados e domingos, com seus respectivos desvios padrões. As **Figuras 9, 10 e 11** representam as curvas de carga para consumidores residenciais da classe de 301 a 500 kWh.

Figura 9 - Curva de carga de um consumidor residencial nos dias úteis.



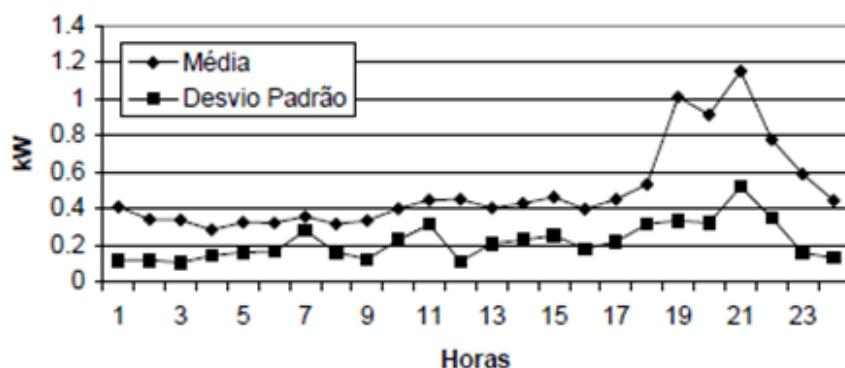
Fonte: Francisquini (2006).

Figura 10 - Curva de carga de um consumidor residencial aos sábados.



Fonte: Francisquini (2006).

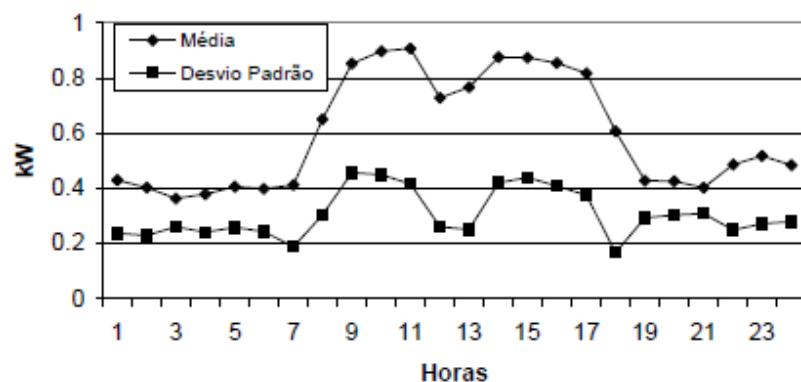
Figura 11 - Curva de carga de um consumidor residencial aos domingos.



Fonte: Francisquini (2006).

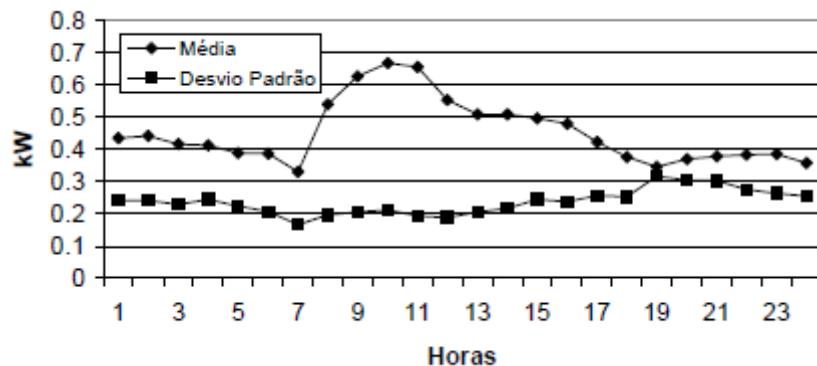
Já as **Figuras 12, 13 e 14** consistem em curvas de carga de consumidores comerciais da classe de 301 a 500 kWh.

Figura 12 - Curva de carga de um consumidor comercial em dias úteis.



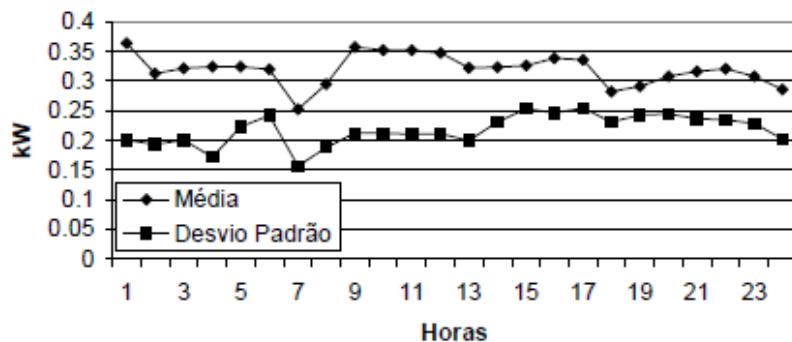
Fonte: Francisquini (2006).

Figura 13 - Curva de carga de um consumidor comercial aos sábados.



Fonte: Francisquini (2006).

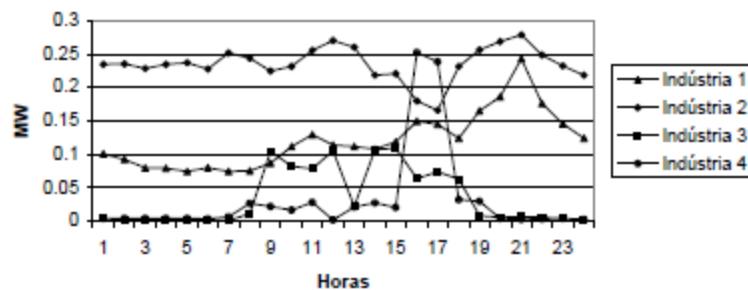
Figura 14 - Curva de carga de um consumidor comercial aos domingos.



Fonte: Francisquini (2006).

Por fim, os consumidores industriais respondem por cerca de 60% de toda a energia elétrica consumida no território nacional. Entretanto, as curvas de carga do setor industrial entram em divergência quando se analisa o ramo de atividade e sua localização. Dessa forma, FRANCISQUINI (2006) organizou os perfis de carga por grupos de indústrias, conforme verificado na **Figura 15**.

Figura 15 – Curvas de carga do setor industrial.



Fonte: Francisquini (2006).

Este agrupamento de dados realizado por FRANCISQUINI (2006) permite a realização da estimativa do consumo médio, máximo e mínimo de energia elétrica, sendo este o foco deste tópico. Dessa forma, é possível resumir todos os dados analisados nas **Tabelas 1 e 2** para a criação de estimativas da porcentagem de variação das cargas ligadas ao SD para futura utilização nesta pesquisa.

Tabela 1 - Consumo de energia de consumidores residenciais.

Consumidor Residencial					
Dia	Máximo (kW)	% do máximo em relação à média	Mínimo (kW)	% do mínimo em relação à média	Média (kW)
Dia útil	1,16	209,32	0,3	54,13	0,55
Sábado	1,15	205,97	0,3	53,73	0,56
Domingo	1,15	224,39	0,3	58,54	0,51

Fonte: Adaptado de Francisquini (2006).

Tabela 2 - Consumo de energia de consumidores comerciais.

Consumidor Comercial					
Dia	Máximo (kW)	% do máximo em relação à média	Mínimo (kW)	% do mínimo em relação à média	Média (kW)
Dia útil	0,90	151,58	0,30	50,53	0,59
Sábado	0,80	174,54	0,30	65,45	0,46
Domingo	0,35	109,37	0,25	78,12	0,32

Fonte: Adaptado de Francisquini (2006).

As **Tabelas 1 e 2** acima reúnem as informações mais relevantes, presente nas pesquisas de FRANCISQUINI (2006), para o presente trabalho sobre os perfis de carga de consumidores residenciais e comerciais. É possível observar que o horário de ocorrência das maiores e menores cargas presentes no SD não são os mesmos para consumidores residenciais e comerciais. Dessa forma, as cargas a serem simuladas na presente pesquisa devem ser variadas aleatoriamente para obtenção de situações próximas das reais. Além do método de seleção das cargas, a tabela também mostra que para ambos os tipos de consumidores as cargas apresentadas variam entre aproximadamente 50% a 200% da carga média.

Entretanto, o trecho correspondente a modelagem utilizada neste trabalho contém somente cargas industriais, logo os perfis de carga comerciais e residenciais pesquisados acima servem como uma breve pesquisa bibliográfica para projetos de pesquisa que desejem dar continuidade ao presente trabalho, ampliando e verificando a efetividade da metodologia desenvolvida em outras áreas do SD. Assim, torna-se necessário um resumo dos dados mais relevantes sobre a variação das cargas

industriais ao longo do dia, conforme mostra a **Figura 15**. Todos estes dados estão suscintamente apresentados na **Tabela 3**.

Tabela 3 – Consumo de energia de consumidores industriais.

Consumidor Industrial			
Tipo	Máximo (kW)	Mínimo (kW)	% do mínimo em relação ao máximo
Indústria 1	0,25	0,07	30
Indústria 2	0,275	0,16	58,18
Indústria 3	0,12	0	0
Indústria 4	0,25	0	0

Fonte: Adaptado de Francisquini (2006).

É possível perceber através da **Tabela 4** que o perfil de carga do ramo industrial pode ser dividido em grupos, adquirindo valores de carga mínima variáveis, envolvendo valores desde zero, no caso do fechamento da indústria em determinados horários do dia, até valores de aproximadamente de 60% da carga máxima. Visando a verificação da efetividade da utilização dos modelos de RNAs submetidos a diferentes perfis de carga do SEP, deve-se abranger a maior amplitude de dados do sistema elétrico que sejam consistentes com a realidade. Desta forma, para a definição da carga mínima dos consumidores industriais, será adotado o valor de 10% da potência instalada (valor máximo de carga) de forma a aproximar-se tanto do grupo de indústrias que fecham em determinado horário do dia quanto das que funcionam com carga menor do que a máxima.

5 REDES NEURAIS ARTIFICIAIS

Para um melhor entendimento da metodologia deste trabalho como um todo, a qual estará fortemente baseada e dependente da aplicação de RNAs, serão apresentados na sequência alguns apontamentos teóricos sobre este procedimento de inteligência artificial.

O cérebro humano possui inúmeras funções, dentre elas, a capacidade de reconhecimento de padrões, controle motor, percepção, inferência, intuição, advinhações, aprendizagem e tomada de decisões.

Assim, a modelagem de uma rede baseada no funcionamento do cérebro humano torna-se uma medida interessante para a análise de dados. Esses sistemas são chamados de redes neurais artificiais e serão utilizados para o desenvolvimento da presente pesquisa. Estas redes são definidas como uma estrutura de processamento, cuja implementação torna-se possível através de dispositivos eletrônicos que são compostos por várias unidades conectadas entre si, formando uma rede de dados. Cada unidade apresenta comportamento específico definido pelo processo de aprendizado no qual foi submetido, assim como no cérebro humano. Dessa forma, como o funcionamento das RNAs é baseado no sistema nervoso humano. Então, faz-se necessária uma breve explanação desta estrutura.

5.1 SISTEMA NERVOSO HUMANO

O neurônio é o elemento principal responsável por toda a capacidade de processamento de dados do sistema nervoso humano. Sua principal função é a transmissão ou retenção de impulsos elétricos e sua estrutura pode ser dividida basicamente em três partes principais: dendritos, corpo celular e axônio (HODGKIN *et al.*, 1952).

Os dendritos são compostos por vários prolongamentos e ramificações, formando a árvore dendrital. Sua principal função é a de captar os impulsos nervosos. O corpo celular compõe a parte principal do neurônio, responsável por processar todas as informações que chegam através dos dendritos. Já os axônios formam a extremidade do neurônio, responsáveis por transmitir todos os impulsos elétricos gerados pelo corpo celular para os dendritos do próximo, formando assim uma rede de dados interconectada entre todo o corpo humano.

Assim, a transmissão de dados no sistema nervoso humano começa pelo recebimento de impulsos nervosos pelos dendritos, ponderação do sinal transmitido através do controle de liberação de neurotransmissores durante a sinapse, processamento da informação no corpo celular através do potencial de ativação e propagação da informação através dos axônios para os próximos neurônios (HODGKIN *et al.*, 1952).

5.2 O NEURÔNIO ARTIFICIAL

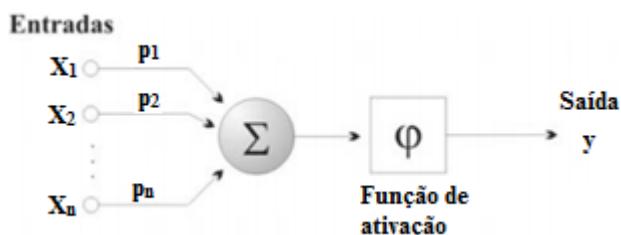
As RNAs tem como base de inspiração o sistema nervoso humano. Dessa forma, é necessário, antes de tudo, criar um modelo de neurônio artificial com a mesma capacidade de processamento de informação do neurônio biológico. Para isso, foram utilizados modelos computacionais inspirados a partir da análise da geração e propagação de impulsos elétricos pela membrana celular dos neurônios.

Os neurônios artificiais fornecem saídas tipicamente contínuas e realizam funções simples, como coletar sinais existentes em suas entradas, agregá-los de acordo com sua função operacional e produzir uma resposta, levando em consideração seu limiar de ativação inerente (θ), assim como no sistema nervoso humano.

Como representado pela **Figura 16**, a importância de cada entrada dos neurônios artificiais é modelada através de pesos sinápticos $\{p_1, p_2, \dots, p_n\}$. O peso de cada entrada do neurônio artificial $\{x_i\}$ é levado em consideração através da multiplicação de cada entrada por sua respectiva ponderação $\{p_i\}$. Dessa forma, todas as entradas são multiplicadas por algum fator pré-determinado pelo neurônio. Já a saída do corpo celular artificial $\{u\}$ é determinada pela diferença do valor produzido entre o corpo celular e o limiar de ativação. A saída final do neurônio artificial $\{y\}$ consiste na aplicação de alguma função sobre a saída intermediária $\{u\}$ (**Figura 16**).

A adequação de uma RNA para a utilização na solução de determinado problema é realizada através de um treinamento que consiste na aplicação de algoritmos pré-determinados de acordo com o método a ser implantado, visando ajustar os pesos e os limiares dos neurônios artificiais para que as respostas a determinadas entradas estejam dentro dos valores esperados (DA SILVA *et al.*, 2010).

Figura 16 – Modelo matemático simplificado de um neurônio artificial



Fonte: Adaptado de Haykin (2001).

Assim, é possível modelar o comportamento de cada neurônio artificial através de duas expressões matemáticas, representadas pelas Equações (1) e (2)

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

$$y = g(u) \quad (2)$$

Basicamente, a arquitetura geral de uma rede neural artificial pode ser resumida em três partes: camada de entrada, camadas intermediárias e camada de saída (DA SILVA *et al.*, 2010).

Durante o desenvolvimento deste trabalho, será analisada a possível utilização de uma rede do tipo PMC devido às evidências do seu desempenho para o problema, já constatadas por BOTTURA *et al.* (2010), CAMARGO (2012) e LIMA (2014). Assim, é interessante a realização de uma breve abordagem sobre seu funcionamento.

5.3 REDE PMC

As redes PMC são formadas por camadas de entrada e de saída, com pelo menos uma camada intermediária entre elas. A camada de entrada é composta pelos neurônios artificiais que representam as variáveis de entrada do sistema, também conhecida como entrada do problema. Já a camada intermediária faz com que o modelo possa ser utilizado em situações reais, pois imprime não linearidades no entendimento e solução dos problemas a rede. Por fim, a camada de saída representa a resposta da rede frente ao problema analisado.

Este modelo de RNA utiliza o método de aprendizado supervisionado que consiste no conhecimento prévio dos resultados esperados da rede. Dessa forma, é possível analisar o erro entre as respostas fornecidas e desejadas e corrigir os pesos dos neurônios com o intuito de diminuir este erro até valores aceitáveis. Vale comentar que o processo de ajuste manual dos pesos citados despende muito tempo pelo fato da existência de uma ou mais camadas intermediárias com erro desconhecido, fazendo-se necessária a utilização de algoritmos de otimização, como o *Backpropagation* (BRAGA *et al.*, 2000).

5.4 UTILIZAÇÃO DAS RNAs VIA SOFTWARE

O Matlab® é um software desenvolvido pela *The Math Works, Inc*, que permite representar as soluções e problemas em linguagem matemática baseados em matrizes, sendo possível realizar análises numéricas, construção de gráficos, operações com matrizes e, principalmente, a implementação de RNA, dentre outras. Este *software* foi designado para o presente trabalho devido a sua facilidade de gerar e depurar um programa quando comparado com as demais linguagens de

programação. Os principais passos para a implementação das RNAs no software (MATSUNAGA, V. Y.,2012):

- Definição dos dados de entrada e saída;
- Inicialização da rede, definido os limites dos padrões de entrada, o número de neurônios artificiais presentes em cada camada da RNA, a função de transferência de cada camada e o algoritmo de treinamento;
- Definição dos parâmetros de treinamento, tais como número máximo de épocas de treinamento, erro desejado, número de iterações que aparecem na tela, taxa de aprendizado e tempo máximo para o treinamento;
- Treinamento da rede; e
- Simulação da rede.

Contudo, para a realização de todas as etapas, são necessários comandos específicos determinados pelo software, conforme mostra a **Tabela 4**.

Tabela 4 – Comandos para a criação de uma RNA via Matlab®

Função	Comando via software
Criação de uma nova rede	<i>newff</i>
Treinamento da rede	<i>train</i>
Simulação da rede	<i>sim</i>

Fonte: Adaptado de Matrunaga (2012).

As principais funções de transferência e os algoritmos de aprendizado das RNAs estão descritas na **Tabela 5** e **Tabela 6**, respectivamente.

Tabela 5 - Principais funções utilizadas na implementação de RNAs via Matlab®.

Função	Descrição
<i>purelin</i>	Linear
<i>tansig</i>	Tangente Hiperbólica
<i>logsin</i>	Sigmóide
<i>satlin</i>	Linear com saturação

Fonte: Adaptado de Matsunaga (2012).

Tabela 6 - Principais algoritmos de treinamento das RNAs.

Algoritmo	Tipo de treinamento <i>Backpropagation</i>
<i>trainlm</i>	Levenberg-Marquardt
<i>traingd</i>	Gradiente decrescente
<i>traingdm</i>	Gradiente decrescente com momentum
<i>trangda</i>	Gradiente com taxa adaptativa
<i>trangdx</i>	Gradiente decrescente com momentum e taxa adaptativa

Fonte: Adaptado de Matsunaga (2012).

Os principais parâmetros de treinamento que precisam ser definidos no código estão resumidos na **Tabela 7**.

Tabela 7 - Descrição dos parâmetros de treinamento das RNAs via Matlab®.

Parâmetro	Descrição
<i>net.train.Param.epochs</i>	Número máximo de épocas de treinamento
<i>net.train.Param.goal</i>	Erro desejado
<i>net.train.Param.show</i>	Número de iterações que aparece na tela
<i>net.train.Param.Ir</i>	Taxa de aprendizado
<i>net.train.Param.time</i>	Tempo máximo (em segundos) para o treinamento

Fonte: Adaptado de Matsunaga (2012).

6 A SIMULAÇÃO COMPUTACIONAL

Este tópico visa introduzir os conceitos sobre circuitos elétricos utilizados nas simulações computacionais, bem como justificar a escolha do tipo de modelagem realizada via o software ATP, além de apresentar todas as faltas elétricas consideradas no sistema e os parâmetros dos demais elementos.

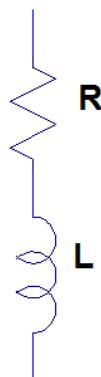
6.1 ANÁLISE DAS CONDIÇÕES DE SIMULAÇÃO

Para o sistema elétrico de potência, os consumidores conectados à rede elétrica são reconhecidos como cargas, pois consomem potência ativa e reativa fornecida pelo sistema elétrico. Estas cargas podem ser representadas, em nível de modelagem, como uma associação série ou paralelo de resistores e indutores. Assim, é necessária uma breve introdução às características de cada arranjo para a escolha de uma que melhor se adeque ao propósito deste trabalho.

6.1.1 ASSOCIAÇÃO SÉRIE

A associação série de resistores (R) e indutores (L) por fase pode ser representada esquematicamente pela **Figura 17**.

Figura 17 – Associação série de resistores e indutores.



Fonte: Adaptado de Johnson, Hilburn e Johnson. (1994).

Desenvolvendo-se as equações básicas de circuitos elétricos (JOHNSON *et. al.*, 1994), tem-se:

$$S = \frac{|\dot{V}|^2}{Z} \quad (3)$$

$$S = \frac{|\dot{V}|^2}{R + jwL} \quad (4)$$

$$S = \frac{|\dot{V}|^2 \cdot (R - jwl)}{R^2 + (wL)^2} \quad (5)$$

$$S = \frac{|\dot{V}|^2 \cdot R}{R^2 + (wL)^2} - \frac{|\dot{V}|^2 \cdot jwl}{R^2 + (wL)^2} \quad (6)$$

Onde,

- S: valor da potência aparente do circuito;
- R: valor da resistência do circuito;
- L: valor da indutância do circuito;
- j: operador imaginário;
- w: frequência angular do circuito; e
- Z: valor da impedância do circuito.

Então, tem-se que a potência ativa (P) e reativa (Q) da associação série são representadas pelas **Equações 5 e 6**.

$$P = \frac{|\dot{V}|^2 \cdot R}{R^2 + (wL)^2} \quad (7)$$

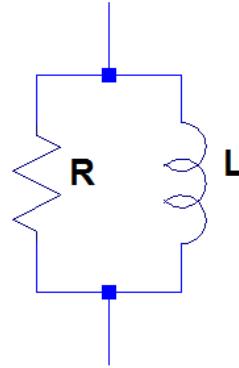
$$Q = - \frac{|\dot{V}|^2 \cdot wl}{R^2 + (wL)^2} \quad (8)$$

É possível ressaltar que esta associação, segundo as **Equações 7 e 8**, possui valores de potência ativa dependente tanto de R quanto de L, valendo o mesmo para a potência reativa. Ou seja, a modificação dos valores das resistências desta associação modifica tanto a potência ativa quanto a potência reativa do sistema.

6.1.2 ASSOCIAÇÃO PARALELO

A associação paralela de resistores e indutores por fase pode ser representada esquematicamente pela **Figura 18**.

Figura 18 - Associação paralela de resistores e indutores.



Fonte: Adaptado de Johnson, Hilburn e Johnson. (1994).

Desenvolvendo-se as equações básicas de circuitos elétricos (JOHNSON *et. al*, 1994), tem-se:

$$S = \frac{|\dot{V}|^2}{Z} \quad (9)$$

$$S = \frac{|\dot{V}|^2}{\frac{R \cdot jwl}{R + jwl}} \quad (10)$$

$$S = \frac{|\dot{V}|^2}{\frac{R \cdot jwl}{R + jwl}} \quad (11)$$

$$S = \frac{|\dot{V}|^2 \cdot R}{R \cdot jwl} + \frac{|\dot{V}|^2 \cdot jwl}{R \cdot jwl} \quad (12)$$

$$S = \frac{|\dot{V}|^2}{jwl} + \frac{|\dot{V}|^2}{R} \quad (13)$$

Então, tem-se que a potência ativa e reativa da associação paralela são representadas pelas **Equações (14) e (15)**.

$$P = \frac{|\dot{V}|^2}{R} \quad (14)$$

$$Q = - \frac{|\dot{V}|^2}{wl} \quad (15)$$

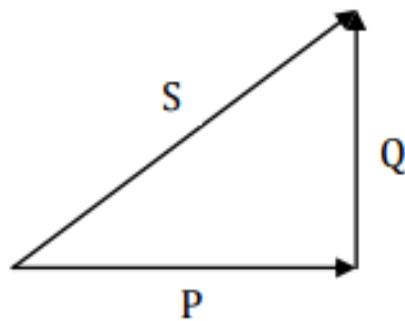
É possível ressaltar que esta associação, segundo as **Equações (14) e (15)**, possui valores de potência ativa dependente somente de R, enquanto o valor da potência reativa depende somente de L, facilitando a manipulação dos valores das cargas para cada situação.

6.1.3 FATOR DE POTÊNCIA

O fator de potência (FP) é definido como a relação entre a potência ativa e aparente, sendo representada pela **Equação (16)**. Já a **Figura 19** representa o triângulo de potências, relacionando a potência aparente, potência ativa e potência reativa.

$$FP = \frac{P}{S} \quad (16)$$

Figura 19 - Triângulo de potências.



Fonte: Adaptado de Johnson, Hilburn e Johnson. (1994).

A **Figura 19** ilustra o triângulo de potências, onde o ângulo φ apresentado na **Equação (16)** refere-se a medida de ângulo entre a potência ativa (P) e a de potência aparente (S). Dessa forma,

é possível reescrever a fórmula do FP na forma da **Equação (17)** para um sistema trifásico com frequência de 60 Hz, como o sistema analisado no presente trabalho.

$$FP = \cos \left[\operatorname{Atan} \left(\frac{Q}{P} \right) \right] \quad (17)$$

Vale ressaltar que o fator de potência indica a circulação de potência ativa e reativa na rede, sendo que baixo valores de fator de potência de uma carga indicam grandes quantidades de potência reativa requisitada, potência esta que não realiza trabalho útil e ocasiona aumento nas perdas da rede elétrica, quedas e flutuações de tensão nas redes de distribuição e limitação na capacidade dos condutores e equipamentos da rede. Dessa forma, a portaria do DNAEE nº 085 foi publicada em 25 de março de 1992 e estipulou que o limite mínimo do fator de potência seria de 0,92 indutivo (ANEEL, 2012b).

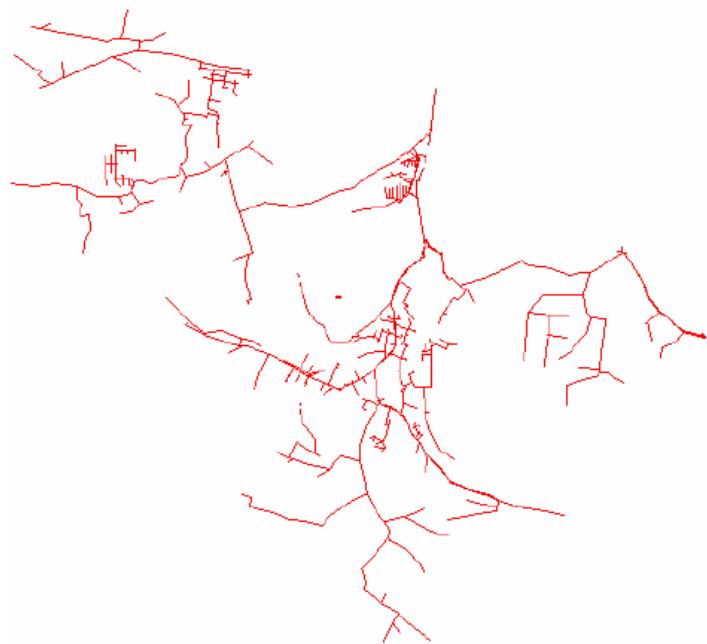
6.2 MODELAGEM DO SISTEMA DE DISTRIBUIÇÃO

6.2.1 CARGAS PREVIAMENTE MODELADAS

O sistema de distribuição analisado foi previamente modelado no software ATP como resultado de uma cooperação entre o Laboratório de Sistemas de Energia Elétrica (LSEE) da Escola de Engenharia Elétrica (EESC-USP) e uma concessionária de energia regional, sendo já utilizado para o desenvolvimento das pesquisas anteriores (BOTTURA *et al.* (2010), CAMARGO (2012) e LIMA (2014)).

A modelagem refere-se a dois alimentadores conectados a um transformador, pertencentes à subestação de Boituva. A distribuição geográfica de cada alimentador pode ser verificada na **Figura 20** e **Figura 21**.

Figura 20 – Distribuição geográfica do alimentador 1.



Fonte: CPFL (2009).

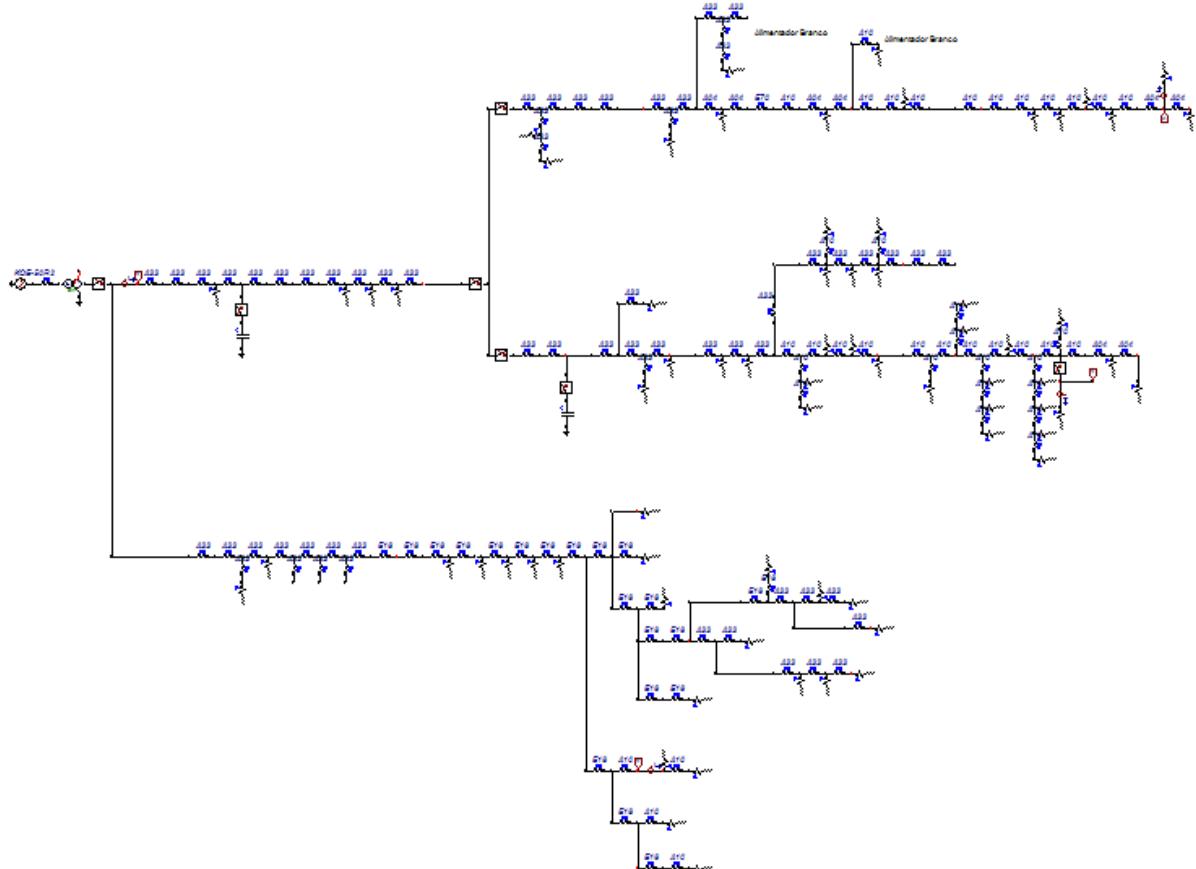
Figura 21 - Distribuição geográfica do alimentador 2.



Fonte: CPFL (2009).

Já na **Figura 22** é possível observar o diagrama unifilar do sistema elétrico modelado no software ATP.

Figura 22 – Modelo do diagrama unifilar do SD previamente modelado no ATP.



Fonte: CPFL (2009).

Todas as informações referentes às cargas, representadas por uma resistência em série com uma indutância nas simulações, podem ser encontradas na **Tabela 18** do apêndice.

É primordial, para o desenvolvimento desta pesquisa, o entendimento da metodologia utilizada para a obtenção do SD previamente modelado. Dessa forma, através dos dados fornecidos pela **Tabela 9**, é possível observar que os valores das resistências e indutâncias utilizadas na modelagem foram especificados para representar aproximadamente 92% e 0,0000392% da demanda contratada de potência ativa e reativa, respectivamente, conforme apresentado na **Tabela 19** do apêndice.

Assim, a modelagem já realizada e utilizada em trabalhos anteriores, como os de BOTTURA *et al.* (2010), CAMARGO (2012) e LIMA (2014), foi realizada considerando-se cargas equivalentes a aproximadamente 92% da demanda contratada de cada consumidor industrial. Através

dos valores de resistência e indutância utilizados nas simulações, também é possível concluir que a potência reativa de cada consumidor industrial representa aproximadamente 0,0000392% da demanda contradada. Este baixo valor de potência reativa resulta também em fator de potência quase unitário. Assim, a modelagem já realizada considera um cenário quase ideal, onde o fator de potência de cada consumidor aproxima-se do valor unitário.

6.2.2 ANÁLISE DO SEP PREVIAMENTE MODELADO

Antes de dar continuidade à modelagem e adaptação do SEP para os diferentes perfis de carga apresentados neste trabalho, foi realizada uma análise minuciosa do sistema já modelado com o intuito verificar se todas as cargas apresentadas em trabalhos anteriores foram devidamente modeladas no software ATP.

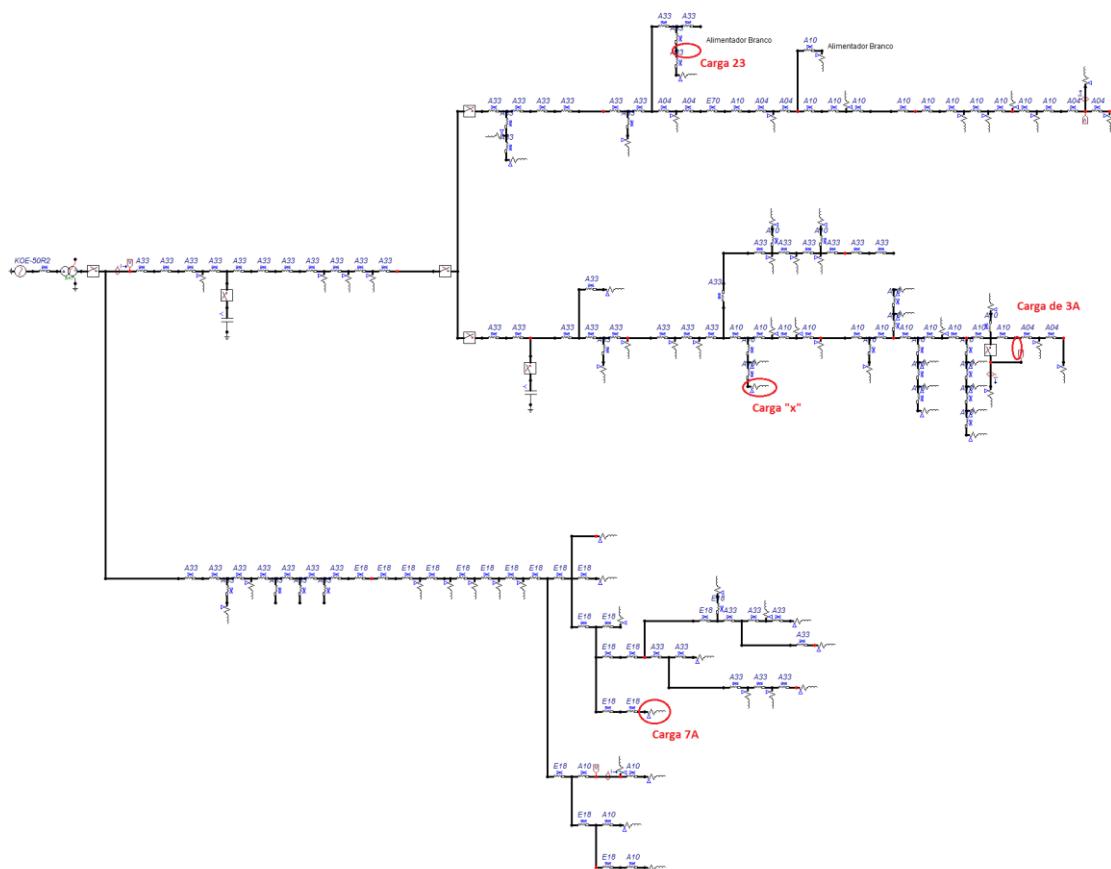
Durante essa fase da pesquisa, verificou-se a ausência das seguintes cargas:

- Carga 23;
- Carga representada por corrente de 3A (ao lado da Carga 6); e
- Carga “x” localizada ao lado da Carga 15.

Por fim, detectou-se uma incoerência da carga representada por uma corrente de 1A e nomeada como 7A (ao lado da carga 37).

Todas as situações mencionadas estão marcadas em vermelho na **Figura 23**.

Figura 23 – Divergências encontradas na modelagem previamente realizada.



Fonte: Adaptado de CPFL (2009).

Vale ressaltar que as análises realizadas se baseiam em incoerências entre a modelagem e os valores documentados das cargas. Entretanto, as cargas citadas acima podem ter sido agrupadas e não alteradas nos relatórios de modelagem. Estes detalhes de modelagem são apresentados neste tópico com o intuito de auxiliar posteriores projetos de pesquisa que venham a utilizar a mesma modelagem deste trabalho.

6.2.3 CARGAS A SEREM MODELADAS

Através da análise do SD previamente modelado, foi possível perceber que o fator de potência das cargas foi próximo de um, situação pouco próxima da realidade, principalmente pelo fato de tratar-se de cargas industriais. Segundo SILVA (2009), em ramos de atividade industrial e até

mesmo em edificações e complexos comerciais de médio a grande porte, existem quantidades significativas de equipamentos elétricos que possuem como característica principal uma rápida dinâmica operacional, mudando em um curto intervalo de tempo entre o estado de operação em vazio para o funcionamento em carga plena. Estas cargas apresentam fator de potência médio operacional relativamente baixo, fundamentalmente por consumirem grandes quantidades de energia reativa nos intervalos de tempo onde ocorre a mudança de estado. Assim, ressaltando-se o fato de que um dos objetivos desta pesquisa trata da adequação da metodologia apresentada para casos mais próximos da realidade, todas as cargas utilizadas nas modelagens serão alteradas para um arranjo em paralelo e adequadas para a obtenção de um fator de potência equivalente a 0,96, uma vez que o mínimo exigido pela ANEEL é de 0,92.

Além da modificação das cargas para adequação a um fator de potência mais próximo da realidade das cargas industriais, estas também serão modificadas na modelagem para uma associação paralelo, pois o arranjo em paralelo de resistores e indutores permite uma manipulação de forma direta nos valores de potência ativa e reativa das cargas desejados, apenas modificando os valores de R e L, respectivamente. Ou seja, o valor de R adotado influenciará somente no valor de P da modelagem e o valor de L, em Q. Esta facilidade de manipulação dos dados das modelagens é de suma importância para o trabalho, uma vez que as cargas serão modificadas para até três valores diferentes, representando as variações características dos perfis das cargas no decorrer de um dia. Vale ressaltar que esta facilidade de modificação de valores não poderia ser alcançada caso fosse utilizada uma associação série de resistores e indutores. Dessa forma, todos os dados referentes aos valores médio, máximo e mínimo das novas cargas a serem modeladas pelo software ATP podem ser verificados nas **Tabelas 18, 19 e 20** do apêndice, respectivamente. Além disso, foi adotado o fator de potência 0,96 indutivo para todas as cargas.

Os estudos realizados para a determinação das novas cargas a serem modeladas será apresentado no capítulo 8 deste trabalho, sendo as principais considerações adotadas apresentadas na **Tabela 8**.

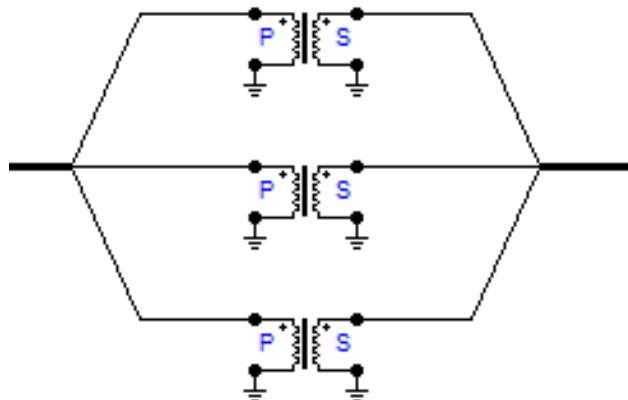
Tabela 8 – Critérios de modelagem das novas cargas

Tipo de carga	Potência ativa modelada
Carga Mínima	10% da potência instalada de cada consumidor
Carga média	Valor igual ao da demanda contratada de cada consumidor
Carga máxima	Valor igual ao da potência instalada de cada consumidor

Fonte: Autoria própria (2017).

Após a definição dos valores de resistência e indutância a serem utilizados como modelo equivalente para cada situação de perfil de carga, tomou-se o cuidado para que as novas simulações representassem ao máximo o SEP real. Dessa forma, foram adicionados, quando necessário, modelos de reguladores de tensão, conforme pode ser observado na **Figura 24**. Isso foi realizado de forma que a tensão no sistema elétrico permaneça sempre entre a faixa de 1,1 p.u. e 0,9 p.u.. A necessidade ou não de se utilizar reguladores de tensão foi verificada através da constante simulação do fluxo de carga do SEP modelado. Normalmente, a regulação de tensão é realizada através de reguladores de tensão ou transformadores reguladores, comumente instalados no barramento da subestação, ou também ao longo das linhas (Manual de Equipamentos elétricos, 2005). Para o presente trabalho, considerou-se a utilização de transformadores ideais para a realização da regulação de tensão, conforme mostra a **Figura 24**.

Figura 24 - Modelo do regulador de tensão implementado via o software ATP.



Fonte: Adaptado do Manual de Equipamentos elétricos (2005).

6.3 SIMULAÇÕES VIA O SOFTWARE ATP

Após a definição do valor de todas as cargas a serem inseridas no SD, é necessário definir as situações das quais o sistema elétrico analisado poderá estar submetido no decorrer do tempo, visando à obtenção de um modelo próximo da realidade. Para isso, foram considerados diferentes tipos, impedâncias e ângulos de inserção das faltas, bem como diferentes cargas. Quanto aos tipos de falta, serão considerados:

- Faltas monofásicas envolvendo a fase A com conexão a terra;
- Faltas monofásicas envolvendo a fase B com conexão a terra;

- Faltas monofásicas envolvendo a fase C com conexão a terra;
- Faltas bifásicas entre as fases A e B;
- Faltas bifásicas entre as fases A e C;
- Faltas bifásicas entre as fases B e C;
- Faltas bifásicas entre as fases A e B com conexão a terra;
- Faltas bifásicas entre as fases A e C com conexão a terra;
- Faltas bifásicas entre as fases B e C com conexão a terra;
- Faltas trifásicas sem a conexão a terra; e
- Faltas trifásicas com a conexão a terra.

Em relação ao tipo de carga conectada, serão considerados:

- Carga máxima de cada ponto de consumo, adotada como a potência instalada;
- Carga mínima de cada ponto de consumo, obtida através do estudo de diferentes perfis de carga de consumidores industriais; e
- Carga média de cada ponto de consumo, obtida através da demanda contratada de cada ponto.

Já em relação ao ângulo de incidência da falta, serão adotados:

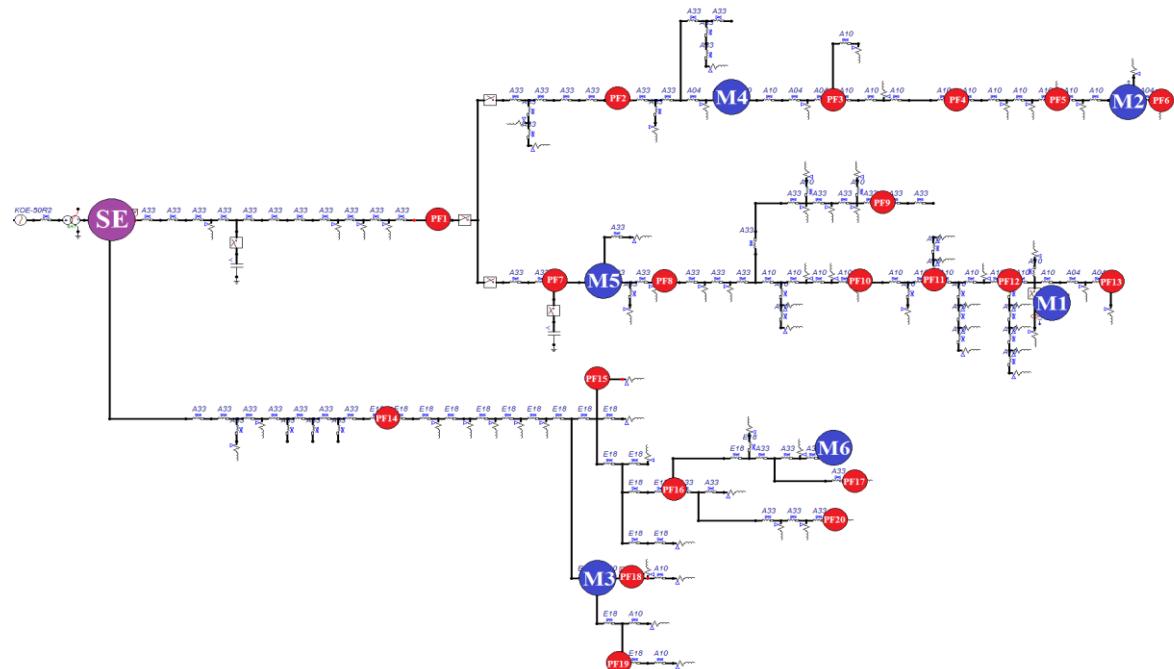
- Ângulo de incidência de 0° ; e
- Ângulo de incidência de 90° .

Em relação às impedâncias de falta, serão adotados os valores de 0, 10, 20, 30 e 40 Ω .

Por fim, as faltas serão inseridas em 20 pontos diferentes do SD, escolhidos de forma a abranger todo o sistema. A localização exata da subestação, dos pontos de inserção das situações de faltas e de monitoramento pode ser observada na **Figura 25**, sendo representados pelas seguintes siglas:

- SE: Subestação;
- Mn ($n = 1, 2, 3, 4, 5$ e 6): Pontos de monitoramento; e
- PFn ($n = 1, 2, 3, 4, \dots, 20$): Pontos de aplicação das faltas.

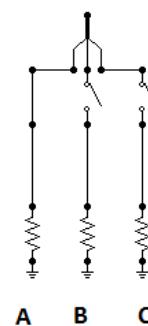
Figura 25 – Posicionamento dos pontos de aplicação das situações de faltas, monitoramento e da subestação de energia no SD.



Fonte: Adaptado de CPFL (2009).

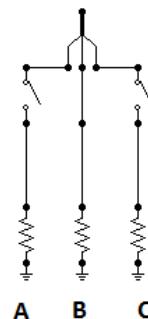
Para a aplicação das faltas, foram utilizadas chaves elétricas no software ATP, definindo-se o instante de tempo no qual ocorre o fechamento e a abertura das mesmas. Além disso, o software possibilita a escolha de qual chave será aberta ou fechada, possibilitando a simulação de todos os tipos de falta considerados neste trabalho. Um exemplo desta aplicação pode ser verificado na **Figura 26**, **Figura 27** e **Figura 28**, onde são simuladas faltas monofásicas nas fases A, B e C, respectivamente, com o envolvimento da terra.

Figura 26 - Exemplo de falta monofásica envolvendo a fase A com conexão a terra.



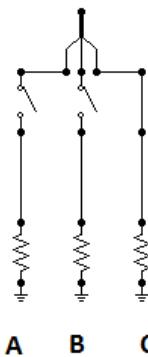
Fonte: Adaptado de Stevenson (1974).

Figura 27 - Exemplo de falta monofásica envolvendo a fase *B* com conexão a terra.



Fonte: Adaptado de Stevenson (1974).

Figura 28 - Exemplo de falta monofásica envolvendo a fase *C* com conexão a terra.



Fonte: Adaptado de Stevenson (1974).

Através do software ATP foi possível estabelecer o tempo de fechamento de cada chave, caracterizando faltas em diferentes ângulos de incidência. A escolha dos instantes de fechamento e abertura das chaves foi realizada de forma a atender aos seguintes critérios:

- Fechamento realizado somente quando o SEP está em regime; e
- Chaves mantidas fechadas pelo tempo de 1 segundo.

Dessa forma, foram escolhidos os instantes de tempo explicitados na **Tabela 9** de forma a caracterizar os diferentes ângulos de incidência das faltas.

Tabela 9 - Tempos de abertura e fechamento das chaves

Ângulo de incidência	Instante de tempo de fechamento das chaves	Instante de tempo de abertura das chaves
0 graus	0,56983 segundos	1,56983 segundos
90 graus	0,57399 segundos	1,57399 segundos

Fonte: Autoria própria (2017).

Assim, dado que a frequência do sistema elétrico modelado é de 60 Hz, o período de um ciclo da forma de onda possui o valor de 0,0166 segundos. Logo, a diferença de tempo entre o ângulo de incidência de zero e noventa graus é de $\frac{1}{4}$ de ciclo, ou seja, 0,00416 segundos, justificando a diferença dos tempos de fechamento das chaves da **Tabela 9**.

Finalmente, foram considerados 20 pontos de aplicação das situações de faltas, submetidos a 11 tipos de falta, 5 valores diferentes de impedância de falta, 2 ângulos de incidência da falta e 3 valores distintos de carga para cada consumidor, totalizando 6.600 casos distintos, conforme pode ser verificado na **Tabela 10**.

Tabela 10 - Quantidade de casos por ponto de falta.

Tipo	Quantidade (por ponto de falta)
Carga	3
Ângulo de incidência	2
Impedância	5
Tipos de falta	11
Total de casos por ponto de falta	330
Pontos de falta	20
Total de casos	6.600

Fonte: Autoria própria (2017).

Assim, serão obtidos valores das tensões eficazes em 6 pontos diferentes do SEP em análise, e também valores das correntes e tensões eficazes na subestação, completando o banco de dados resultante das simulações.

7 APLICAÇÃO E TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS

Este tópico visa apresentar a metodologia utilizada para a obtenção e formatação do banco de dados e sua respectiva utilização durante a etapa de treinamento das redes neurais artificiais propostas.

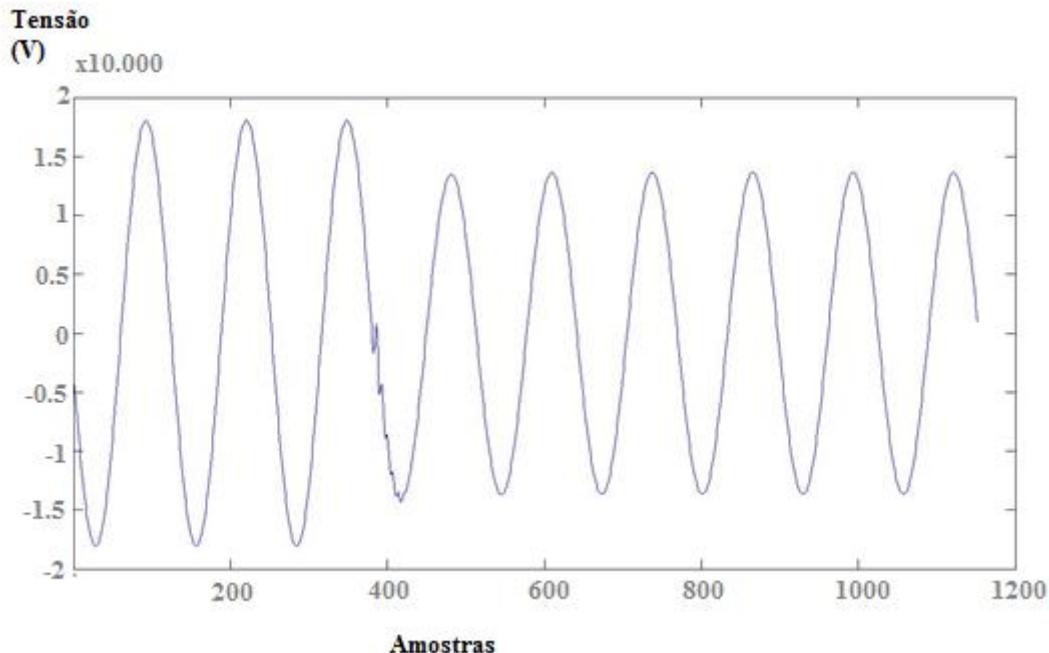
7.1 O BANCO DE DADOS GERADO

Após a realização de todas as simulações referentes aos diferentes perfis de carga e de falta, foram obtidos 6.600 padrões para serem utilizados como banco de dados. A saída do *software ATP* foi configurada para fornecer como resultado as formas de ondas amostradas das tensões trifásicas nos 6 pontos de monitoramento, bem como as formas de ondas das tensões e correntes trifásicas da subestação. Todos os sinais são amostrados por 128 valores por ciclo de onda (60 Hz), ou seja, cada ciclo da senóide é representado computacionalmente por 128 amostras. Entretanto, o banco de dados será formado pelos valores eficazes destas formas de onda. Logo é necessário um tratamento prévio destes dados.

A manipulação do banco de dados e implementação das RNAs será realizado via Matlab. Todavia, o software ATP gera arquivos de saída no formato *.pl4*, o qual não é compatível com o Matlab. Logo, foi necessária a implementação de um código via Matlab para executar um programa externo que converte o arquivo *.pl4* em *.mat*, conforme pode ser verificado no **Anexo 1**, possibilitando a fácil manipulação dos dados gerados.

Com todos os dados convertidos corretamente, realizou-se o recorte das formas de onda fornecidas pelo software ATP, selecionando-se a parcela da onda que continha os dados mais significativos para às RNAs, consistindo de 9 ciclos da onda, sendo 3 de pré-falta, e 6 de pós falta, conforme apresentado na **Figura 29**.

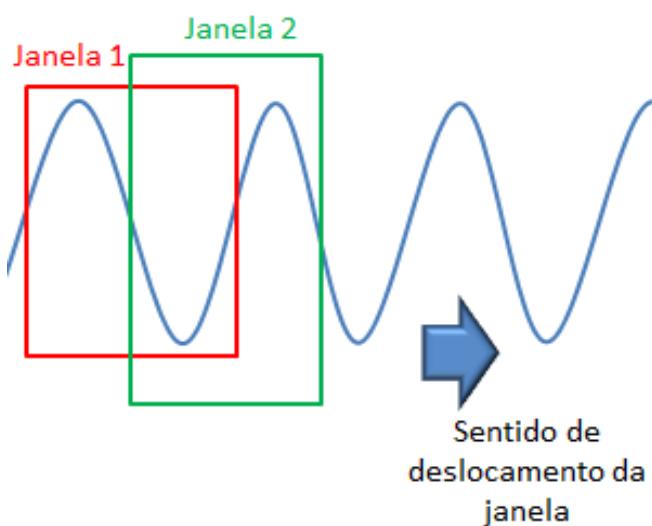
Figura 29 – Parcela da forma de onda da tensão da fase A na subestação para o ponto de falta 1 (PF1), ângulo de incidência zero graus e falta franca.



Fonte: Autoria própria (2017).

Após o recorte de todas as formas de ondas, foi aplicada uma janela deslizante com dimensão de um ciclo, considerando-se um deslocamento de meio ciclo, para o cálculo dos valores RMS, conforme ilustrado na **Figura 30**.

Figura 30 – Janela deslizante aplicada sobre os sinais.



Fonte: Autoria própria (2017).

Dessa forma, foram obtidos 17 valores RMS para cada forma de onda, sendo seis de pré-falta e onze de pós falta. Assim, o banco de dados para as RNAs é composto por 6.600 casos, cada caso contendo 17 valores RMS, resultando em 112.200 pares de entrada e saída.

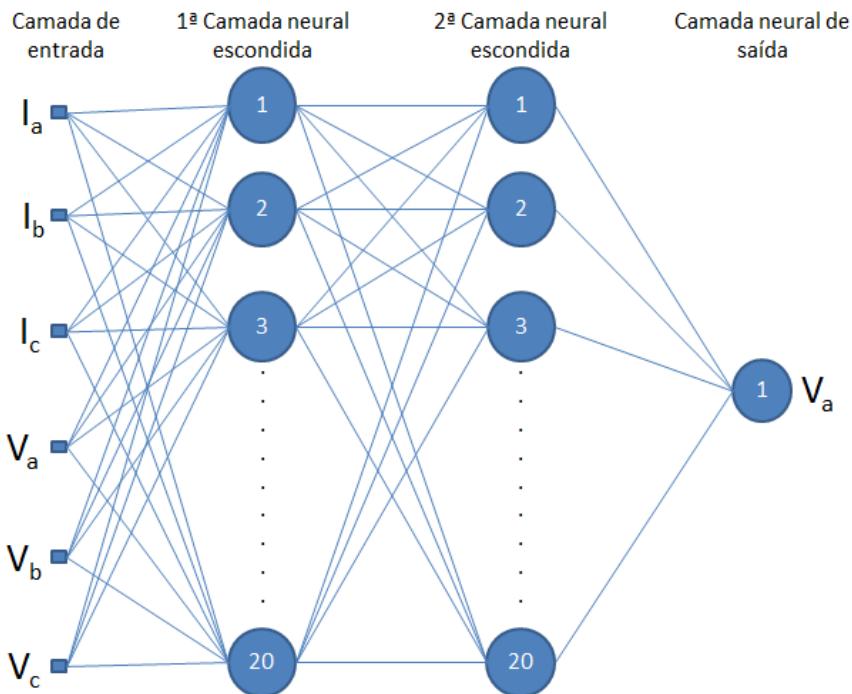
Para finalizar o tratamento do banco de dados, todos os valores de tensão e corrente foram normalizados em relação aos valores nominais verificados junto a SE. Estes valores nominais de tensão e corrente foram obtidos na SE através da simulação do fluxo de carga do SEP modelado em condições nominais de operação. Vale ressaltar que foram obtidos 3 valores distintos de valor nominal para as tensões e correntes trifásicas, dado que foram simuladas três situações distintas de carga (leve, média e pesada).

7.2 A FASE DE TREINAMENTO DAS RNAs

Para a aplicação desta pesquisa, serão utilizadas inicialmente redes do tipo PMC contendo 6 valores de entrada, 20 neurônios na primeira camada intermediária, 20 neurônios na segunda camada intermediária e 1 neurônio de saída (6-20-20-1). Assim como descrito em tópicos anteriores, este tipo de rede neural foi selecionada devido à comprovação de sua eficácia e alta precisão em problemas relacionados à SEPs segundo estudos de AGGARWAL *et al.* (1998), e como continuidade aos trabalhos de BOTTURA *et al.* (2010), CAMARGO (2012) e LIMA (2014).

Através da utilização das RNAs serão estimados os valores das tensões trifásicas em seis diferentes pontos de monitoramento. Entretanto, a RNA selecionada possui somente 1 neurônio na camada de saída, conforme ilustra a **Figura 31**, fazendo-se necessário a utilização de 3 RNAs para a estimativa das três tensões de um ponto de monitoramento. Dessa forma, serão implantadas 18 RNAs com a topologia 6-20-20-1. A **Tabela 11** mostra somente as RNAs utilizadas para o ponto de monitoramento 1 (M1), uma vez que os demais pontos de monitoramento seguem a mesma formatação.

Figura 31 – Rede neural do tipo 6-20-20-1 para a fase A.



Fonte: Adaptado de Haykin (2001).

Tabela 11 - RNAs utilizadas em cada ponto de monitoramento.

Ponto de monitoramento	Entrada da RNA	Saída da RNA	Topologia da RNA
M1	Valores eficazes das tensões e correntes trifásicas da subestação	Tensão eficaz da fase A	6-20-20-1
M1	Valores eficazes das tensões e correntes trifásicas da subestação	Tensão eficaz da fase B	6-20-20-1
M1	Valores eficazes das tensões e correntes trifásicas da subestação	Tensão eficaz da fase C	6-20-20-1

Fonte: Autoria própria (2017).

7.2.1 MÉTODOS DE ABORDAGEM

Reforçando que o principal objetivo deste trabalho é analisar o desempenho das RNAs mediante aos diferentes perfis de carga, serão utilizadas quatro diferentes abordagens para análise, de forma a se obter o melhor resultado possível. Os quatro métodos são:

- Método 0: Utilização das RNAs já treinadas por LIMA (2014) para validação dos três tipos de carga simulados;
- Método 1: Utilização de 70% do banco de dados da carga média para o treinamento e o restante para a validação;
- Método 2: Utilização de 70% do banco de dados da carga pesada e 70% do banco de dados da carga leve para o treinamento e o restante para a validação; e
- Método 3: Utilização de 70% do banco de dados da carga pesada, 70% do banco de dados da carga média e 70% do banco de dados da carga leve para o treinamento e o restante para validação.

Os métodos de treinamento das RNAs estão sumarizados na **Tabela 12**.

Tabela 12 – Banco de dados de treinamento e teste utilizados em cada método.

Método	Banco de dados Utilizado	Carga Leve	Carga Média	Carga Pesada
Zero	Treinamento	Redes já treinadas por LIMA (2014)	Redes já treinadas por LIMA (2014)	Redes já treinadas por LIMA (2014)
	Teste	100% (2.200 casos)	100% (2.200 casos)	100% (2.200 casos)
1	Treinamento	-	70% (1.540 casos)	-
	Teste	100% (2.200 casos)	30% (660 casos)	(2.200 casos)
2	Treinamento	70% (1.540 casos)	-	70% (1.540 casos)
	Teste	30% (660 casos)	100% (2.200 casos)	30% (660 casos)
2 - Modificado	Treinamento	50% (1.100 casos)	-	50% (1.100 casos)
	Teste	50% (1.100 casos)	100% (2.200 casos)	50% (1.100 casos)
3	Treinamento	70% (1.540 casos)	70% (1.540 casos)	70% (1.540 casos)
	Teste	30% (660 casos)	30% (660 casos)	30% (660 casos)

Fonte: Autoria própria (2017).

Após a aplicação dos quatro métodos de treinamento e teste das RNAs apresentadas, será possível selecionar a melhor metodologia para o contexto da pesquisa aqui apresentada. Dada a seleção do melhor método de treinamento, posteriormente será analisado o efeito do aumento do

número de neurônios das camadas intermediárias das RNAs sobre o índice de acertos. Para isso, serão treinadas as seguintes topologias de rede:

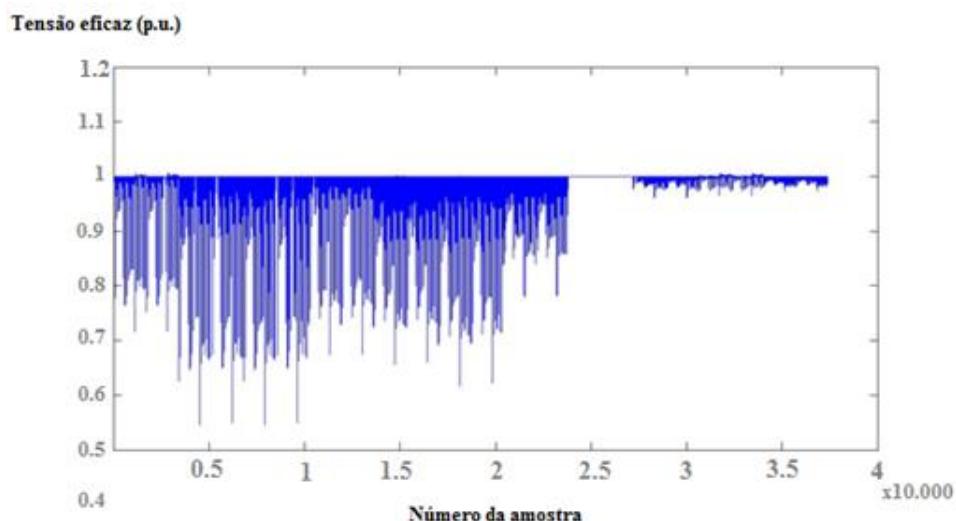
- 6-20-25-1;
- 6-25-25-1;
- 6-25-30-1;
- 6-30-30-1;
- 6-30-35-1;
- 6-35-35-1; e
- 6-50-50-1.

A proposta de aumento do número de neurônios justifica-se pela premissa do aumento da complexidade do problema devido à introdução dos diferentes perfis de carga, quando comparado aos trabalhos que antecedem este, como as pesquisas de BOTTURA *et al.* (2010), CAMARGO (2012) e LIMA (2014). Ressalta-se que esta premissa será fortificada ou enfraquecida de acordo com os resultados parciais do trabalho, os quais consistem na definição do melhor método de treinamento.

7.2.1.1 O TREINAMENTO ATRAVÉS DO MÉTODO 1

Para o método de abordagem 1, o banco de dados referente ao treinamento e validação das redes foi coletado de forma aleatória do banco de dados. Para isso, embaralhou-se os dados através de uma função implementada via Matlab®, conforme pode ser verificado no **Anexo 2**, concretizando a inexistência de dados que possam induzir as RNAs ao erro. O banco de dados original pode ser observado na **Figura 32**.

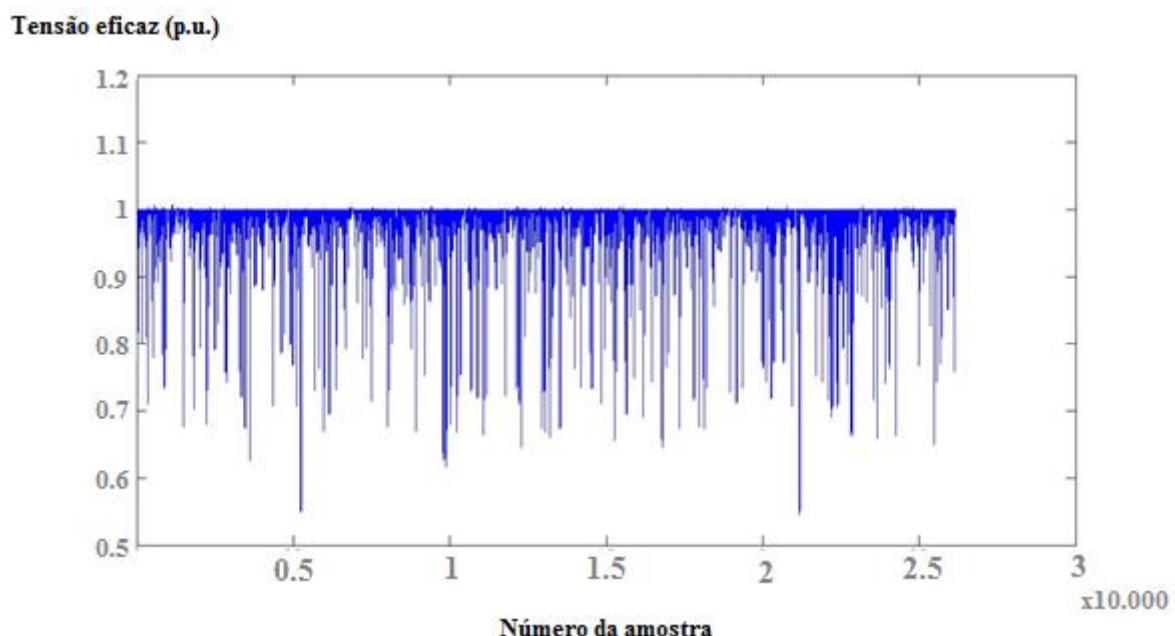
Figura 32 - Tensão eficaz da fase A da subestação para os diferentes tipos de curtos-circuitos considerados.



Fonte: Autoria própria (2017).

Já o vetor final de treinamento das RNAs pode ser observado na **Figura 33**.

Figura 33 – Banco de dados para o treinamento embaralhado, referente a tensão eficaz da fase A da subestação para o método 1.



Fonte: Autoria própria (2017).

Com o banco de dados de treinamento selecionado aleatoriamente, foram definidos os parâmetros de treinamento conforme a **Tabela 13**.

Tabela 13 - Parâmetros de treinamento das RNAs.

Número de épocas	800
Erro final desejado	10E-6
Função de ativação da camada 1	Tangente Hiperbólica
Função de ativação da camada 2	Tangente Hiperbólica
Função de ativação da camada 3	Linear (Rampa)
Algoritmo de Treinamento	Levenberg-Marquardt

Fonte: Lima (2014).

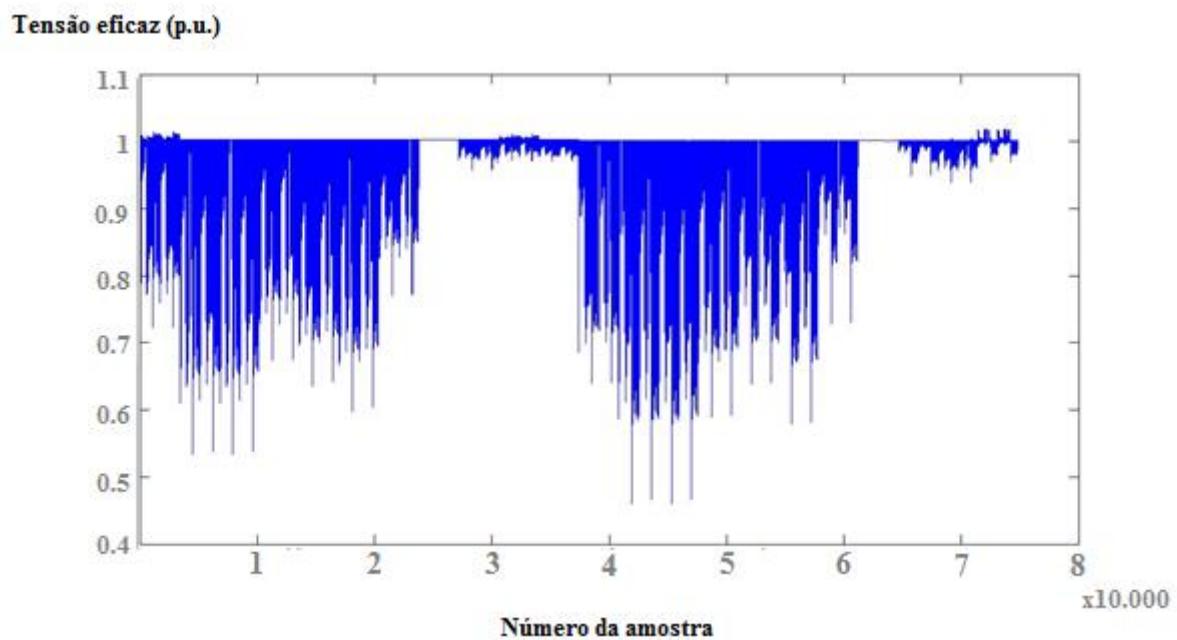
Com os dados acima, realizou-se o treinamento de todas as RNAs. Ou seja, foi realizado um total de 18 treinamentos para cada método.

7.2.1.2 O TREINAMENTO ATRAVÉS DO MÉTODO 2

Para o método 2, o banco de dados referente ao treinamento e validação das RNAs também foi coletado do banco de dados inicial referente as cargas leve e pesada. O banco de dados

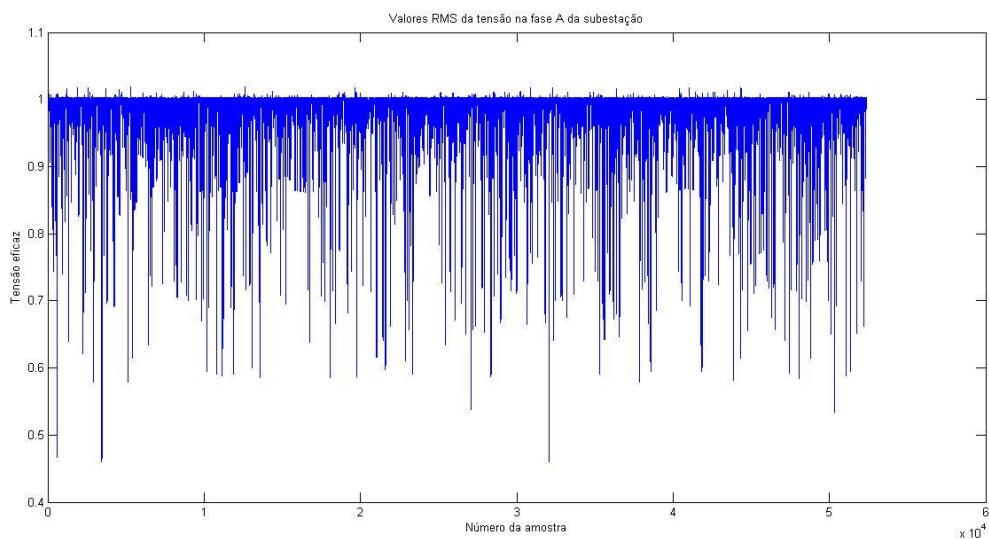
original e aquele utilizado para o treinamento das RNAs podem ser observados nas **Figuras 34 e 35**, respectivamente.

Figura 34 – Tensão eficaz da fase A da subestação para as cargas leve e pesada.



Fonte: Autoria própria (2017).

Figura 35 - Banco de dados aleatório (embaralhado) para o treinamento, referente a tensão eficaz da fase A da subestação para o método 2.

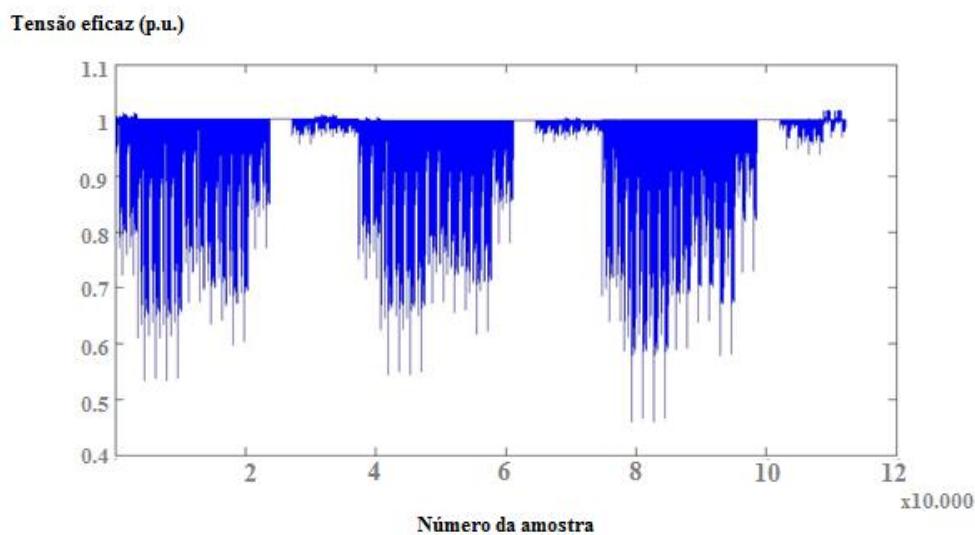


Fonte: Autoria própria (2017).

7.2.1.3 O TREINAMENTO ATRAVÉS DO MÉTODO 3

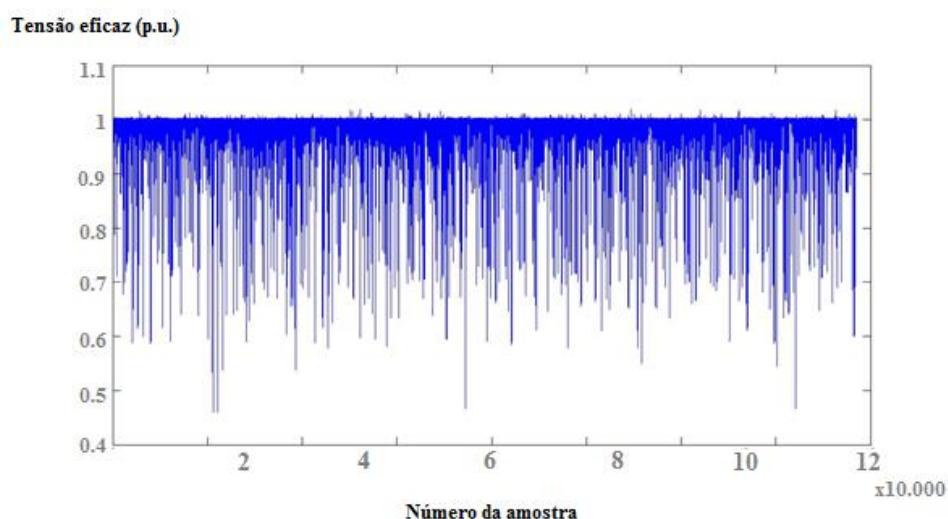
Para o método 3, o banco de dados referente ao treinamento e validação das RNAs foi coletado do banco de dados inicial referente as cargas leve e pesada. O banco de dados original e aquele utilizado para o treinamento das RNAs podem ser observados nas **Figuras 36** e **37**, respectivamente.

Figura 36 – Tensão eficaz da fase A da subestação para o método 3.



Fonte: Autoria própria (2017).

Figura 37 - Banco de dados de treinamento embaralhado, referente à tensão eficaz da fase A da subestação para o método 3.



Fonte: Autoria própria (2017).

8 A FASE DE TESTE DAS RNAs

Devido ao grande volume de dados e a semelhança dos resultados para os diferentes pontos de monitoramento, serão apresentadas apenas as tabelas contendo as consolidações referentes ao ponto de monitoramento 1 (M1) de cada método, os quais são apresentados nas seções de 8.1 a 8.5. Vale destacar que as análises referentes a cada método consideraram todos os pontos de monitoramento.

8.1 TESTE ATRAVÉS DO MÉTODO ZERO

Este tópico foi nomeado como método zero, pois serve como elo entre os trabalhos já realizados nesta linha de pesquisa e o presente trabalho, dado como continuação de BOTTURA *et al.* (2010), CAMARGO (2012) e LIMA (2014).

Dessa forma, foi utilizada a melhor topologia definida por LIMA (2014) para testar o desempenho das RNAs já treinadas quando submetidas aos diferentes perfis de carga. Vale ressaltar que as RNAs treinadas por LIMA (2014) e aqui utilizadas, não possuíram nenhum contato com o banco de dados referente às cargas leve e pesada.

8.1.1 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 1 (M1)

Tabela 14 - Erro das fases A, B e C do ponto de monitoramento 1 para as cargas média, leve e pesada do método zero.

Carga	Fase	Erro<0,01 p.u. (%)	Erro<0,03 p.u. (%)	Erro<0,05 p.u. (%)	Erro<0,07 p.u. (%)
Média	A	2,80	40,99	47,77	56,29
Média	B	3,90	59,18	63,70	67,36
Média	C	4,57	60,20	64,56	67,49
Leve	A	2,94	7,98	42,25	53,38
Leve	B	52,15	60,07	62,61	64,89
Leve	C	49,19	57,76	60,62	62,98
Pesada	A	3,10	8,23	41,79	47,64
Pesada	B	0,40	1,26	2,73	3,95
Pesada	C	0,66	2,23	3,82	5,44

Fonte: Autoria própria (2017).

Após a utilização das redes já treinadas foi possível constatar que o índice de acertos para os dados referentes à carga média permaneceu entre 50% e 60%, inferiores aos resultados obtidos por LIMA (2014). Esse fato pode ter sido ocasionado devido a uma mudança durante a fase de modelagem

do SEP, onde o fator de potência adotado foi de 0,96, inferior aos trabalhos anteriores. Dessa forma, o valor da potência reativa das cargas aumentou durante a fase de modelagem, justificando a ligeira mudança no banco de dados e redução do índice de acertos. Vale ressaltar que esta mudança foi realizada visando aproximar-se o fator de potência das cargas para casos mais reais.

Já o índice de acertos das cargas pesadas foi extremamente baixo, permanecendo entre 4% e 5%, com exceção da fase A do ponto de monitoramento 1, que adquiriu o valor de 47,64%. Esse fato evidencia a possibilidade da pouca abrangência de perfis de carga do banco de dados, uma vez que as RNAs por LIMA (2014) foram expostas somente ao caso de carga média. A comprovação e análise destas conclusões preliminares serão realizadas após a implantação do método 1 a seguir.

8.2 TESTE ATRAVÉS DO MÉTODO 1

Este tópico tem como objetivo mostrar o desempenho e a porcentagem de acerto das RNAs quando utilizado somente 70% dos dados referentes à carga média para a realização do treinamento das RNAs. A validação é realizada através da apresentação dos dados restantes (30% dos dados da carga média e 70% dos dados das cargas leve e pesada) à RNA treinada.

8.2.1 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 1 (M1)

Para as cargas médias deste conjunto de dados, a RNA referente à fase A apresentou os melhores resultados, sendo 75,03% das saídas com erro menor do que 0,01 p.u., 88,61% das saídas com erro menor do que 0,03 p.u., 93,96% das saídas com erro menor do que 0,05 p.u. e 96,43% das saídas com erro menor do que 0,07.

Entretanto, como o método 1 é caracterizado por possuir um banco de dados de treinamento composto apenas por dados de carga média, os resultados apresentados pelas RNAs para os demais casos mostraram-se insatisfatórios.

Para a situação de carga leve, a RNA referente à fase A apresentou os melhores resultados, sendo 4,32% das saídas com erro menor do que 0,01 p.u., 55,06% das saídas com erro menor do que 0,03 p.u., 58,22% das saídas com erro menor do que 0,05 p.u. e 59,82% das saídas com erro menor do que 0,07 p.u.

Já para a situação de carga pesada, a RNA referente a fase A apresentou os melhores resultados, sendo 0,40% das saídas com erro menor do que 0,01 p.u., 1,40% das saídas com erro menor do que 0,03 p.u., 2,33% das saídas com erro menor do que 0,05 p.u. e 3,38% das saídas com erro menor do que 0,07 p.u.

8.2.2 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 2 (M2)

O ponto de monitoramento 2 mostrou índices de acertos para os dados referentes a carga média superiores aos índices do ponto de monitoramento 1. Para este conjunto de dados, a RNA

referente à fase B apresentou os melhores resultados, sendo 75,37% das saídas com erro menor do que 0,01 p.u., 89,78% das saídas com erro menor do que 0,03 p.u., 94,69% das saídas com erro menor do que 0,05 p.u. e 96,57% das saídas com erro menor do que 0,07.

Entretanto, assim como no ponto de monitoramento 1, verificou-se um baixo índice de acertos para os demais tipos de carga.

Para a situação de carga leve, a RNA referente à fase A apresentou os melhores resultados, sendo 33,96% das saídas com erro menor do que 0,01 p.u., 50,72% das saídas com erro menor do que 0,03 p.u., 53,85% das saídas com erro menor do que 0,05 p.u. e 55,52% das saídas com erro menor do que 0,07 p.u.

Já para a situação de carga pesada, a RNA referente à fase B apresentou os melhores resultados, sendo 0,79% das saídas com erro menor do que 0,01 p.u., 3,28% das saídas com erro menor do que 0,03 p.u., 5,90% das saídas com erro menor do que 0,05 p.u. e 7,98% das saídas com erro menor do que 0,07 p.u.

8.2.3 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 3 (M3)

O ponto de monitoramento 3 mostrou índices de acertos para os dados referentes a carga média inferiores aos índices do ponto de monitoramento 2. Para este conjunto de dados, a RNA referente à fase B apresentou os melhores resultados, sendo 74,30% das saídas com erro menor do que 0,01 p.u., 88,89% das saídas com erro menor do que 0,03 p.u., 94,31% das saídas com erro menor do que 0,05 p.u. e 96,46% das saídas com erro menor do que 0,07.

Entretanto, assim como nos demais pontos de monitoramento, verificou-se um baixo índice de acertos para os demais tipos de carga.

Para a situação de carga leve, a RNA referente à fase A apresentou os melhores resultados, sendo 6,16% das saídas com erro menor do que 0,01 p.u., 53,91% das saídas com erro menor do que 0,03 p.u., 57,75% das saídas com erro menor do que 0,05 p.u. e 60,29% das saídas com erro menor do que 0,07 p.u.

Já para a situação de carga pesada, a RNA referente à fase B apresentou os melhores resultados, sendo 1,37% das saídas com erro menor do que 0,01 p.u., 4,93% das saídas com erro menor do que 0,03 p.u., 7,23% das saídas com erro menor do que 0,05 p.u. e 10,24% das saídas com erro menor do que 0,07 p.u.

8.2.4 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 4 (M4)

O ponto de monitoramento 4 mostrou o maior índice de acertos para os dados referentes a carga média, sendo o maior índice de acertos dentre os pontos de monitoramento anteriores. Para este conjunto de dados, a RNA referente à fase C apresentou os melhores resultados, sendo 74,60% das saídas com erro menor do que 0,01 p.u., 89,83% das saídas com erro menor do que 0,03 p.u., 94,43% das saídas com erro menor do que 0,05 p.u. e 96,95% das saídas com erro menor do que 0,07.

Entretanto, assim como nos demais pontos de monitoramento, verificou-se um baixo índice de acertos para os demais tipos de carga.

Para a situação de carga leve, a RNA referente à fase C apresentou os melhores resultados, sendo 6,22% das saídas com erro menor do que 0,01 p.u., 49,60% das saídas com erro menor do que 0,03 p.u., 54,70% das saídas com erro menor do que 0,05 p.u. e 57,34% das saídas com erro menor do que 0,07 p.u.

Já para a situação de carga pesada, a RNA referente à fase A apresentou os melhores resultados, sendo 0,47% das saídas com erro menor do que 0,01 p.u., 1,93% das saídas com erro menor do que 0,03 p.u., 3,76% das saídas com erro menor do que 0,05 p.u. e 5,67% das saídas com erro menor do que 0,07 p.u.

8.2.5 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 5 (M5)

O ponto de monitoramento 5 mostrou índices de acertos para os dados referentes a carga média inferiores ao ponto de monitoramento 4. Para este conjunto de dados, a RNA referente à fase C apresentou os melhores resultados, sendo 74,95% das saídas com erro menor do que 0,01 p.u., 91,49% das saídas com erro menor do que 0,03 p.u., 94,88% das saídas com erro menor do que 0,05 p.u. e 96,70% das saídas com erro menor do que 0,07.

Entretanto, assim como nos demais pontos de monitoramento, verificou-se um baixo índice de acertos para os demais tipos de carga.

Para a situação de carga leve, a RNA referente à fase C apresentou os melhores resultados, sendo 5,26% das saídas com erro menor do que 0,01 p.u., 58,83% das saídas com erro menor do que 0,03 p.u., 60,01% das saídas com erro menor do que 0,05 p.u. e 62,22% das saídas com erro menor do que 0,07 p.u.

Já para a situação de carga pesada, a RNA referente à fase C apresentou os melhores resultados, sendo 0,21% das saídas com erro menor do que 0,01 p.u., 0,91% das saídas com erro menor do que 0,03 p.u., 1,52% das saídas com erro menor do que 0,05 p.u. e 2,46% das saídas com erro menor do que 0,07 p.u.

8.2.6 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 6 (M6)

O ponto de monitoramento 6 mostrou índices de acertos para os dados referentes a carga média superiores aos índices de acertos do ponto de monitoramento 5, mas inferiores ao ponto 4. Para este conjunto de dados, a RNA referente à fase C apresentou os melhores resultados, sendo 74,59% das saídas com erro menor do que 0,01 p.u., 89,81% das saídas com erro menor do que 0,03 p.u., 94,71% das saídas com erro menor do que 0,05 p.u. e 96,71% das saídas com erro menor do que 0,07.

Para a situação de carga leve, a RNA referente à fase B apresentou os melhores resultados, sendo 33,07% das saídas com erro menor do que 0,01 p.u., 54,22% das saídas com erro

menor do que 0,03 p.u., 57,62% das saídas com erro menor do que 0,05 p.u. e 58,92% das saídas com erro menor do que 0,07 p.u.

Já para a situação de carga pesada, a RNA referente a fase C apresentou os melhores resultados, sendo 0,70% das saídas com erro menor do que 0,01 p.u., 2,83% das saídas com erro menor do que 0,03 p.u., 4,28% das saídas com erro menor do que 0,05 p.u. e 5,97% das saídas com erro menor do que 0,07 p.u.

8.2.7 CONCLUSÕES PARCIAIS

Através da análise dos resultados acima, é possível perceber-se que as RNAs não apresentam resultados satisfatórios para a determinação das tensões trifásicas das cargas pesada e leve quando treinadas somente com dados referentes as cargas médias.

Esse resultado era esperado, sendo justificado pelo fato de que o conjunto de dados de treinamento das RNAs não representava uma parcela significativa do banco de dados. Segundo HAYKIN (2009), a capacidade de generalização das RNAs do tipo PMC é influenciada por três fatores: (1) tamanho do banco de dados de treinamento da RNA e quão representativo estes dados são; (2) arquitetura da RNA; e (3) complexidade do problema.

Dado que as arquiteturas das RNAs já foram devidamente testadas e aprovadas por BOTTURA *et al.* (2010), CAMARGO (2012) e LIMA (2014), restam dois fatores que podem afetar o desempenho das mesmas.

Sendo assim, a solução para uma melhor representatividade dos dados (item 1 do último parágrafo) será analisada nos próximos tópicos através da aplicação do método 2.

8.3 TESTE DAS REDES ATRAVÉS DO MÉTODO 2

8.3.1 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 1 (M1)

Este tópico busca mitigar os problemas encontrados no método 1, como o baixo índice de acertos das RNAs para as cargas leve e pesada. Isso será realizado através da mudança de abordagem do treinamento das RNAs dos pontos de monitoramento. Para o momento, serão apresentados dados de treinamento referentes ao banco de dados das cargas leve e pesada. Essa abordagem baseia-se nos trabalhos de HAYKIN (2009), os quais justificam a falta de um banco de dados abrangente como causa da redução da capacidade de generalização das RNAs.

Dessa forma, após a fase de treinamento, o teste das RNAs para o banco de dados referente às cargas leve e pesada mostrou maior índice de acertos na fase C, sendo 51,22% das saídas com erro menor do que 0,01 p.u., 73,94% das saídas com erro menor do que 0,03 p.u., 83,89% das saídas com erro menor do que 0,05 p.u. e 89,27% das saídas com erro menor do que 0,07. Entretanto, verificou-se um índice de acertos muito baixo para as cargas médias.

Para a situação de carga média, a RNA referente à fase A apresentou os melhores resultados, sendo 1,48% das saídas com erro menor do que 0,01 p.u., 4,97% das saídas com erro menor do que 0,03 p.u., 8,71% das saídas com erro menor do que 0,05 p.u. e 14,44% das saídas com erro menor do que 0,07 p.u.

8.3.2 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 2 (M2)

O ponto de monitoramento 2 mostrou o maior índice de acertos para os dados referentes as cargas leve e pesada, superior ao índice de acerto do ponto de monitoramento 1. Para este conjunto de dados, a RNA referente à fase A apresentou os melhores resultados, sendo 45,39% das saídas com erro menor do que 0,01 p.u., 71,46% das saídas com erro menor do que 0,03 p.u., 84,39% das saídas com erro menor do que 0,05 p.u. e 90,56% das saídas com erro menor do que 0,07.

Entretanto, verificou-se um baixo índice de acertos para os demais tipos de carga. Para a situação de carga média, a RNA referente à fase C apresentou os melhores resultados, sendo 1,39% das saídas com erro menor do que 0,01 p.u., 4,38% das saídas com erro menor do que 0,03 p.u., 7,57% das saídas com erro menor do que 0,05 p.u. e 11,26% das saídas com erro menor do que 0,07 p.u.

8.3.3 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 3 (M3)

O ponto de monitoramento 3 mostrou o maior índice de acertos para os dados referentes as cargas leve e pesada, superior ao índice de acerto dos pontos de monitoramento anteriores. Para este conjunto de dados, a RNA referente à fase B apresentou os melhores resultados, sendo 53,93% das saídas com erro menor do que 0,01 p.u., 77,08% das saídas com erro menor do que 0,03 p.u., 86,52% das saídas com erro menor do que 0,05 p.u. e 90,95% das saídas com erro menor do que 0,07 p.u..

Entretanto, verificou-se um baixo índice de acertos para os demais tipos de carga. Para a situação carga média, a RNA referente à fase C apresentou os melhores resultados, sendo 2,36% das saídas com erro menor do que 0,01 p.u., 6,43% das saídas com erro menor do que 0,03 p.u., 12,50% das saídas com erro menor do que 0,05 p.u. e 18,58% das saídas com erro menor do que 0,07 p.u.

8.3.4 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 4 (M4)

O ponto de monitoramento 4 mostrou o maior índice de acertos para os dados referentes as cargas leve e pesada, inferior ao ponto de monitoramento 3. Para este conjunto de dados, a RNA referente à fase A apresentou os melhores resultados, sendo 50,58% das saídas com erro menor do que 0,01 p.u., 74,82% das saídas com erro menor do que 0,03 p.u., 85,02% das saídas com erro menor do que 0,05 p.u. e 90,66% das saídas com erro menor do que 0,07.

Entretanto, verificou-se um baixo índice de acertos para os demais tipos de carga. Para a situação carga média, a RNA referente à fase A apresentou os melhores resultados, sendo 2,80% das saídas com erro menor do que 0,01 p.u., 6,91% das saídas com erro menor do que 0,03 p.u., 10,81%

das saídas com erro menor do que 0,05 p.u. e 14,53% das saídas com erro menor do que 0,07 p.u.

8.3.5 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 5 (M5)

O ponto de monitoramento 5 mostrou o maior índice de acertos para os dados referentes as cargas leve e pesada. Para este conjunto de dados, a RNA referente à fase A apresentou os melhores resultados, sendo 51,91% das saídas com erro menor do que 0,01 p.u., 76,17% das saídas com erro menor do que 0,03 p.u., 83,81% das saídas com erro menor do que 0,05 p.u. e 90,89% das saídas com erro menor do que 0,07.

Entretanto, verificou-se um baixo índice de acertos para os demais tipos de carga. Para a situação carga média, a RNA referente à fase C apresentou os melhores resultados, sendo 2,26% das saídas com erro menor do que 0,01 p.u., 6,33% das saídas com erro menor do que 0,03 p.u., 10,29% das saídas com erro menor do que 0,05 p.u. e 15,26% das saídas com erro menor do que 0,07 p.u..

8.3.6 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 6 (M6)

O ponto de monitoramento 6 também mostrou o maior índice de acertos para os dados referentes as cargas leve e pesada, sendo o melhor dentre todos os anteriores. Para este conjunto de dados, a RNA referente à fase A apresentou os melhores resultados, sendo 49,82% das saídas com erro menor do que 0,01 p.u., 76,16% das saídas com erro menor do que 0,03 p.u., 86,93% das saídas com erro menor do que 0,05 p.u. e 91,59% das saídas com erro menor do que 0,07 p.u..

Entretanto, verificou-se um baixo índice de acertos para os demais tipos de carga. Para a situação carga média, a RNA referente à fase B apresentou os melhores resultados, sendo 1,89% das saídas com erro menor do que 0,01 p.u., 5,02% das saídas com erro menor do que 0,03 p.u., 7,86% das saídas com erro menor do que 0,05 p.u. e 13,15% das saídas com erro menor do que 0,07 p.u..

8.3.7 CONCLUSÕES PARCIAIS

A análise dos dados apresentados permite concluir que após a mudança do tipo de carga presente no banco de treinamento, o índice de acertos das RNAs para os casos de carga leve e pesada aumentaram significativamente. Entretanto, é importante destacar que os índices de acerto para as cargas médias reduziram drasticamente, permanecendo em torno de 10% e 15% (erro menor do que 0,07 p.u.) para a maioria dos pontos de monitoramento. Esse resultado pode mostrar algumas das características das RNAs aqui implementadas, tais como:

- Aumento da complexidade do problema abordado;
- Ocorrência de treinamento excessivo (“overtrainning”); e
- Banco de dados pouco representativo.

As hipóteses acima foram baseadas nos estudos de HAYKIN (2009). Suas pesquisas afirmam que as RNAs, quando submetidas a um banco de treinamento excessivamente grande, podem sofrer de “*overtrainning*”, ou seja, a rede neural passa a “decorar” o padrão de respostas que deve fornecer, perdendo sua capacidade de generalização.

Sendo assim, objetivando a busca de resultados mais precisos, será realizado novamente o treinamento das RNAs utilizando o método 2 modificado, sendo apresentado e detalhado no item a seguir.

8.4 TESTE DAS REDES ATRAVÉS DO MÉTODO 2 MODIFICADO

Este capítulo tem como objetivo verificar os possíveis problemas de “*overtrainning*” das RNAs treinadas no presente trabalho. Para isso, o tamanho do banco de dados de treinamento e teste será alterado da seguinte forma:

- Banco de dados de treinamento: 50% do banco de dados da carga leve e 50% do banco de dados da carga pesada;
- Banco de teste: 50% do banco de dados da carga leve, 50% do banco de dados da carga pesada e 100% do banco de dados da carga média.

8.4.1 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 1 (M1)

Dada a semelhança entre os resultados referentes aos diferentes pontos de monitoramento, serão apresentadas somente as consolidações referentes ao M1. As taxas de acerto referentes a este ponto de monitoramento pode ser verificada na **Tabela 15**.

Tabela 15 - Erro das fases A, B e C do ponto de monitoramento 1 para as carga média, leve e pesada do método 2 modificado.

Carga	Fase	Erro<0,01 p.u. (%)	Erro<0,03 p.u. (%)	Erro<0,05 p.u. (%)	Erro<0,07 p.u. (%)
Leve e Pesada	A	49,76	74,11	85,36	90,46
Leve e Pesada	B	50,90	76,36	85,86	91,21
Leve e Pesada	C	49,68	72,73	84,56	90,11
Média	A	1,65	5,59	9,06	12,53
Média	B	1,31	3,97	7,60	10,62
Média	C	2,71	7,01	11,16	17,32

Fonte: Autoria própria (2017).

Comparando-se os resultados obtidos com o método 2 é possível perceber uma baixa evolução no desempenho das RNAs. As cargas médias continuam apresentando resultados pouco

satisfatórios, mantendo a taxa de acerto em torno de 12% para erros menores do que 0,07 p.u..

8.5. TESTE DAS REDES ATRAVÉS DO MÉTODO 3

Este último método de abordagem tem como objetivo verificar a possibilidade do aumento do índice de acertos e desempenho das RNAs quando submetidas a um banco de dados contendo amostras dos três tipos de carga (leve, média e pesada). Para isso, o banco de dados de treinamento e teste será alterado da seguinte forma:

- Banco de dados de treinamento: 70% do banco de dados da carga leve, 70% do banco de dados da carga pesada e 70% do banco de dados da carga média; e
- Banco de teste: 30% do banco de dados da carga leve, 30% do banco de dados da carga pesada e 30% do banco de dados da carga média.

8.5.1 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 1 (M1)

O ponto de monitoramento 1 mostrou bons resultados, sendo que o maior índice de acertos foi para os dados referentes a carga leve. Para este conjunto de dados, a RNA referente à fase C apresentou os melhores resultados, sendo 47,24% das saídas com erro menor do que 0,01 p.u., 72,70% das saídas com erro menor do que 0,03 p.u., 86,31% das saídas com erro menor do que 0,05 p.u., e 92,19% das saídas com erro menor do que 0,07 p.u..

Para os demais tipos de carga, a RNA apresentou resultados também satisfatórios, obtendo-se índice de acertos em torno de 88% para erros menores do que 0,07 p.u. para a carga média e 80% para a carga pesada.

Todos os dados obtidos via simulação para o ponto de monitoramento 1 apresentados acima podem ser verificado na **Tabelas 16**.

Tabela 16 - Erro das fases A, B e C do ponto de monitoramento 1 das carga média, leve e pesada do método 3.

Carga	Fase	Erro<0,01 p.u. (%)	Erro<0,03 p.u. (%)	Erro<0,05 p.u. (%)	Erro<0,07 p.u. (%)
Média	A	38,50	58,79	72,70	83,03
Média	B	41,57	64,87	80,00	88,17
Média	C	41,63	62,77	77,41	88,41
Leve	A	45,26	68,12	81,37	88,14
Leve	B	47,95	73,80	85,63	91,00
Leve	C	47,24	72,70	86,31	92,19
Pesada	A	36,04	53,39	65,80	74,20
Pesada	B	38,93	58,20	71,96	81,48

Pesada	C	38,11	55,99	69,83	80,73
--------	---	-------	-------	-------	-------

Fonte: Autoria própria (2017).

8.5.2 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 2 (M2)

O ponto de monitoramento 2 também mostrou bons resultados, sendo que o maior índice de acertos para os dados referentes a carga leve. Para este conjunto de dados, a RNA referente à fase A apresentou os melhores resultados, sendo 46,29% das saídas com erro menor do que 0,01 p.u., 73,65% das saídas com erro menor do que 0,03 p.u., 85,55% das saídas com erro menor do que 0,05 p.u. e 91,73% das saídas com erro menor do que 0,07 p.u..

Para os demais tipos de carga, a RNA apresentou resultados também satisfatórios, obtendo-se índices de acertos em torno de 85% para erros menores do que 0,07 p.u. para a carga média e 78% para a carga pesada.

8.5.3 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 3 (M3)

Para o ponto de monitoramento 3 obteve-se o maior índice de acertos até o momento para os dados referentes a carga leve. Para este conjunto de dados, a RNA referente à fase C apresentou os melhores resultados, sendo 45,78% das saídas com erro menor do que 0,01 p.u., 72,86% das saídas com erro menor do que 0,03 p.u., 84,89% das saídas com erro menor do que 0,05 p.u. e 91,05% das saídas com erro menor do que 0,07 p.u..

Para os demais tipos de carga, a RNA apresentou resultados também satisfatórios, obtendo-se índices de acertos em torno de 86% para erros menores do que 0,07 p.u. para a carga média e 80% para a carga pesada.

8.5.4 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 4 (M4)

Para este conjunto de dados, a RNA referente à fase A apresentou os melhores resultados, sendo 46,34% das saídas com erro menor do que 0,01 p.u., 71,59% das saídas com erro menor do que 0,03 p.u., 84,89% das saídas com erro menor do que 0,05 p.u. e 91,43% das saídas com erro menor do que 0,07 p.u..

Para os demais tipos de carga, a RNA apresentou resultados também satisfatórios, obtendo-se índice de acertos em torno de 85% para erros menores do que 0,07 p.u. para a carga média e 80% para a carga pesada.

8.5.5 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 5 (M5)

Para este conjunto de dados, a RNA referente à fase C apresentou os melhores resultados, sendo 46,46% das saídas com erro menor do que 0,01 p.u., 71,86% das saídas com erro menor do que

0,03 p.u., 83,38% das saídas com erro menor do que 0,05 p.u. e 90,53% das saídas com erro menor do que 0,07 p.u..

Para os demais tipos de carga, a RNA apresentou resultados também satisfatórios, obtendo-se índice de acertos em torno de 86% para erros menores do que 0,07 p.u. para a carga média e 80% para a carga pesada.

8.5.6 ANÁLISE DO DESEMPENHO DA RNA PARA O PONTO 6 (M6)

Para estas situações, a RNA referente à fase C apresentou os melhores resultados, sendo 47,35% das saídas com erro menor do que 0,01 p.u., 74,26% das saídas com erro menor do que 0,03 p.u., 85,63% das saídas com erro menor do que 0,05 p.u. e 92,04% das saídas com erro menor do que 0,07 p.u..

Para os demais tipos de carga, a RNA apresentou resultados também satisfatórios, obtendo-se índice de acertos em torno de 85% para erros menores do que 0,07 p.u. para a carga média e 75% para a carga pesada. Entretanto, houve uma exceção para a fase A, sendo de 45,93% para erros menores do que 0,07 p.u..

9. ANÁLISE DE DIFERENTES TOPOLOGIAS DE RNAs

Após a análise do desempenho das RNAs frente a diferentes metodologias de treinamento, é possível concluir que o método 3, o qual expôs as RNAs aos diferentes perfis de carga durante sua fase de treinamento, apresentou os melhores resultados.

Dessa forma, todas as análises posteriores a esta seção farão uso da formatação do banco de dados de treinamento apresentada pelo método 3 visando observar a influência do aumento do número de neurônios nas camadas intermediárias das RNAs sobre seu desempenho. Vale adiantar que os demais parâmetros das RNAs permanecerão inalterados.

Tendo em vista o grande volume de dados com a qual a presente pesquisa conta, a organização dos resultados e análises pertinente foi elaborada da seguinte forma:

- Apresentação dos dados resultantes das simulações; e
- Análise gráfica do aumento do desempenho das RNAs.

9.1 TOPOLOGIA 6-20-25-1

A estratégia adotada para a abordagem do problema consiste em aumentar 5 neurônios de uma camada intermediária da RNA por vez. Logo, a primeira topologia de RNA a ser analisada conta com 20 neurônios na primeira camada intermediária e 25 neurônios na segunda camada intermediária, permanecendo os mesmos seis neurônios na camada de entrada e um neurônio na camada de saída (6-20-25-1). Assim, os resultados obtidos para as cargas leve, média e pesada podem ser observados na **Tabela 23** do apêndice.

9.2 TOPOLOGIA 6-25-25-1

Dando sequência as análises, foram adicionados 5 neurônios na primeira camada intermediária. Assim, foram obtidos os resultados para as cargas leve, média e pesada da topologia 6-25-25-1, apresentados na **Tabela 24** do apêndice.

9.3 TOPOLOGIA 6-25-30-1

Na busca por RNAs com melhores desempenhos, foram treinadas e testadas redes com a topologia 6-25-30-1, obtendo-se os resultados apresentados na **Tabela 25** para as cargas leve, média e pesada do apêndice.

9.4 TOPOLOGIA 6-30-30-1

Novamente, aumentou-se o número de neurônios da primeira camada intermediária em 5 unidades, obtendo-se para as cargas leve, média e pesada os resultados apresentados na **Tabela 26** do

apêndice.

9.5 TOPOLOGIA 6-30-35-1

A topologia 6-30-35-1 apresentou os resultados para as cargas leves, média e pesada, mostrados nas **Tabela 27** do apêndice.

9.6 TOPOLOGIA 6-35-35-1

Para a topologia 6-35-35-1, foram obtidos os resultados para as cargas leve, média e pesada mostrados na **Tabela 28** do apêndice.

9.7 TOPOLOGIA 6-50-50-1

No intuito de verificar a resposta das RNAs frente a um grande número de neurônios nas camadas intermediárias, o presente trabalho também avaliou a utilização da topologia 6-50-50-1.

Entretanto, verificou-se que o tempo necessário para a realização do treinamento das RNAs via *Matlab®* aumentou significativamente, demorando doze vezes mais quando comparada com a topologia proposta no início desta pesquisa (6-20-20-1). Dessa forma, tendo em vista a complexidade das simulações computacionais e a semelhança dos resultados para diferentes pontos de monitoramento dada uma mesma topologia de rede, foram realizadas validações da topologia 6-50-50-1 somente para os pontos de monitoramento 1 e 2, conforme pode ser observado na **Tabela 17** abaixo.

Tabela 17 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-50-50-1.

Ponto de Monitoramento	Carga	Fase	Erro<0,01 p.u. (%)	Erro<0,03 p.u. (%)	Erro<0,05 p.u. (%)	Erro<0,07 p.u. (%)
M1	Leve	A	66,09	86,14	92,77	94,91
M1	Leve	B	62,71	85,73	92,58	94,75
M1	Leve	C	68,68	87,80	93,28	94,98
M2	Leve	A	67,07	87,99	93,05	95,18
M2	Leve	B	66,12	86,76	92,63	95,10
M2	Leve	C	65,87	87,10	92,17	94,69
M1	Média	A	64,68	86,48	92,17	95,74
M1	Média	B	56,02	80,43	89,79	93,50
M1	Média	C	64,62	86,76	93,70	96,20
M2	Média	A	64,20	87,15	93,36	95,88
M2	Média	B	59,89	84,12	92,07	96,37
M2	Média	C	59,77	85,12	92,73	95,51

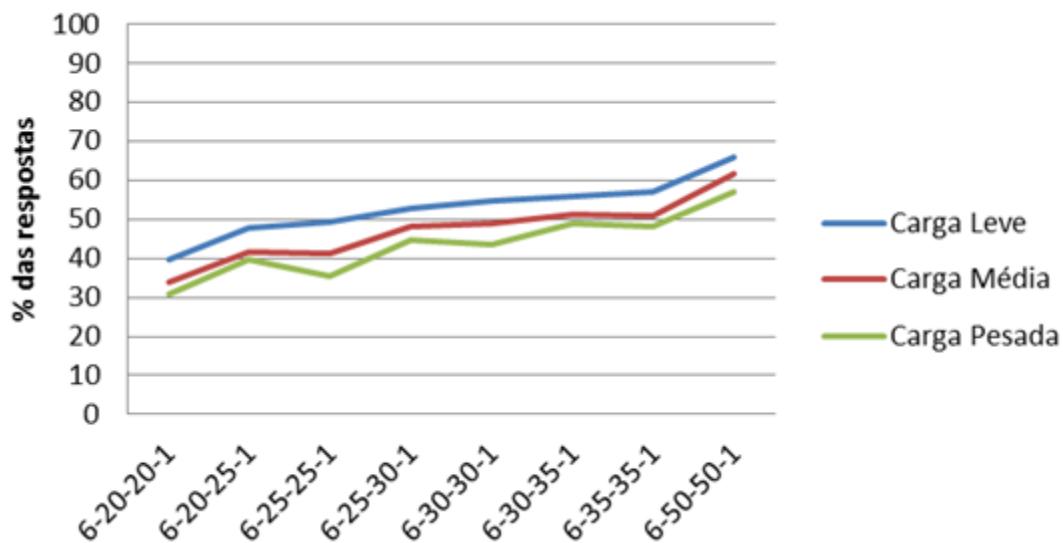
M1	Pesada	A	58,93	81,29	88,75	92,66
M1	Pesada	B	52,06	75,08	84,37	88,82
M1	Pesada	C	58,80	82,07	88,18	91,77
M2	Pesada	A	58,59	80,52	88,35	92,23
M2	Pesada	B	57,39	79,10	86,72	91,34
M2	Pesada	C	56,28	79,18	88,11	92,31

Fonte: Autoria própria (2017).

9.8 ANÁLISE DOS RESULTADOS

Após a apresentação dos resultados de simulação, é possível realizar uma análise geral da influência do aumento do número de neurônios das camadas intermediárias das RNAs sobre o desempenho de suas respostas. Para isso, foram calculadas as médias das taxas de acerto de todas as fases e todos os pontos de monitoramento, obtendo-se a evolução da taxa de acertos para um erro menor do que 0,01 p.u. para cada topologia proposta, conforme pode ser observado na **Figura 38**.

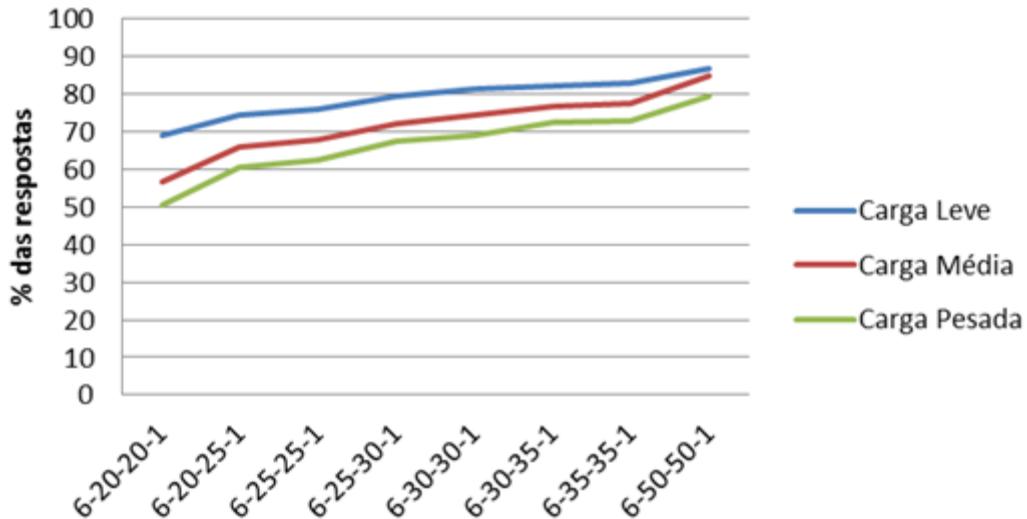
Figura 38 – Taxas de acertos de cada topologia de RNA para um erro < 0,01 p.u..



Fonte: Autoria própria (2017).

Através da **Figura 38** é possível observar-se que houve um aumento de aproximadamente 20% de acerto para todos os perfis de carga analisados quando comparadas a primeira e última topologia propostas, sendo elas 6-20-20-1 e 6-50-50-1, respectivamente. A evolução da taxa de acertos para um erro menor do que 0,03 p.u. pode ser observado na **Figura 39**.

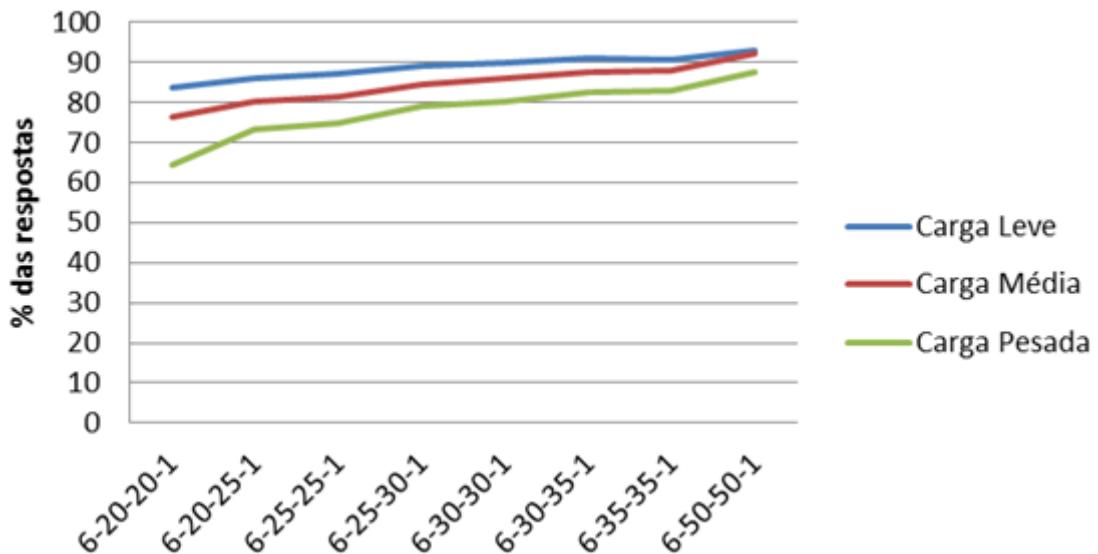
Figura 39 - Taxas de acertos de cada topologia de RNA para um erro < 0,03 p.u.



Fonte: Autoria própria (2017).

O desempenho das redes neurais para o erro menor do que 0,03 p.u. também aumentou por volta de 20% quando comparadas a primeira e última topografia. Entretanto, é possível perceber que o aumento do índice de acertos das cargas leves começa a saturar, ou seja, a melhoria de seu desempenho frente ao aumento do número de neurônios começa a reduzir.

Figura 40 - Taxas de acertos de cada topologia de RNA para um erro < 0,05 p.u..

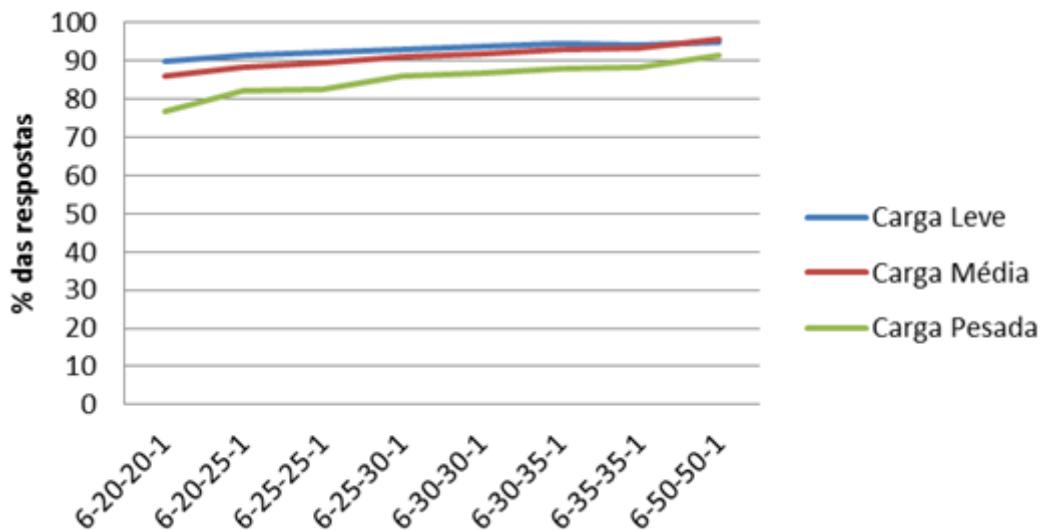


Fonte: Autoria própria (2017).

A análise dos erros menores do que 0,05 p.u. confirma as observações anteriores, pois o aumento do desempenho das RNAs para as cargas leves foi somente de 10% quando comparada a

primeira e última topologia proposta. Por fim, a análise dos erros menores do que 0,07 p.u. foram sumarizados na **Figura 41**.

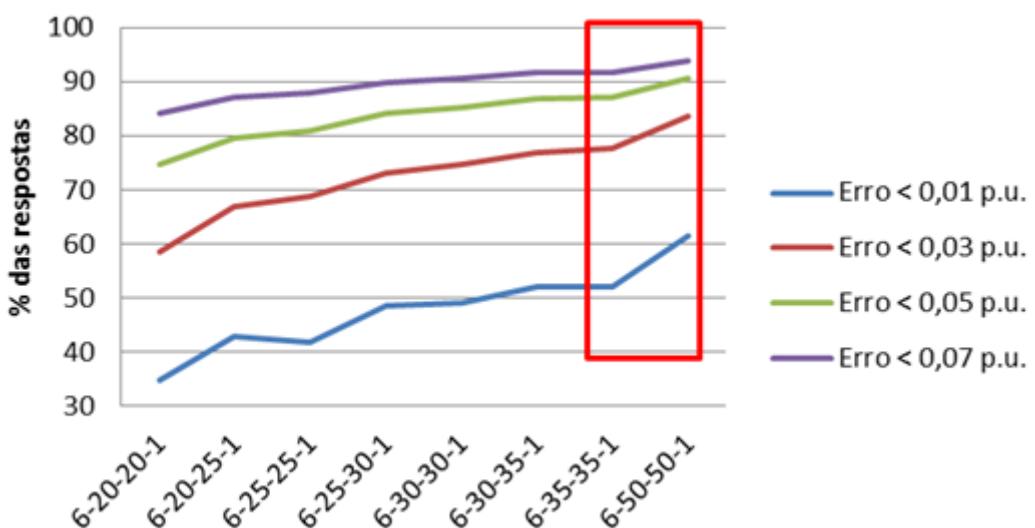
Figura 41 - Taxas de acertos de cada topologia de RNA para um erro < 0,07 p.u..



Fonte: Autoria própria (2017).

Através da análise do gráfico relativo às taxas de acerto das redes para erros menores do que 0,07 p.u. é possível perceber que a inclinação das retas é inferior quando comparada com os demais gráficos. Este fato demonstra um menor aumento de desempenho das RNAs frente ao aumento do número de neurônios, indicando saturação da rede para uma taxa de acertos por volta de 90%. Esta saturação pode ser verificada através da análise da **Figura 42**.

Figura 42 – Evolução das taxas de acertos das RNA para cada perfil de erro.



Fonte: Autoria própria (2017).

A variação busca de aumento de desempenho entre as duas últimas topologias ocorre devido a um aumento de 15 neurônios nas duas camadas intermediárias ao invés de 5. Este gráfico mostra de forma mais clara a saturação da rede mencionada anteriormente. Note que quanto mais os resultados se aproximam da taxa de acertos de 90%, menor é o aumento do desempenho da rede frente ao aumento do número de neurônios. Entretanto, a porcentagem das respostas com erro menor do que 0,01 p.u. aumentaram significativamente, indicando crescimento do número das respostas mais precisas.

10. CONCLUSÕES

Esta pesquisa teve como principal objetivo apresentar um método alternativo de monitoramento remoto via RNAs para estimar os valores das tensões trifásicas do SD. A metodologia seguida permitiu definir o melhor método de treinamento das redes e apresentar o comportamento de diferentes topologias de RNAs frente a diferentes variações de carga no SEP, dado que estes valores sofrem constante alteração no decorrer do dia.

Para isso, foram modelados via o software ATP situações de carga pesada, média e leve do SEP, compondo o banco de dados a ser utilizado pelas RNAs. Como ponto de partida, analisou-se o comportamento das RNAs já treinadas em trabalhos anteriores por LIMA (2014), verificando-se nesta pesquisa o baixo índice de acertos para as cargas pesadas, possuindo valor mínimo de 0,37% de acertos para um erro menor do que 0,01 p.u. para o ponto de monitoramento 4 da fase A, e valor máximo de 47,64% de índice de acertos para um erro menor do que 0,07 p.u. para o ponto de monitoramento 1 da fase C. Para a situação de carga média, obteve-se como maior índice de acertos o valor de 80,07% para um erro menor do que 0,07 p.u. para o ponto de monitoramento 5 da fase B. Esse baixo índice de acertos pode ter sido causado pela baixa abrangência de perfis de carga do banco de dados de treinamento das RNAs apresentadas por LIMA (2014), fator esse caracterizado por HAYKIN (2009) como um dos principais motivos da perda de capacidade de generalização das RNAs. Sendo assim, foram treinadas novas RNAs com o banco de dados gerado via o software ATP, referentes às cargas médias, caracterizando o método 1 de treinamento apresentado no presente trabalho. Com isso, as RNAs apresentaram resultados semelhantes aos anteriores, os quais mostram um índice de acertos extremamente baixo para os casos de carga pesada, possuindo máximo de 10,24% para um erro menor do que 0,07 p.u (M3 - fase B). Já para os casos de carga média, obteve-se resultado semelhante em todos os pontos de monitoramento, permanecendo em torno de 96% para um erro menor do que 0,07 p.u.. Para os casos de carga leve, o maior índice de acertos foi de 62,22% para um erro menor do que 0,07 p.u. (M5 - fase C).

Os dados apresentados pelas RNA quando treinadas com os casos de carga média foram semelhantes às respostas das RNAs apresentadas por LIMA (2014) e aqui testadas, reforçando a possibilidade de falta de representatividade do banco de dados de treinamento. Dessa forma, foram treinadas novas RNAs utilizando-se os dados das cargas leves e pesadas. Como resultado, o índice de acertos das cargas médias foi reduzido consideravelmente, adquirindo valor máximo de 18,58% (M3 - fase C). Esse fato mostra a possibilidade da ocorrência de um sobre treinamento (“*Overtrainning*”), apresentado também por HAYKIN (2009) como fator que pode reduzir a capacidade de generalização das RNAs.

Dessa forma, foram treinadas novas RNAs com um banco de treinamento reduzido, mas ainda contendo valores de carga leve e pesada, caracterizando o método 2 modificado. Essa pequena mudança ainda não gerou RNAs com índice de acertos satisfatórios, permanecendo os valores

semelhantes aos do método citado acima.

Enfim, como tentativa final de aumento do desempenho das RNAs, investigou-se novamente a possibilidade da RNA não estar sendo submetida a um banco de dados representativo. Logo, definiu-se o terceiro método de treinamento, onde foram utilizados dados referentes aos três perfis de carga, sendo 70% de cada um para o treinamento e o restante para a fase de testes. Após essa mudança, as RNA passaram a apresentar índices de acertos aceitáveis, permanecendo em torno de 90% para as cargas leve, 85% para as cargas médias e 80% para as cargas pesadas para um erro menor do que 0,07 p.u..

Investigou-se também a influência do aumento do número de neurônios das camadas intermediárias das RNAs sobre o desempenho de suas respostas. Para isso, foram treinadas sete novas topologias de redes. Dessa forma, foram obtidos índices de acerto para um erro menor do que 0,07 p.u. por volta de 95% para as cargas leves, 95% para as cargas médias e 91% para as cargas pesadas, utilizando-se a topologia 6-50-50-1. Entretanto, é importante destacar o tempo de simulação computacional requerido para o treinamento desta rede, sendo 12 vezes superior quando comparada com a topologia 6-20-20-1. Além disso, a curva de análise do aumento de desempenho da RNA frente ao aumento do número de neurônios apresentada anteriormente mostra que o índice de acertos para erros menores do que 0,01 p.u. tendem a melhorar quando utilizados mais neurônios do que a topologia proposta no presente trabalho, pois a curva de crescimento possui inclinação.

Assim, destaca-se novamente a importância do correto treinamento e escolha da topologia das RNAs para a obtenção de resultados satisfatórios, sendo que este treinamento deve realmente conter dados representativos do sistema a ser testado e o número de neurônios ser suficiente para fornecer resultados precisos, dada a complexidade do problema analisado.

Cabe comentar que o presente trabalho foi publicado no XII Conferência Brasileira sobre Qualidade de Energia Elétrica (CBQEE) (OTA et al., 2017).

10.1 TRABALHOS FUTUROS

Conforme especificado, a proposta deste trabalho consistia na análise do desempenho de diferentes topologias RNAs frente aos diferentes perfis de carga do SEP. Através dos dados apresentados no decorrer desta pesquisa, é possível perceber a diminuição do índice de acertos das RNAs quando comparado com os trabalhos de LIMA (2014).

A diminuição do índice de acertos das RNAs pode ter sido ocasionada devido ao aumento da complexidade do problema quando inseridos diferentes tipos de perfis de carga. Sendo assim, as RNAs com a topologia 6-20-20-1 podem não possuir a capacidade de abstração necessária com a quantidade de camadas intermediárias e neurônios propostos por LIMA (2014). Sendo assim, a mudança da topologia da rede neural para 6-50-50-1 elevou os índices de acerto para cerca de 95%.

Entretanto, a curva de crescimento do desempenho da rede frente ao aumento do número de neurônios apresentada anteriormente reduz sua inclinação significativamente quando as taxas de acerto ficam próximas de 90%.

Sendo assim, devem ser considerados outros métodos de abordagem do problema para a obtenção de resultados mais precisos, dado que o aumento indiscriminado de neurônios das camadas intermediárias das RNAs necessita de grande esforço computacional, muitas vezes indisponível entre os potenciais usuários desta metodologia de monitoramento remoto.

REFERÊNCIAS BIBLIOGRÁFICAS

AGGARWAL, R.; SONG, Y.. Artificial neural networks in power systems. III. Examples of applications in power systems. **Power Engineering Journal**, v. 12, n. 6, p. 279-287, 1998.

ANEEL - Agência Nacional de Energia Elétrica, **PRODIST – Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional**, Resolução Normativa nº24, de 27 de Janeiro de 2000.

ANEEL - Agência Nacional de Energia Elétrica, **PRODIST – Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional**, Resolução Normativa nº395/2009 – Módulo 8 0 Rev.1

ANEEL - Agência Nacional de Energia Elétrica, **PRODIST – Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional**, Resolução Normativa nº482, de 17 de Abril de 2012a.

ANEEL - Agência Nacional de Energia Elétrica. **Nota Técnica Nº 0083/2012-SRD/ANEEL**. Junho de 2012b.

BELISÁRIO, César D. A., BAHIENSE, Daniella A., OLIVEIRA, Gecê M.. “**Continuidade nos Serviços de Distribuição de Energia Elétrica**”, Conj. & Planej., Salvador: SEI, n.105, p. 36-40, Fev 2003.

BEZERRA, U. H. et al. **Sistema para o Monitoramento da Qualidade de Energia Elétrica em Conjunto de Consumidores em Baixa Tensão**. In: CITNEL – Congresso de Inovação Tecnológica em Energia Elétrica, Brasília – DF. 2001a.

BEZERRA, U. H. et al. **Desenvolvimento do Protótipo de um Instrumento para o Monitoramento da Qualidade de Energia Elétrica de uma Concessionária de Energia Elétrica**. In: CITNEL – Congresso de Inovação Tecnológica em Energia Elétrica, Brasília – DF. 2001b.

BOTTURA, F. B. et al. **Um método alternativo e inteligente para o monitoramento remoto das variações de tensão de curta duração em um sistema de distribuição de energia elétrica**. Trabalho de conclusão de curso (Engenharia Elétrica) – Escola de Engenharia de São Carlos (EESC), Universidade de São Paulo (USP). São Carlos – SP, 2010.

BRAGA, A. de P.; PONCE DE LEON, F. d. C. A.; BERNARDA LUDERMIR, T. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC, 2000.

BRASIL, Ministério das Minas e Energia, DNAEE, Eletrobrás, Empresas Concessionárias de Energia Elétrica; **Nova Tarifa de Energia Elétrica: metodologia e aplicação**, Brasília: DNAEE, 1985.

CAMARGO, F. S. P.. **Uma estimativa alternativa, remota e continuada das variações de tensão em um sistema de distribuição utilizando redes neurais artificiais**. Trabalho de conclusão de curso (Engenharia Elétrica) – Escola de Engenharia de São Carlos (EESC), Universidade de São Paulo (USP). São Carlos – SP, 2012.

COLGANO, G. P.. **Desenvolvimento e implementação de um sistema de monitoramento em Tempo real da tensão da rede com acesso remoto**. 2009. Tese de Doutorado. Universidade Federal do Espírito Santo.

CPFL – COMPANHIA PAULISTA DE FORÇA E LUZ. Relatório de simulação. São Paulo, 2009.

DA SILVA, I. N.; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes Neurais Artificiais para engenharia e ciências aplicadas: curso prático**. Artliber, 2010.

DUGAN,R. C.; M. F. McGranaghan, S. Santoso and H. W. Beaty, “**Electrical Power Systems Quality**”, McGraw-Hill, 2nd Edition, ISBN: 0-07-138622-X, 2002.

ELETROBRÁS, Pesquisa de posse de equipamentos e hábitos de uso, ano base 2005: Classe Residencial Relatório Brasil – Sumário Executivo, Rio de Janeiro, 2009.

FANG, Xi et al. Smart grid—The new and improved power grid: A survey. **Communications Surveys & Tutorials, IEEE**, v. 14, n. 4, p. 944-980, 2012.

FRANCISQUINI, A. A. **Estimação de Curvas de Carga em Pontos de Consumo e em Transformadores de Distribuição**, 2006. Tese de Doutorado. Universidade Estadual Paulista “Júlio de Mesquita Filho”.

HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, p.36, 2001.

HAYKIN, S. et al. **Neural networks and learning machines**. Upper Saddle River, NJ, USA:: Pearson, 2009.

HODGKIN, A. L.; HUXLEY, A. F. **A quantitative description of membrane current and its application to conduction and excitation in nerve**. The Journal of physiology, v. 117, n. 4, p. 500-544, 1952.

JOHNSON, D. E.; HILBURN, J. L.; JOHNSON, J. R. **Fundamentos de análise de circuitos elétricos**. Livros Tecnicos e Cientificos, 1994.

KNAUSS, John-Paul H.; WARREN, Cheri; KEARNS, Dave. An innovative approach to smart automation testing at National Grid. **Transmission and Distribution Conference and Exposition (T&D), 2012 IEEE PES**. IEEE, 2012. p. 1-8.

LIMA, D. F. **O monitoramento remoto da tensão trifásica frente às situações de curtos-circuitos em um sistema de distribuição via redes neurais artificiais**. Trabalho de conclusão de curso (Engenharia Elétrica) – Escola de Engenharia de São Carlos (EESC), Universidade de São Paulo (USP). São Carlos – SP, 2014.

Manual de Equipamentos Elétricos, 3^a edição, Rio de Janeiro, RJ, Editora LTC, 2005.

MATSUNAGA, V. Y. **Curso de Redes Neurais Utilizando o MatLab**. Belém do Pará, 2012.

NAKAWIRO, Worawat; ERLICH, István. Online voltage stability monitoring using artificial neural network. **Electric Utility Deregulation and Restructuring and Power Technologies, 2008. DRPT 2008. Third International Conference on**. IEEE, 2008. p. 941-947.

OLESKOVICZ, M. **Apostila do Curso de Qualidade da Energia Elétrica**. EESC – USP, São Carlos – SP, 2007.

OTA, R.T; OLESKOVICZ, M.; BOTTURA, F. B.; LIMA, D. F. **Utilização de RNAs para o monitoramento remote das tensões frente a diferentes perfis de carga em um sistema de distribuição**. XII Conferência Brasileira Sobre Qualidade de Energia Elétrica – XII CBQEE, Curitiba/PR, 2017.

POPOVIĆ, D.; KUKOLJ, D.; KULIĆ, F. Monitoring and assessment of voltage stability margins

using artificial neural networks with a reduced input set. **IEE Proceedings-Generation, Transmission and Distribution**, v. 145, n. 4, p. 355-362, 1998.

SILVA, M. C. I., **Correção do fator de potência de cargas industriais com dinâmica rápida**. 2009.

SINGH, P.; KOTHARI, D. P.; SINGH, M.. **Feasibility of Interconnected Distribution Network for the Integration of Distributed Energy Resources Using GA Approach**. International Review of Electrical Engineering (IREE), v. 8, n. 1, p. 314-320, 2013.

STEVENSON, W. D. **Elementos de análise de sistemas de potência**. McGraw-Hill do Brasil, 1974.

TETKO, I. V., LIVINGSTONE, D. J., LUIK, A. I. “**Neural network studies. 1. Comparison of overfitting and overtraining**”, *J. Chem. Inf. Comput. Sci.*, 1995, 35, 826-833.

APÊNDICE A – Algoritmo para conversão dos arquivos .pl4 para .mat

CONVERSÃO DOS ARQUIVOS .PL4 PARA .MAT

```
comeco = 'C:\Users\rodolfotakeshi94\Documents\ATPDATA\';  
tipo = {'ab0caso', 'ab90caso', 'abc0caso', 'abc90caso', 'abct0caso', ...  
'abct90caso', 'abt0caso', 'abt90caso', 'ac0caso', 'ac90caso', ...  
'act0caso','act90caso', 'at0caso', 'at90caso', 'bc0caso', 'bc90caso', ...  
'bct0caso', 'bct90caso', 'bt0caso', 'bt90caso', 'ct0caso', 'ct90caso'};  
for primCont = 1:1:22 %Percorre todos os casos de falta  
for casos_falta=1:10  
aux = cat(2,char(tipo(primCont)),int2str(casos_falta),'.pl4');  
% system(['Pl42mat.exe ' cat(2,comeco,aux)]), %Executa arquivo externo conversao .pl4 .mat  
disp(['Pl42mat.exe ' cat(2,comeco,aux)])  
end  
end
```

APÊNDICE B - Algoritmo para coleta aleatória dos dados

```
function [casosTrein casosTest] = f_AmostrAleat(nCasos,pTrein)
casos_tot = randperm(nCasos);
casosTrein = casos_tot(1:nCasos*pTrein);
casosTest = casos_tot(nCasos*pTrein+1:nCasos);
end
```

APÊNDICE C – Tabelas complementares

Tabela 18 – Dados das cargas modeladas

Consumidores	Potência Instalada (kVA)	Demandा Contratada (kW)	Corrente (A)	Resistência (Ω)	L(mH)
Carga 1	700	320	8	4601,19	0,005
Carga 2	75	30	0,75	49079,39	0,055
Carga 3	1000	577	14,42	2552,67	0,003
Carga 4	-	8	0,2	184047,7	0,021
Carga 5	1000	500	12,5	2944,76	0,003
Carga 6	9650	600	15	2453,97	0,003
Carga 7	1000	600	15	2453,97	0,003
Carga 8	-	180	4,5	8179,9	0,092
Carga 9	1000	200	5	7361,91	0,008
Carga 10	425	250	6,25	5889,53	0,007
Carga 11	-	130	3,25	11326,01	0,013
Carga 12	500	150	3,75	9815,88	0,011
Carga 13	-	100	2,5	14723,82	0,017
Carga 14	500	450	11,25	3271,96	0,004
Carga 15	-	170	4,25	8661,07	0,010
Carga 16	225	112	2,8	13146,27	0,015
Carga 17	1000	360	9	4089,95	0,005
Carga 18	-	250	6,25	5889,53	0,007
Carga 19	-	100	2,5	14723,82	0,017
Carga 20	-	120	3	12269,85	0,014
Carga 21	-	67	1,67	22041,64	0,025
Carga 22	500	400	10	3680,95	0,004
Carga 23	360	145	3,62	10168,38	0,011
Carga 24	150	30	0,75	49079,39	0,055
Carga 25	-	300	7,5	4907,94	0,006
Carga 26	175	116	2,9	12692,95	0,014
Carga 27	225	225	5,62	6549,74	0,007
Carga 28	-	100	2,5	14723,82	0,017
Carga 29	500	30	0,75	49079,39	0,055
Carga 30	1000	299	1,75	4927,65	0,006

Carga 31	225	70	3,5	21034,03	0,024
Carga 32	500	140	2,75	10517,01	0,012
Carga 33	-	110	2,75	13385,29	0,015
Carga 34	300	240	6	6134,92	0,007
Carga 35	112,5	40	1	36810	0,042
Carga 36	300	268	6,7	5494	0,006
Carga 37	150	50	1,25	29448	0,033
Carga 38	1000	593	14,82	2483,8	0,003
Carga 39	225	43	1,08	3424,1	0,039
Carga 40	112,5	180	4,5	8179,9	0,009
Carga 41	1000	310	7,75	4749,6	0,005
Carga 42	2000	1219	30,47	1208,1	0,001
Carga 43	112,5	88	2,2	16732	0,002
Carga 44	500	287	7,17	5133,8	0,006
Carga 45	112,5	58	1,45	25386	0,029
Carga 46	112,5	130	3,25	11326	0,013
Carga 47	1000	694	17,35	2121,6	0,002
Carga 48	500	255	6,37	5778,6	0,007

Tabela 19 – Potência ativa e reativa modeladas.

Consumidores	Potência ativa modelada (kW)	% da Demanda Cont.	Potência reativa modelada (VAr)
Carga 1	294,48	92,02	0,13
Carga 2	27,61	92,02	0,01
Carga 3	530,79	91,99	0,23
Carga 4	7,36	92,02	0,00
Carga 5	460,12	92,02	0,20
Carga 6	552,14	92,02	0,24
Carga 7	552,14	92,02	0,24
Carga 8	165,64	92,02	0,71
Carga 9	184,05	92,02	0,08
Carga 10	230,06	92,02	0,10
Carga 11	119,63	92,02	0,05
Carga 12	138,04	92,02	0,06

Carga 13	92,02	92,02	0,04
Carga 14	414,11	92,02	0,18
Carga 15	156,44	92,02	0,07
Carga 16	103,07	92,02	0,04
Carga 17	331,29	92,02	0,14
Carga 18	230,06	92,02	0,10
Carga 19	92,02	92,02	0,04
Carga 20	110,43	92,02	0,05
Carga 21	61,47	91,75	0,03
Carga 22	368,10	92,02	0,16
Carga 23	133,25	91,90	0,06
Carga 24	27,61	92,02	0,01
Carga 25	276,07	92,02	0,12
Carga 26	106,75	92,02	0,05
Carga 27	206,87	91,94	0,09
Carga 28	92,02	92,02	0,04
Carga 29	27,61	92,02	0,01
Carga 30	15,09	5,05	0,01
Carga 31	257,67	368,10	0,11
Carga 32	79,53	56,81	0,03
Carga 33	101,23	92,02	0,04
Carga 34	220,86	92,02	0,09
Carga 35	36,81	92,03	0,02
Carga 36	246,63	92,02	0,11
Carga 37	46,01	92,03	0,02
Carga 38	545,52	91,99	0,23
Carga 39	3,99	9,29	0,02
Carga 40	165,64	92,02	0,07
Carga 41	285,27	92,02	0,12
Carga 42	1121,63	92,01	0,48
Carga 43	80,98	92,03	0,00
Carga 44	263,92	91,96	0,11
Carga 45	53,37	92,02	0,02
Carga 46	119,63	92,02	0,05
Carga 47	638,65	92,02	0,27
Carga 48	234,48	91,95	0,10

Tabela 20 – Valores médios das cargas

Consumidores	Demand Contratada (kW)	Potência ativa por fase (kW)	Potência reativa por fase (kVAr)	Resistência por fase (Ω)	Indutância por fase (H)
Carga 1	320	106,67	31,11	2829,22	14,86
Carga 2	30	10,00	2,92	30178,37	158,46
Carga 3	577	192,33	56,10	1569,07	8,24
Carga 4	8	2,67	0,78	113168,88	594,24
Carga 5	500	166,67	48,61	1810,70	9,51
Carga 6	600	200,00	58,33	1508,92	7,92
Carga 7	600	200,00	58,33	1508,92	7,92
Carga 8	180	60,00	17,50	5029,73	26,41
Carga 9	200	66,67	19,44	4526,76	23,77
Carga 10	250	83,33	24,31	3621,40	19,02
Carga 11	130	43,33	12,64	6964,24	36,57
Carga 12	150	50,00	14,58	6035,67	31,69
Carga 13	100	33,33	9,72	9053,51	47,54
Carga 14	450	150,00	43,75	2011,89	10,56
Carga 15	170	56,67	16,53	5325,59	27,96
Carga 16	112	37,33	10,89	8083,49	42,45
Carga 17	360	120,00	35,00	2514,86	13,21
Carga 18	250	83,33	24,31	3621,40	19,02
Carga 19	100	33,33	9,72	9053,51	47,54
Carga 20	120	40,00	11,67	7544,59	39,62
Carga 21	67	22,33	6,51	13512,70	70,95
Carga 22	400	133,33	38,89	2263,38	11,88
Carga 23	145	48,33	14,10	6243,80	32,79
Carga 24	30	10,00	2,92	30178,37	158,46
Carga 25	300	100,00	29,17	3017,84	15,85
Carga 26	116	38,67	11,28	7804,75	40,98
Carga 27	225	75,00	21,88	4023,78	21,13
Carga 28	100	33,33	9,72	9053,51	47,54
Carga 29	30	10,00	2,92	30178,37	158,46
Carga 30	299	99,67	29,07	3027,93	15,90
Carga 31	70	23,33	6,81	12933,59	67,91

Carga 32	140	46,67	13,61	6466,79	33,96
Carga 33	110	36,67	10,69	8230,46	43,22
Carga 34	240	80,00	23,33	3772,30	19,81
Carga 35	40	13,33	3,89	22633,78	118,85
Carga 36	268	89,33	26,06	3378,18	17,74
Carga 37	50	16,67	4,86	18107,02	95,08
Carga 38	593	197,67	57,65	1526,73	8,02
Carga 39	43	14,33	4,18	21054,68	110,56
Carga 40	180	60,00	17,50	5029,73	26,41
Carga 41	310	103,33	30,14	2920,49	15,34
Carga 42	1219	406,33	118,51	742,70	3,90
Carga 43	88	29,33	8,56	10288,08	54,02
Carga 44	287	95,67	27,90	3154,53	16,56
Carga 45	58	19,33	5,64	15609,50	81,96
Carga 46	130	43,33	12,64	6964,24	36,57
Carga 47	694	231,33	67,47	1304,54	6,85
Carga 48	255	85,00	24,79	3550,40	18,64

Tabela 21 – Valores máximos das cargas

Consumidores	Potência Instalada (kVA)	Potência ativa por fase (kW)	Potência reativa por fase (kVAr)	Resistência por fase (Ω)	Indutância por fase (H)
Carga 1	700	224,00	65,33	1347,29	7,07
Carga 2	75	24,00	7,00	12574,68	66,03
Carga 3	1000	320,00	93,33	943,10	4,95
Carga 4	16	5,12	1,49	58943,83	309,50
Carga 5	1000	320,00	93,33	943,10	4,95
Carga 6	9650	3088,00	900,67	97,73	0,51
Carga 7	1000	320,00	93,33	943,10	4,95
Carga 8	360	115,20	33,60	2619,73	13,76
Carga 9	1000	320,00	93,33	943,10	4,95
Carga 10	425	136,00	39,67	2219,06	11,65
Carga 11	260	83,20	24,27	3627,31	19,05
Carga 12	500	160,00	46,67	1886,20	9,90
Carga 13	200	64,00	18,67	4715,51	24,76

Carga 14	500	160,00	46,67	1886,20	9,90
Carga 15	340	108,80	31,73	2773,83	14,56
Carga 16	225	72,00	21,00	4191,56	22,01
Carga 17	1000	320,00	93,33	943,10	4,95
Carga 18	500	160,00	46,67	1886,20	9,90
Carga 19	200	64,00	18,67	4715,51	24,76
Carga 20	240	76,80	22,40	3929,59	20,63
Carga 21	134	42,88	12,51	7038,07	36,96
Carga 22	500	160,00	46,67	1886,20	9,90
Carga 23	360	115,20	33,60	2619,73	13,76
Carga 24	150	48,00	14,00	6287,34	33,01
Carga 25	600	192,00	56,00	1571,84	8,25
Carga 26	175	56,00	16,33	5389,15	28,30
Carga 27	225	72,00	21,00	4191,56	22,01
Carga 28	200	64,00	18,67	4715,51	24,76
Carga 29	500	160,00	46,67	1886,20	9,90
Carga 30	1000	320,00	93,33	943,10	4,95
Carga 31	225	72,00	21,00	4191,56	22,01
Carga 32	500	160,00	46,67	1886,20	9,90
Carga 33	220	70,40	20,53	4286,82	22,51
Carga 34	300	96,00	28,00	3143,67	16,51
Carga 35	112,5	36,00	10,50	8383,12	44,02
Carga 36	300	96,00	28,00	3143,67	16,51
Carga 37	150	48,00	14,00	6287,34	33,01
Carga 38	1000	320,00	93,33	943,10	4,95
Carga 39	225	72,00	21,00	4191,56	22,01
Carga 40	112,5	36,00	10,50	8383,12	44,02
Carga 41	1000	320,00	93,33	943,10	4,95
Carga 42	2000	640,00	186,67	471,55	2,48
Carga 43	112,5	36,00	10,50	8383,12	44,02
Carga 44	500	160,00	46,67	1886,20	9,90
Carga 45	112,5	36,00	10,50	8383,12	44,02
Carga 46	112,5	36,00	10,50	8383,12	44,02
Carga 47	1000	320,00	93,33	943,10	4,95
Carga 48	500	160,00	46,67	1886,20	9,90

Tabela 22 – Valores mínimos das cargas

Consumidores	Potência Instalada (kVA)	Potência ativa por fase (kW)	Potência reativa por fase (kVAr)	Resistência por fase (Ω)	Indutância por fase (H)
Carga 1	700	22,40	6,53	13472,87	70,74
Carga 2	75	2,40	0,70	125746,83	660,27
Carga 3	1000	32,00	9,33	9431,01	49,52
Carga 4	16	0,51	0,15	589438,27	3095,00
Carga 5	1000	32,00	9,33	9431,01	49,52
Carga 6	9650	308,80	90,07	977,31	5,13
Carga 7	1000	32,00	9,33	9431,01	49,52
Carga 8	360	11,52	3,36	26197,26	137,56
Carga 9	1000	32,00	9,33	9431,01	49,52
Carga 10	425	13,60	3,97	22190,62	116,52
Carga 11	260	8,32	2,43	36273,12	190,46
Carga 12	500	16,00	4,67	18862,02	99,04
Carga 13	200	6,40	1,87	47155,06	247,60
Carga 14	500	16,00	4,67	18862,02	99,04
Carga 15	340	10,88	3,17	27738,27	145,65
Carga 16	225	7,20	2,10	41915,61	220,09
Carga 17	1000	32,00	9,33	9431,01	49,52
Carga 18	500	16,00	4,67	18862,02	99,04
Carga 19	200	6,40	1,87	47155,06	247,60
Carga 20	240	7,68	2,24	39295,88	206,33
Carga 21	134	4,29	1,25	70380,69	369,55
Carga 22	500	16,00	4,67	18862,02	99,04
Carga 23	360	11,52	3,36	26197,26	137,56
Carga 24	150	4,80	1,40	62873,42	330,13
Carga 25	600	19,20	5,60	15718,35	82,53
Carga 26	175	5,60	1,63	53891,50	282,97
Carga 27	225	7,20	2,10	41915,61	220,09
Carga 28	200	6,40	1,87	47155,06	247,60
Carga 29	500	16,00	4,67	18862,02	99,04
Carga 30	1000	32,00	9,33	9431,01	49,52
Carga 31	225	7,20	2,10	41915,61	220,09

Carga 32	500	16,00	4,67	18862,02	99,04
Carga 33	220	7,04	2,05	42868,24	225,09
Carga 34	300	9,60	2,80	31436,71	165,07
Carga 35	112,5	3,60	1,05	83831,22	440,18
Carga 36	300	9,60	2,80	31436,71	165,07
Carga 37	150	4,80	1,40	62873,42	330,13
Carga 38	1000	32,00	9,33	9431,01	49,52
Carga 39	225	7,20	2,10	41915,61	220,09
Carga 40	112,5	3,60	1,05	83831,22	440,18
Carga 41	1000	32,00	9,33	9431,01	49,52
Carga 42	2000	64,00	18,67	4715,51	24,76
Carga 43	112,5	3,60	1,05	83831,22	440,18
Carga 44	500	16,00	4,67	18862,02	99,04
Carga 45	112,5	3,60	1,05	83831,22	440,18
Carga 46	112,5	3,60	1,05	83831,22	440,18
Carga 47	1000	32,00	9,33	9431,01	49,52
Carga 48	500	16,00	4,67	18862,02	99,04

Tabela 23 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-20-25-1.

Ponto de Monitoramento	Carga	Fase	Erro<0,01 p.u. (%)	Erro<0,03 p.u. (%)	Erro<0,05 p.u. (%)	Erro<0,07 p.u. (%)
M1	Leve	A	46,52	75,84	86,99	91,47
M1	Leve	B	47,67	72,85	85,14	91,24
M1	Leve	C	51,72	78,43	87,92	92,33
M2	Leve	A	46,58	74,01	85,75	90,71
M2	Leve	B	42,18	67,66	80,57	87,87
M2	Leve	C	48,37	75,72	87,34	92,09
M3	Leve	A	49,07	74,82	86,24	91,91
M3	Leve	B	46,82	74,81	85,56	91,54
M3	Leve	C	49,41	73,96	84,10	90,35
M4	Leve	A	48,56	74,46	86,59	92,42
M4	Leve	B	45,83	75,39	86,94	92,44
M4	Leve	C	49,05	74,21	86,36	91,68
M5	Leve	A	48,08	74,19	86,43	91,48
M5	Leve	B	47,98	73,98	85,53	91,31
M5	Leve	C	48,70	75,54	86,79	91,83

M6	Leve	A	47,95	73,73	84,99	91,09
M6	Leve	B	47,27	74,57	86,93	91,84
M6	Leve	C	49,88	73,56	87,57	92,70
M1	Média	A	38,98	67,23	79,83	86,67
M1	Média	B	45,27	68,27	82,20	90,16
M1	Média	C	46,52	67,94	81,01	89,27
M2	Média	A	40,39	62,18	78,93	85,95
M2	Média	B	12,47	60,62	77,05	85,12
M2	Média	C	42,23	65,93	79,87	89,29
M3	Média	A	43,76	65,31	78,99	87,18
M3	Média	B	42,49	65,61	80,63	89,07
M3	Média	C	43,73	64,63	77,43	87,91
M4	Média	A	44,09	66,12	80,97	88,69
M4	Média	B	42,04	66,90	82,28	89,61
M4	Média	C	45,10	66,89	80,43	89,64
M5	Média	A	41,99	63,31	78,21	87,26
M5	Média	B	43,96	66,81	81,49	88,72
M5	Média	C	43,21	68,24	82,47	90,63
M6	Média	A	43,88	66,66	79,30	88,20
M6	Média	B	43,44	64,22	79,56	84,46
M6	Média	C	42,72	67,14	80,20	88,44
M1	Pesada	A	40,48	61,12	71,34	81,22
M1	Pesada	B	41,63	63,49	76,66	83,90
M1	Pesada	C	41,35	59,81	71,76	82,01
M2	Pesada	A	39,60	58,73	71,45	79,31
M2	Pesada	B	10,22	54,29	67,26	79,41
M2	Pesada	C	41,19	62,15	75,47	82,80
M3	Pesada	A	41,53	58,09	70,74	80,43
M3	Pesada	B	41,38	59,25	71,76	82,64
M3	Pesada	C	39,66	55,98	72,42	82,79
M4	Pesada	A	41,68	61,02	73,81	81,55
M4	Pesada	B	41,57	64,83	75,37	82,35
M4	Pesada	C	41,32	61,51	72,32	79,88
M5	Pesada	A	42,65	59,40	72,53	80,99
M5	Pesada	B	40,68	59,38	72,74	81,85
M5	Pesada	C	41,42	64,71	76,83	84,93

M6	Pesada	A	40,57	62,14	74,05	82,01
M6	Pesada	B	42,01	61,48	73,66	83,25
M6	Pesada	C	43,53	63,98	75,22	83,89

Tabela 24 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-25-25-1.

Ponto de Monitoramento	Carga	Fase	Erro<0,01 p.u. (%)	Erro<0,03 p.u. (%)	Erro<0,05 p.u. (%)	Erro<0,07 p.u. (%)
M1	Leve	A	52,45	80,24	88,74	93,26
M1	Leve	B	48,68	75,72	86,65	92,25
M1	Leve	C	52,92	79,44	88,49	93,33
M2	Leve	A	44,59	71,53	85,24	90,21
M2	Leve	B	47,33	75,04	88,03	93,74
M2	Leve	C	50,85	77,99	88,05	92,64
M3	Leve	A	44,09	74,22	86,92	91,56
M3	Leve	B	48,40	75,11	86,14	92,20
M3	Leve	C	49,28	72,98	85,73	91,26
M4	Leve	A	52,42	78,19	89,89	93,63
M4	Leve	B	52,36	77,50	88,90	93,80
M4	Leve	C	54,36	80,25	88,92	93,63
M5	Leve	A	45,11	70,30	85,41	91,16
M5	Leve	B	49,16	75,25	85,86	91,34
M5	Leve	C	48,89	77,06	88,68	93,36
M6	Leve	A	47,14	73,28	85,15	90,93
M6	Leve	B	52,93	80,20	88,73	92,87
M6	Leve	C	46,58	70,67	82,46	89,31
M1	Média	A	47,49	71,24	84,59	91,00
M1	Média	B	45,57	68,17	80,80	89,57
M1	Média	C	46,94	72,18	84,57	92,10
M2	Média	A	40,36	66,56	79,40	88,49
M2	Média	B	41,36	64,84	79,59	88,23
M2	Média	C	43,84	67,43	80,36	88,70
M3	Média	A	45,25	69,14	81,24	89,57
M3	Média	B	41,29	65,63	82,06	89,50
M3	Média	C	40,14	64,63	78,73	87,04
M4	Média	A	46,18	72,00	83,53	90,67
M4	Média	B	49,81	73,53	85,23	89,94

M4	Média	C	48,14	73,71	84,88	91,95
M5	Média	A	12,97	61,73	77,73	88,81
M5	Média	B	41,80	65,31	80,00	88,65
M5	Média	C	45,82	69,41	82,63	89,80
M6	Média	A	42,14	61,77	77,92	87,71
M6	Média	B	46,57	69,78	82,88	90,81
M6	Média	C	17,44	67,15	80,24	89,89
M1	Pesada	A	44,87	67,96	78,65	85,60
M1	Pesada	B	39,60	62,66	75,12	83,41
M1	Pesada	C	42,99	64,91	75,71	82,27
M2	Pesada	A	13,65	59,67	71,52	80,12
M2	Pesada	B	39,46	59,41	73,26	79,49
M2	Pesada	C	42,11	61,68	76,87	83,63
M3	Pesada	A	42,55	64,59	76,30	84,11
M3	Pesada	B	40,43	61,91	72,88	81,34
M3	Pesada	C	14,03	57,55	67,35	76,76
M4	Pesada	A	42,74	66,97	79,25	85,17
M4	Pesada	B	40,91	64,20	77,00	84,78
M4	Pesada	C	42,64	67,73	80,77	85,64
M5	Pesada	A	9,60	55,96	69,06	79,12
M5	Pesada	B	41,60	61,30	74,33	82,28
M5	Pesada	C	41,22	64,72	75,29	84,23
M6	Pesada	A	41,64	59,13	73,40	80,96
M6	Pesada	B	44,14	63,43	76,79	85,61
M6	Pesada	C	11,07	58,94	72,11	81,11

Tabela 25 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-25-30-1

Ponto de Monitoramento	Carga	Fase	Erro<0,01 p.u. (%)	Erro<0,03 p.u. (%)	Erro<0,05 p.u. (%)	Erro<0,07 p.u. (%)
M1	Leve	A	49,48	77,50	87,67	92,92
M1	Leve	B	50,76	77,15	87,75	92,30
M1	Leve	C	52,57	79,04	89,01	94,03
M2	Leve	A	51,75	79,30	89,96	93,75
M2	Leve	B	52,28	77,87	89,35	93,27
M2	Leve	C	52,67	79,80	88,22	93,33
M3	Leve	A	52,82	80,02	89,26	93,08

M3	Leve	B	53,50	81,05	90,04	94,07
M3	Leve	C	50,37	79,55	89,79	93,11
M4	Leve	A	52,67	78,92	87,73	92,62
M4	Leve	B	53,62	80,97	89,32	93,16
M4	Leve	C	52,67	80,54	88,45	92,96
M5	Leve	A	54,33	80,40	90,12	93,64
M5	Leve	B	54,14	80,49	90,04	93,93
M5	Leve	C	54,98	80,66	88,46	92,77
M6	Leve	A	53,36	77,24	88,23	93,39
M6	Leve	B	54,42	78,40	88,44	93,40
M6	Leve	C	51,96	81,06	90,53	84,54
M1	Média	A	45,34	71,13	81,97	89,71
M1	Média	B	45,50	68,18	82,43	89,82
M1	Média	C	48,51	72,82	85,46	91,27
M2	Média	A	49,09	73,75	84,71	92,23
M2	Média	B	45,19	69,30	83,12	90,21
M2	Média	C	48,85	72,23	84,03	91,28
M3	Média	A	49,97	75,27	85,40	92,73
M3	Média	B	48,57	72,14	84,85	90,91
M3	Média	C	49,2	73,42	83,89	90,96
M4	Média	A	47,06	71,60	83,58	91,10
M4	Média	B	47,01	73,58	85,65	92,82
M4	Média	C	47,35	70,94	84,07	90,17
M5	Média	A	50,39	73,39	85,45	91,81
M5	Média	B	49,99	74,26	85,55	90,66
M5	Média	C	49,64	71,57	84,72	91,42
M6	Média	A	47,02	69,73	83,17	90,82
M6	Média	B	47,69	72,56	85,61	91,24
M6	Média	C	49,03	75,11	85,86	91,37
M1	Pesada	A	44,99	65,02	74,13	83,09
M1	Pesada	B	43,64	63,93	75,37	82,35
M1	Pesada	C	44,32	66,66	77,54	84,27
M2	Pesada	A	48,96	71,98	80,08	87,35
M2	Pesada	B	42,06	66,52	78,54	84,25
M2	Pesada	C	46,70	67,44	79,92	89,61
M3	Pesada	A	43,52	67,73	80,14	87,01

M3	Pesada	B	43,22	68,70	82,44	86,45
M3	Pesada	C	43,77	69,04	79,40	86,32
M4	Pesada	A	44,37	65,83	76,87	84,56
M4	Pesada	B	44,99	66,82	79,88	87,03
M4	Pesada	C	44,18	67,40	78,07	84,67
M5	Pesada	A	44,99	70,73	81,12	86,57
M5	Pesada	B	45,44	70,21	81,40	86,94
M5	Pesada	C	46,58	68,40	80,09	86,18
M6	Pesada	A	43,76	66,81	78,84	85,52
M6	Pesada	B	43,26	65,19	78,46	86,24
M6	Pesada	C	45,74	68,71	81,33	87,37

Tabela 26 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-30-30-1

Ponto de Monitoramento	Carga	Fase	Erro<0,01 p.u. (%)	Erro<0,03 p.u. (%)	Erro<0,05 p.u. (%)	Erro<0,07 p.u. (%)
M1	Leve	A	54,36	81,57	90,59	94,44
M1	Leve	B	53,03	82,15	89,74	93,88
M1	Leve	C	55,46	80,96	89,94	93,66
M2	Leve	A	53,34	80,67	89,64	93,11
M2	Leve	B	54,08	80,67	89,66	93,71
M2	Leve	C	58,19	82,48	90,54	94,01
M3	Leve	A	56,08	81,53	90,79	94,26
M3	Leve	B	48,76	76,75	86,45	90,67
M3	Leve	C	53,48	82,24	89,53	94,44
M4	Leve	A	60,02	83,41	90,96	93,96
M4	Leve	B	45,43	75,00	86,19	92,12
M4	Leve	C	56,62	81,72	89,95	93,51
M5	Leve	A	54,16	80,85	89,97	93,33
M5	Leve	B	51,84	81,26	89,95	93,29
M5	Leve	C	57,34	82,90	90,92	93,67
M6	Leve	A	57,32	81,41	91,35	94,22
M6	Leve	B	56,64	81,29	89,14	93,45
M6	Leve	C	58,04	85,38	91,49	94,38
M1	Média	A	48,45	75,48	85,67	92,40
M1	Média	B	50,38	72,80	85,71	91,40
M1	Média	C	50,26	74,39	86,02	91,18

M2	Média	A	48,48	72,60	86,33	92,56
M2	Média	B	50,56	76,74	88,23	93,11
M2	Média	C	47,12	75,43	87,44	93,10
M3	Média	A	49,06	72,65	85,06	91,33
M3	Média	B	43,04	66,76	80,01	87,71
M3	Média	C	48,46	72,26	84,11	91,38
M4	Média	A	51,96	77,86	88,79	93,19
M4	Média	B	41,49	66,43	79,43	87,08
M4	Média	C	49,90	78,33	88,17	93,07
M5	Média	A	49,29	75,53	88,13	92,64
M5	Média	B	48,65	74,91	84,65	90,64
M5	Média	C	53,69	76,87	87,40	92,58
M6	Média	A	51,16	78,04	87,51	93,77
M6	Média	B	51,06	73,48	85,51	91,74
M6	Média	C	51,23	77,09	88,35	93,34
M1	Pesada	A	48,26	73,19	80,77	87,56
M1	Pesada	B	46,36	68,45	81,61	88,23
M1	Pesada	C	46,32	66,29	77,76	84,84
M2	Pesada	A	44,18	66,99	79,13	84,96
M2	Pesada	B	46,80	69,70	80,89	86,21
M2	Pesada	C	47,10	70,35	81,68	86,45
M3	Pesada	A	45,18	67,79	80,29	87,06
M3	Pesada	B	17,61	64,73	76,73	85,56
M3	Pesada	C	45,59	65,89	77,27	83,26
M4	Pesada	A	51,37	73,39	82,89	88,87
M4	Pesada	B	14,99	62,04	72,62	81,08
M4	Pesada	C	47,55	73,19	84,54	89,19
M5	Pesada	A	48,55	70,58	80,88	88,06
M5	Pesada	B	46,08	67,06	77,98	86,79
M5	Pesada	C	46,79	70,38	81,55	88,19
M6	Pesada	A	50,80	71,42	83,79	88,26
M6	Pesada	B	45,93	69,82	80,96	87,12
M6	Pesada	C	47,57	69,89	82,11	87,77

Tabela 27 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-30-35-1

Ponto de Monitoramento	Carga	Fase	Erro<0,01 p.u. (%)	Erro<0,03 p.u. (%)	Erro<0,05 p.u. (%)	Erro<0,07 p.u. (%)
M1	Leve	A	57,26	81,63	89,85	94,14
M1	Leve	B	59,16	83,55	91,24	94,71
M1	Leve	C	58,24	82,99	91,79	94,97
M2	Leve	A	53,55	81,26	89,63	93,33
M2	Leve	B	57,32	82,64	91,36	94,27
M2	Leve	C	58,69	83,77	92,70	95,48
M3	Leve	A	51,68	80,28	90,25	93,25
M3	Leve	B	55,57	80,79	90,24	93,94
M3	Leve	C	56,39	84,08	92,13	94,94
M4	Leve	A	56,05	82,19	90,97	94,06
M4	Leve	B	57,37	82,96	91,73	94,44
M4	Leve	C	54,86	79,70	89,76	93,94
M5	Leve	A	52,42	79,46	88,67	92,58
M5	Leve	B	54,03	80,79	90,48	94,54
M5	Leve	C	57,36	84,46	91,15	94,48
M6	Leve	A	53,78	83,09	90,19	94,15
M6	Leve	B	56,91	83,52	90,98	94,21
M6	Leve	C	58,79	84,05	91,84	95,62
M1	Média	A	51,78	77,30	88,41	93,71
M1	Média	B	53,66	78,23	87,89	93,10
M1	Média	C	52,51	77,80	89,13	93,71
M2	Média	A	53,34	78,15	89,53	93,28
M2	Média	B	50,24	74,41	86,26	92,61
M2	Média	C	49,96	75,63	86,72	91,97
M3	Média	A	51,45	76,35	87,65	92,40
M3	Média	B	50,27	75,87	87,06	91,71
M3	Média	C	51,90	77,20	87,74	93,83
M4	Média	A	50,85	77,05	89,13	93,35
M4	Média	B	51,87	78,01	88,24	93,36
M4	Média	C	53,15	76,22	87,70	93,72
M5	Média	A	48,14	73,36	84,47	91,69
M5	Média	B	50,29	76,16	87,25	92,30
M5	Média	C	51,05	75,48	86,24	92,55

M6	Média	A	51,65	77,17	88,79	93,92
M6	Média	B	50,15	76,35	87,99	92,68
M6	Média	C	53,49	78,31	88,69	92,66
M1	Pesada	A	49,58	74,46	83,11	88,79
M1	Pesada	B	51,33	74,80	85,22	88,80
M1	Pesada	C	50,18	71,72	83,20	88,35
M2	Pesada	A	47,21	71,17	81,16	88,02
M2	Pesada	B	46,12	69,11	80,77	85,54
M2	Pesada	C	47,72	71,04	80,78	86,63
M3	Pesada	A	49,31	71,29	81,97	87,12
M3	Pesada	B	48,04	70,63	82,18	88,27
M3	Pesada	C	49,68	72,95	81,65	87,04
M4	Pesada	A	50,10	72,30	84,05	88,22
M4	Pesada	B	49,06	75,58	84,05	88,71
M4	Pesada	C	51,15	73,19	83,57	88,16
M5	Pesada	A	46,03	68,98	80,66	87,04
M5	Pesada	B	48,70	70,36	82,22	88,14
M5	Pesada	C	47,71	71,41	81,83	87,16
M6	Pesada	A	48,49	74,01	82,06	88,51
M6	Pesada	B	50,06	74,66	84,21	89,51
M6	Pesada	C	50,93	74,56	83,75	89,49

Tabela 28 - Erro das fases A, B e C para as cargas leve, média e pesada da topologia 6-35-35-1

Ponto de Monitoramento	Carga	Fase	Erro<0,01 p.u. (%)	Erro<0,03 p.u. (%)	Erro<0,05 p.u. (%)	Erro<0,07 p.u. (%)
M1	Leve	A	58,38	82,82	90,11	94,32
M1	Leve	B	56,09	81,80	90,76	93,91
M1	Leve	C	56,24	82,73	91,55	94,44
M2	Leve	A	56,12	81,98	91,17	94,18
M2	Leve	B	57,64	82,03	90,51	94,03
M2	Leve	C	59,06	83,35	91,20	94,58
M3	Leve	A	59,90	84,21	91,02	94,08
M3	Leve	B	57,02	84,04	91,65	94,58
M3	Leve	C	57,12	83,83	90,88	94,09
M4	Leve	A	58,33	83,71	91,36	94,41

M4	Leve	B	47,94	72,21	86,41	92,46
M4	Leve	C	61,86	85,95	92,27	94,94
M5	Leve	A	55,75	83,65	90,50	93,95
M5	Leve	B	58,71	82,69	91,00	94,39
M5	Leve	C	55,60	82,47	89,59	93,57
M6	Leve	A	60,07	83,74	90,41	93,68
M6	Leve	B	56,85	83,59	92,13	95,32
M6	Leve	C	55,91	84,00	90,96	94,41
M1	Média	A	54,26	79,58	88,95	94,53
M1	Média	B	52,00	77,74	86,53	92,96
M1	Média	C	52,63	76,35	87,93	93,25
M2	Média	A	47,33	74,94	86,54	92,53
M2	Média	B	50,28	76,43	87,89	92,94
M2	Média	C	55,35	80,23	89,28	94,43
M3	Média	A	54,55	78,34	88,98	93,60
M3	Média	B	51,03	75,88	87,08	93,81
M3	Média	C	52,08	76,86	87,76	92,63
M4	Média	A	55,78	80,75	90,41	93,27
M4	Média	B	17,78	67,84	82,56	89,15
M4	Média	C	51,56	77,24	87,80	93,26
M5	Média	A	52,07	77,95	88,35	94,11
M5	Média	B	52,13	79,93	88,49	93,91
M5	Média	C	51,17	76,87	85,44	92,46
M6	Média	A	57,65	80,21	90,17	94,54
M6	Média	B	52,43	79,21	89,83	93,56
M6	Média	C	54,09	80,00	88,66	93,35
M1	Pesada	A	51,85	74,91	84,25	89,87
M1	Pesada	B	49,14	71,56	82,55	87,68
M1	Pesada	C	50,43	71,42	82,85	88,21
M2	Pesada	A	48,99	70,27	81,16	87,84
M2	Pesada	B	47,66	70,51	82,23	87,36
M2	Pesada	C	52,06	77,48	84,75	89,39
M3	Pesada	A	53,65	76,20	84,62	89,55
M3	Pesada	B	51,86	75,62	83,62	88,48
M3	Pesada	C	47,57	70,78	81,35	86,76
M4	Pesada	A	51,88	75,33	83,90	89,85

M4	Pesada	B	13,84	62,87	76,09	82,78
M4	Pesada	C	51,27	72,03	83,11	88,57
M5	Pesada	A	48,67	73,58	83,71	89,09
M5	Pesada	B	51,33	75,15	84,05	89,70
M5	Pesada	C	46,33	70,49	81,66	86,88
M6	Pesada	A	49,41	74,51	84,45	89,62
M6	Pesada	B	50,73	73,31	84,05	88,55
M6	Pesada	C	53,25	75,86	84,72	89,69