

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
CÂMPUS CORNÉLIO PROCÓPIO  
DIRETORIA DE GRADUAÇÃO E EDUCAÇÃO PROFISSIONAL  
CURSO DE ENGENHARIA ELÉTRICA

VINICIOS THOMAZ MEDEIROS

**RECONHECIMENTO DE PADRÕES RELATIVOS AOS PROBLEMAS  
QUE CAUSAM VARIAÇÕES DE TENSÃO EM REGIME  
PERMANENTE UTILIZANDO REDES NEURAIAS ARTIFICIAIS**

CORNÉLIO PROCÓPIO

2015

**VINICIOS THOMAZ MEDEIROS**

**RECONHECIMENTO DE PADRÕES RELATIVOS AOS PROBLEMAS  
QUE CAUSAM VARIAÇÕES DE TENSÃO EM REGIME  
PERMANENTE UTILIZANDO REDES NEURAS ARTIFICIAIS**

Trabalho de Conclusão de Curso em  
Engenharia Elétrica, do Departamento  
Acadêmico de Engenharia Elétrica, da  
Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Murilo da Silva

**CORNÉLIO PROCÓPIO**

**2015**



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



## **FOLHA DE APROVAÇÃO**

**Vinícios Thomaz Medeiros**

**Reconhecimento de padrões relativos aos problemas que causam variações de tensão em regime permanente utilizando redes neurais artificiais**

Trabalho de conclusão de curso apresentado às 08:20hs do dia 11/11/2015 como requisito parcial para a obtenção do título de Engenheiro Eletricista no programa de Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná. O candidato foi arguido pela Banca Avaliadora composta pelos professores abaixo assinados. Após deliberação, a Banca Avaliadora considerou o trabalho aprovado.

---

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

---

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

---

Prof(a). Dr(a). Edson Aparecido Rozas Theodoro - (Membro)

---

Prof(a). Dr(a). Fábio Renan Durand - (Membro)

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

Dedico este trabalho à minha mãe Alice, que ao longo de toda minha vida, sempre se esforçou muito para que eu pudesse ter total condições de alcançar meus objetivos.

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus pela força e paz que eu tive para vencer as dificuldades.

Um agradecimento especial ao meu orientador Prof. Dr. Murilo da Silva, que além da dedicação na orientação deste trabalho, depositou sua confiança em mim fazendo com que eu conquistasse muitas vitórias. Com seus conselhos aprendi muito e pude crescer como pessoa e como profissional.

Agradeço a todos os professores da UTFPR-CP, pela dedicação na profissão, por todos os ensinamentos e conselhos que ofereceram em todas as disciplinas que participei. Em especial a Prof.<sup>a</sup> Dra. Gabriela, Prof. Dr. Danilo, Prof. Dr. Fabio e Prof. Dr. Edson pela simpatia e dedicação em oferecer dicas e conselhos que foram muito pertinentes para contribuição deste trabalho.

A minha mãe Alice e meu irmão Victor, que estiveram sempre ao meu lado me apoiando, me dando forças e sendo meu porto seguro para que eu continuasse sempre na luta durante essa etapa da minha vida.

Agradeço também a minha namorada Gislaine, que compartilhou comigo todo esse momento da graduação, sendo paciente nas minhas ausências e me ajudando bastante com dicas e apoio moral para o desenvolvimento deste e de muitos outros trabalhos ao longo do curso, transparecendo segurança e inspiração.

Aos meus amigos e colegas que conheci durante o curso e todos os demais que sempre torceram por mim e me apoiaram no decorrer da minha graduação.

Por fim, gostaria de agradecer a todos de maneira geral, que diretamente ou indiretamente me ajudaram e contribuíram para elaboração deste trabalho.

*“Sempre faça o melhor que puder, pois a sensação de que você poderia ter feito algo melhor, te acompanhará por toda a vida. ”*

(Próprio Autor)

## RESUMO

MEDEIROS, Vinícios Thomaz. Reconhecimento de padrões relativos aos problemas que causam variações de tensão em regime permanente utilizando redes neurais artificiais. 2015. 63 f. Trabalho de Conclusão de Curso em Engenharia Elétrica, do Departamento Acadêmico de Engenharia Elétrica, da Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2015.

Dado o constante avanço tecnológico das últimas décadas, conscientização e disseminação da informação à população, globalização e concorrência dos setores produtivos e a regulação do setor elétrico brasileiro, a qualidade da energia elétrica (QEE) tem ganhado grande importância no cenário geral, principalmente devido ao impacto financeiro que a falta de QEE pode trazer às diversas classes de consumidores. Deste modo, neste trabalho é proposto uma ferramenta para auxiliar as concessionárias e permissionárias de distribuição de energia elétrica quanto a verificação preliminar de problemas relacionados a variação de tensão de longa duração, sem que haja necessidade de uma avaliação completa do sistema, ou seja, o problema será classificado simultaneamente com a medição de tensão efetuada na unidade consumidora. A ferramenta proposta neste trabalho baseia-se na utilização de Redes Neurais Artificiais (RNAs) com arquitetura *Feed-Forward* de múltiplas camadas, conhecida como *Multi-Layer Perceptron* (MLP), para reconhecimento de padrões relativos a problemas causadores de variações de tensão de longa duração em sistemas de distribuição de energia. Propõe-se neste trabalho uma topologia de RNA simples e de fácil implementação em *hardware*. Os dados apresentados à rede na fase de treinamento e teste foram fornecidos pela concessionária de distribuição de energia elétrica, CPFL (Companhia Paulista de Força e Luz), os quais foram coletados a partir de medições reais realizadas em unidades consumidoras. A ferramenta proposta busca identificar a causa do problema assim que houver uma reclamação por parte do consumidor, de maneira rápida e eficiente.

**Palavras-chave:** Redes Neurais Artificiais. Algoritmo Supervisionado. Reconhecimento de Padrão. Variação de Tensão de Longa Duração. Qualidade de Energia Elétrica.

## ABSTRACT

MEDEIROS, Vinicios Thomaz. Identification of sources of generating problems causing stress changes in long-term using artificial neural network. 2015. 63 f. Final Thesis (Graduation) - Electrical Engineering Course, Academic Department of Electrical Engineering, Technological Federal University of Paraná. Cornélio Procópio, 2015.

Due to constant technological advance in the last decades, awareness and information dissemination to the population, globalization and competition of productive sectors and the regulation of the Brazilian electricity sector, the electrical energy quality has gained great importance in the overall scenario, mainly due to the financial impact that the lack of electrical energy quality can bring to the varied classes of consumers. Thus, this work proposes a tool to assist dealers and licensees in the electrical energy distribution regarding the preliminary verification for problems related to long-term voltage variations, without the need of a thorough evaluation of the system, which means that the problem will be simultaneously classified accordingly to the voltage measurement performed on the unit consumer. The tool proposed in this work is based on the utilization of Artificial Neural Networks with feed-forward architecture of multiple layers, known as Multi-Layer Perceptron (MLP) for pattern recognition of problems that cause long term voltage variations in energy distribution systems. This research proposes a simple RNA topology and easy implementation in hardware. Data presented for the network in the training and testing phase were provided by the electricity distribution utility, CPFL (Companhia Paulista de Forca e Luz), which were collected from actual measurements made in consumers units. The proposed tool seeks to identify the cause of problems as soon as there is a consumer complaining, in a quick and efficient way.

**Keywords:** Artificial Neural Networks. Supervised Algorithm. Pattern Recognition. Voltage variation of Long Duration. Quality of Electricity.



## PUBLICAÇÕES

MEDEIROS, V. T.; DA SILVA, M.; SILVA, H. J. B.; LEOPOLDINO, R; SILVA, R. C. S. Identificação Das Causas de Problemas de Nível de Tensão Inadequados Utilizando Redes Neurais Artificiais e Dados Reais da CPFL. In: XI CBQEE. In: Conferência Brasileira sobre Qualidade da Energia Elétrica, 2015, Campina Grande - PB. Conferência Brasileira sobre Qualidade da Energia Elétrica, realizado de 07/07/2015 a 10/07/2015.

MEDEIROS, V. T.; DA SILVA, M.; SILVA, H. J. B.; LEOPOLDINO, R; SILVA, R. C. S. Aplicação de redes neurais artificiais em reconhecimento de padrões relativos aos problemas de variações de tensão de longa duração no sistema elétrico de potência. In: XII SBAI. In: Simpósio Brasileiro de Automação Inteligente, realizado de 25/10/2015 a 28/10/2015, Natal - RN.

MEDEIROS, V. T.; DA SILVA M.; SILVA, H. J. B.; LEOPOLDINO, R; SILVA, R. C. S. Reconhecimento de Padrões Relativos aos Problemas que Causam Variações de Tensão em Regime Permanente Utilizando Redes Neurais Artificiais. In: XI CLAGTEE. In: *The XI Latin-American Congress Electricity Generation and Transmission*, 2015, São José dos Campos – SP, realizado de 08/11/2015 a 11/11/2015.

## LISTA DE FIGURAS

Figura 1: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um Setor Normal. ....	21
Figura 2: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um Setor Sobrecarregado.....	22
Figura 3: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um setor com problema de Conexão de Ramal. ....	23
Figura 4: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um Setor com problema de Conexão de Ramal após regularização.....	23
Figura 5: Queda de tensão ao longo do transporte da energia elétrica. ....	25
Figura 6: Neurônio Artificial.....	28
Figura 7: Estrutura de uma Rede MLP com duas camadas intermediárias. ....	30
Figura 8: Fluxograma do Processo que será utilizado para gerar os resultados. ....	37
Figura 9: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um setor com problema de TAP de transformador sobre dimensionado. ....	42
Figura 10: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um setor com problema de RT sobre dimensionado. ....	42
Figura 11: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um setor com problema de Trafo Avariado. ....	44
Figura 12: Modelo matemático de entrada da rede. ....	47

## **LISTA DE QUADROS**

- Quadro 1: Padrão de saída da rede neural para cada problema de acordo com o método 1. ... 39
- Quadro 2: Padrão de saída da rede neural para cada problema de acordo com o método 2. ... 40
- Quadro 3: Padrão de saída da rede neural para cada problema de acordo com o método 5. ... 43
- Quadro 4: Padrão de saída da rede neural para cada problema de acordo com o método 6. ... 45

## LISTA DE TABELAS

Tabela 1 - Resultados dos treinamentos para diferentes topologias de redes neurais utilizando o método 1 de tratamento dos dados .....	49
Tabela 2 – Resultados dos testes para diferentes padrões de problemas de acordo com o método 2 .....	50
Tabela 3 - Resultados dos treinamentos para diferentes topologias de redes neurais utilizando o método 2 de tratamento dos dados .....	51
Tabela 4 - Resultados dos testes para diferentes padrões de problemas de acordo com o método 2 .....	51
Tabela 5 - Resultados do melhor treinamento realizado utilizando os métodos 3 e 4 de tratamento dos dados .....	52
Tabela 6 - Resultados dos testes para diferentes padrões de problemas de acordo com o método 3 .....	52
Tabela 7 – Resultados dos testes para diferentes padrões de problemas de acordo com o método 5 .....	53
Tabela 8 – Resultados dos testes para diferentes padrões de problemas de acordo com o método 5 .....	54
Tabela 9 - Melhores resultados no treinamento para todas as redes neurais individuais utilizando o método 7 de tratamento dos dados .....	55
Tabela 10 – Resultados dos testes para diferentes padrões de problemas de acordo com o método 7 .....	56
Tabela 11 – Resultado geral dos testes para todos os métodos .....	56

## LISTA DE ABREVIACOES

ANEEL	Agncia Nacional de Energia Eltrica;
CPFL	Companhia Paulista de Fora e Luz;
DRC	Durao Relativa de Transgresso de tenso Precria Individual da Unidade Consumidora;
DRP	Durao Relativa de Transgresso de tenso Crtica Individual da Unidade Consumidora;
MLP	<i>Multi-Layer Perceptron;</i>
MSE	<i>Mean Squared Error;</i>
PRODIST	Procedimentos de Distribuio;
QEE	Qualidade de Energia Eltrica;
RNA	Rede Neural Artificial;
RT	Regulador de Tenso;
SEP	Sistema Eltrico de Potncia;

## LISTA DE SÍMBOLOS

$\Delta V$	Queda de Tensão
$l$	Comprimento do Condutor
$I_c$	Corrente do Condutor
$z$	Impedância da Linha
$r$	Resistência da Linha
$x$	Reatância da Linha
$\varphi$	Ângulo $\Phi$
$\{x_1, x_2, \dots, x_n\}$	Entrada da Rede
$\{w_1, w_2, \dots, w_n\}$	Pesos Sinápticos da Rede
$\theta$	Limiar de Ativação
$u$	Potencial de Ativação
$g(u)$	Função de Ativação
$y$	Saída da Rede
$\beta$	Constante Beta
$e$	Exponencial
$V$	Volts
$\Sigma$	Somatório

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>15</b>
1.1	QUALIDADE DA ENERGIA ELÉTRICA .....	15
1.2	OBJETIVO.....	18
1.2.1	Objetivo Geral.....	18
1.2.2	Objetivos Específicos.....	18
1.3	JUSTIFICATIVA.....	19
<b>2</b>	<b>MOTIVAÇÃO DO PROBLEMA</b> .....	<b>21</b>
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>25</b>
3.1	VARIAÇÃO DE TENSÃO DE LONGA DURAÇÃO .....	25
3.2	REDES NEURAIS ARTIFICIAIS .....	26
3.2.1	Definição de Rede Neural Artificial .....	26
3.2.2	Neurônio Artificial .....	28
3.2.3	Função de Ativação.....	29
3.2.4	Rede MLP .....	30
3.2.5	Algoritmo de treinamento .....	31
3.2.5.1	Método Levenberg-Marquardt.....	32
<b>4</b>	<b>METODOLOGIA</b> .....	<b>37</b>
4.1	TRATAMENTO DOS DADOS .....	37
4.1.1	Método 1 .....	38
4.1.2	Método 2 .....	39
4.1.3	Método 3 .....	41
4.1.4	Método 4 .....	41
4.1.5	Método 5 .....	41
4.1.6	Método 6 .....	43
4.1.7	Método 7 .....	45
4.2	TREINAMENTO DA RNA.....	46
4.3	TESTE DA RNA .....	47
<b>5</b>	<b>RESULTADOS E DISCUSSÃO</b> .....	<b>49</b>
5.1	ANÁLISE DOS RESULTADOS OBTIDOS A PARTIR DO MÉTODO 1 .....	49
5.2	ANÁLISE DOS RESULTADOS OBTIDOS A PARTIR DO MÉTODO 2 .....	50
5.3	ANÁLISE DOS RESULTADOS OBTIDOS PARA O MÉTODO 3 E 4. ....	52
5.4	ANÁLISE DOS RESULTADOS OBTIDOS A PARTIR DO MÉTODO 5. ....	53
5.5	ANÁLISE DOS RESULTADOS OBTIDOS A PARTIR DO MÉTODO 6. ....	54
5.6	ANÁLISE DOS RESULTADOS OBTIDOS A PARTIR DO MÉTODO 7. ....	54
5.7	ANALISE GERAL DOS RESULTADOS .....	56

<b>6</b>	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>58</b>
<b>7</b>	<b>PERSPECTIVAS PARA TRABALHOS FUTUROS .....</b>	<b>60</b>
	<b>REFERÊNCIAS .....</b>	<b>61</b>



# 1 INTRODUÇÃO

## 1.1 QUALIDADE DA ENERGIA ELÉTRICA

A energia elétrica é um recurso indispensável para o desenvolvimento sócio/econômico de um país. Dessa forma, os Sistemas Elétricos de Potência (SEP) devem garantir um alto grau de confiabilidade e conformidade na continuidade do fornecimento da energia elétrica. O termo confiabilidade está ligado à continuidade do fornecimento de energia elétrica ao consumidor, ou seja, se há ou não a mesma, já o termo conformidade está diretamente associado à forma de onda entregue ao consumidor, ou melhor, aos fenômenos associados a forma de onda da tensão. Dentre estes fenômenos pode-se destacar as variações de tensão de longa duração, que são caracterizadas pela mudança na amplitude da tensão por um período maior que 1 minuto e são classificadas como: sub tensão, sobre tensão e interrupção sustentada (DUGAN et al., 2003).

As interrupções sustentadas são caracterizadas pelo decréscimo do valor eficaz da tensão para menos de 10% da tensão nominal do sistema, sendo que tipicamente os valores ficam em 0 Volts. As interrupções são inerentes ao sistema elétrico e advindas de diversos motivos, sendo eles: falha de disjuntores, queima de fusível, falha de componentes do sistema, curto-circuito, rompimento dos cabos por queda de árvores, tempestades, entre outros. Além disso, as interrupções sustentadas do fornecimento de energia, podem ser programadas pela própria concessionária, devido a necessidade de realizar melhorias e manutenção no sistema de fornecimento.

As sub tensões são caracterizadas pelo decréscimo do valor eficaz da tensão abaixo de 90%, sendo que tipicamente os valores ficam entre 10 e 90% da tensão nominal. A sub tensão é inerente ao sistema elétrico e pode ser causada principalmente, pelo carregamento excessivo de circuitos alimentadores, pois os mesmos estão submetidos a determinados níveis de corrente que interagindo com a impedância da rede, dão origem a quedas de tensão acentuadas. Outros problemas que causam sub tensão são: seleção de TAPs errados de transformadores, problemas com reguladores de tensão, transformadores avariados, falha em conexão de circuitos, dentre outros. A sub tensão pode causar mau funcionamento de dispositivos eletrônicos, equipamentos e processos, aquecimento e perda de vida útil em motores, diminuição do índice de iluminação em caso de lâmpada incandescentes. Tais problemas podem culminar em perdas financeiras, bem como, insatisfação das diversas classes de consumidores (KJOLLE et al., 2008).

As sobre tensões são caracterizadas pelo aumento do valor eficaz da tensão acima de 110%, sendo que tipicamente os valores permanecem entre 110 e 120% do valor nominal. As sobre tensões são ocasionadas principalmente, pelo desligamento de grandes cargas do sistema, os quais são submetidos a determinados níveis de corrente, que ao interagirem com a impedância da rede, dão origem a elevações de tensão acentuadas. Outros problemas que causam a sobre tensão são: TAP errado de transformadores, excesso de bancos de capacitores fixos, falta de neutro em sistemas trifásicos, problemas com reguladores de tensão, dentre outros. A sobre tensão pode causar falha em dispositivos elétricos, atuação de proteções do sistema, elevação da potência reativa fornecida, queima de lâmpadas, dentre outros. Tais problemas, assim como problemas de sub tensão, podem culminar em perdas financeiras, bem como, insatisfação das diversas classes de consumidores (KJOLLE et al., 2008).

Do ponto de vista das concessionárias de distribuição de energia as variações de tensão de longa duração podem gerar inúmeras reclamações de consumidores e desgaste da sua imagem, assim como, acarretar penalizações devido a transgressão dos padrões de nível de tensão estabelecidos por normas diante um ambiente regulado.

No Brasil, as variações de tensão de longa duração são reguladas pela ANEEL, por meio do PRODIST, módulo 8, revisão 6. Neste caso, é notório que a cada nova revisão do PRODIST busca-se melhorar a qualidade da energia e o serviço prestado pelas concessionárias aos seus consumidores. Por exemplo, a revisão 6, do módulo 8 do PRODIST extingue o prazo de regularização do nível de tensão, uma vez diagnosticada a transgressão dos padrões de nível de tensão, estabelece-se o ressarcimento financeiro ao consumidor, bem como, diminui a faixa de nível de tensão adequada de algumas classes de tensões de forma a restringir o limite de transgressão de tensão permitido.

Portanto, a partir de 2015 as concessionárias terão um aumento de custos referente a compensação financeira paga aos clientes devido à dificuldade em corrigir os problemas de níveis de tensão dentro do tempo hábil, visto que não há mais prazo para regularização do problema.

Na literatura nacional e internacional, como em (RODRIGUEZ et al., 2014), (GOIS et al., 2009), (DELMONT; OLESKOVICZ; ARRUDA, 2007), (CHANDEL; GULERIA; CHANDEL, 2008), (GAOUDA et al., 1999), (CERQUEIRA et al., 2006) e (GRANADOS-LIEBERMAN et al., 2011), encontram-se diversas propostas para detecção e classificação de distúrbios relacionados à qualidade da energia, porém, poucos são os métodos propostos que classificam a fonte causadora do distúrbio, o que se faz muito importante nos dias de hoje, dado a legislação vigente e a necessidade de uma tomada de decisão rápida e eficiente por parte da

concessionária, visto que a regularização do problema que esteja causando o distúrbio deve ser feita no menor tempo possível.

Dado o exposto, este trabalho busca uma alternativa para análise e classificação das causas dos problemas que levam a variações de tensão de longa duração, com o objetivo de identificar a causa do problema e assim tomar a melhor decisão para correção do mesmo, trazendo benefícios a concessionária quanto a melhoria do processo, redução do número de ressarcimentos e custo de manutenção com melhorias do sistema de distribuição, bem como, ao consumidor através da rápida resolução do problema.

O presente trabalho propõe classificar diferentes padrões de problemas que acarretam variações de tensão de longa duração utilizando RNA, as quais serão treinadas e testadas com dados reais de tensão obtidos em campo e fornecidas pela CPFL.

## 1.2 OBJETIVO

### 1.2.1 Objetivo Geral

Propor uma ferramenta fundamentada em Redes Neurais Artificiais para reconhecer padrões de fontes geradoras de problemas que causam níveis de tensão inadequados em sistemas de distribuição de energia elétrica.

### 1.2.2 Objetivos Específicos

- Realizar pesquisas bibliográficas relacionadas a problemas de variação de longa duração ligadas a afundamentos e elevações de tensão, metodologias de análise: detecção e classificação dos agentes causadores e normatização vigente;
- Realizar estudos referentes a Redes Neurais Artificiais. Conceitos, tipos de RNAs, técnicas de treinamento e aplicabilidade ao problema proposto;
- Adequação dos dados das medições de tensão fornecidos pela concessionária a serem apresentadas a RNA na fase de treinamento e teste. Avaliar diferentes metodologias de tratamento dos dados para apresentação a RNA;
- Realizar treinamentos com as RNAs a fim de encontrar a melhor topologia para cada metodologia de tratamento dos dados, que seja capaz de resolver o problema, buscando sempre prezar pela simplicidade e eficiência;
- Realizar testes com a RNA para cada metodologia proposta, utilizando dados reais fornecidos pela CPFL;
- Analisar e discutir os resultados obtidos para validar a eficiência de RNA na identificação das causas de níveis de tensão inadequados.

### 1.3 JUSTIFICATIVA

A principal motivação para elaboração deste trabalho está baseada na revisão 6 do módulo 8 do PRODIST que entrou em vigência em 01/01/2015. Esta revisão do módulo 8 do PRODIST, que trata e regula os aspectos de qualidade da energia elétrica fornecida ao consumidor, contemplou diversas mudanças, dentre elas a extinção dos prazos para que seja realizada a regularização dos níveis de tensão quando da constatação da transgressão dos limites dos níveis adequados de tensão delineados por essa mesma resolução. Na revisão 4 do módulo 8 do PRODIST, vigente até 31/12/2014, a ANEEL definia que em caso de reclamação de nível de tensão por parte do consumidor, a concessionária teria 30 dias para realização da medição de tensão comprobatória do problema e estimação dos indicadores de transgressão dos níveis de tensão DRP (duração relativa de transgressão de tensão precária individual da unidade consumidora) e DRC (duração relativa de transgressão de tensão crítica individual da unidade consumidora). Uma vez comprovado a transgressão dos indicadores de nível de tensão (DRP/DRC), a concessionária teria o prazo de 90 dias para regularização do problema devido a transgressão do indicador DRP e 15 dias caso fosse constatado DRC, a partir da comunicação ao consumidor da violação dos limites de nível de tensão.

Portanto, as concessionárias dispunham de um prazo para regularização do problema de nível de tensão, sem que houvesse penalização da concessionária e conseqüente ressarcimento ao consumidor, caso o problema fosse sanado dentro do prazo de regularização. Na revisão 6 do módulo 8, com a revogação dos prazos para regularização, uma vez constatado a transgressão dos indicadores de nível de tensão em regime permanente, as concessionárias deverão compensar imediatamente o consumidor até que o problema seja sanado e comprovado por uma nova medição.

Percebe-se que a partir de 2015 as concessionárias terão um aumento de custos referente a compensação financeira feita aos clientes devido a incapacidade de corrigir os problemas de níveis de tensão em tempo hábil. Portanto, o desenvolvimento de uma ferramenta que auxilie na identificação dos problemas ligados a variações de tensão será benéfico tanto para concessionárias como para os consumidores. Com a ferramenta proposta neste trabalho a concessionária poderá diagnosticar qual a causa dos problemas de níveis de tensão inadequados na rede, de forma rápida e eficiente, sem a necessidade de uma avaliação minuciosa. Isto fará com que o tempo de reparo diminua, evitando assim a compensação ao consumidor e o pagamento de multas a ANEEL. Desta maneira o consumidor também passará a ficar menos

tempo com níveis de tensão inadequados, passando a contar com uma maior qualidade de energia. Vale Ressaltar que, mesmo que o consumidor seja compensado financeiramente pela concessionária, ainda assim, existem problemas de variações de tensão que podem prejudicar o funcionamento das cargas, no âmbito industrial esses problemas podem gerar maiores custos do que a compensação.

## 2 MOTIVAÇÃO DO PROBLEMA

Atualmente, a análise do nível de tensão em regime permanente é realizada pelo estudo dos valores de tensão eficaz integralizados de 10 em 10 minutos durante 7 dias, perfazendo 1008 leituras válidas. A identificação ou não de transgressão baseia-se somente na relação dos números de leituras que estão fora das faixas adequadas pelo número total de leituras comparada a limites estabelecidos por norma. Todo este processo é regulamentado pela ANEEL, por meio do módulo 8 do PRODIST. Na grande maioria dos casos, o nível de tensão aferido varia de acordo com o carregamento do sistema, da carga do consumidor e das características do sistema de distribuição, apresentando, portanto, um padrão específico, ou seja, um comportamento característico ao longo dos dias e da semana. Neste contexto, o sinal de medição pode ter um padrão normal, onde todas as amostras permanecem dentro da faixa de tensão prevista pelo PRODIST, conforme a Figura 1, ou um padrão anormal, onde algumas amostras ultrapassam as faixas de limites adequados de tensão, conforme a Figura 2. Neste caso, o sinal de medição tem um padrão característico de setor sobrecarregado. Contudo, ambos os padrões seguem um perfil característico de queda de tensão devido a variação de carga do sistema.

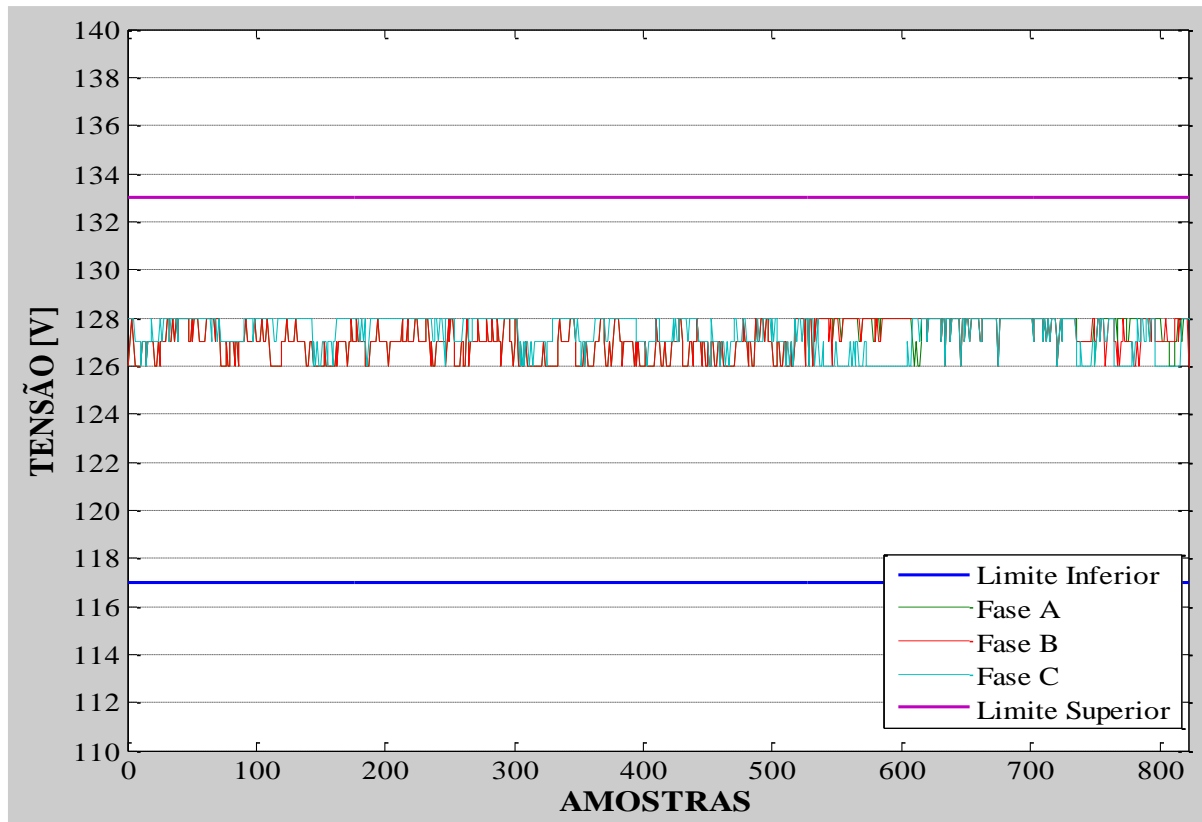
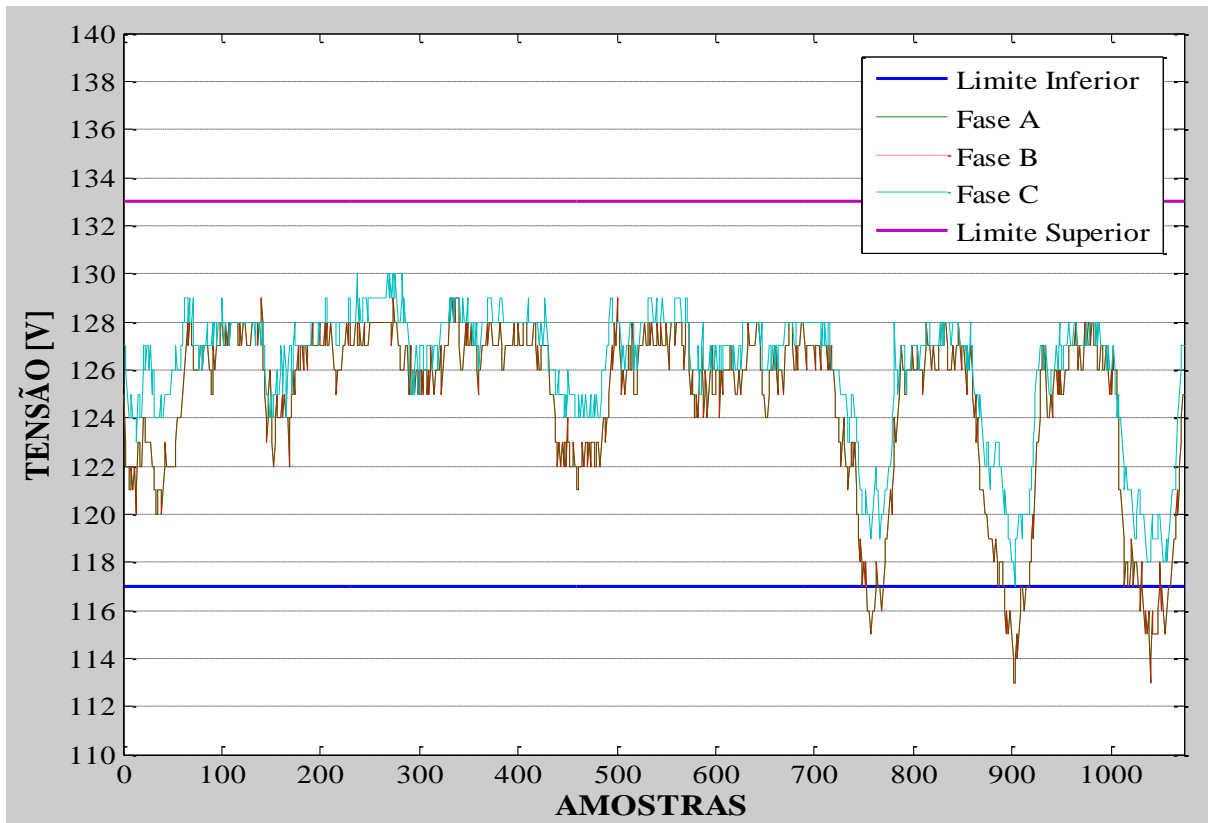


Figura 1: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um Setor Normal.  
Fonte: Próprio Autor

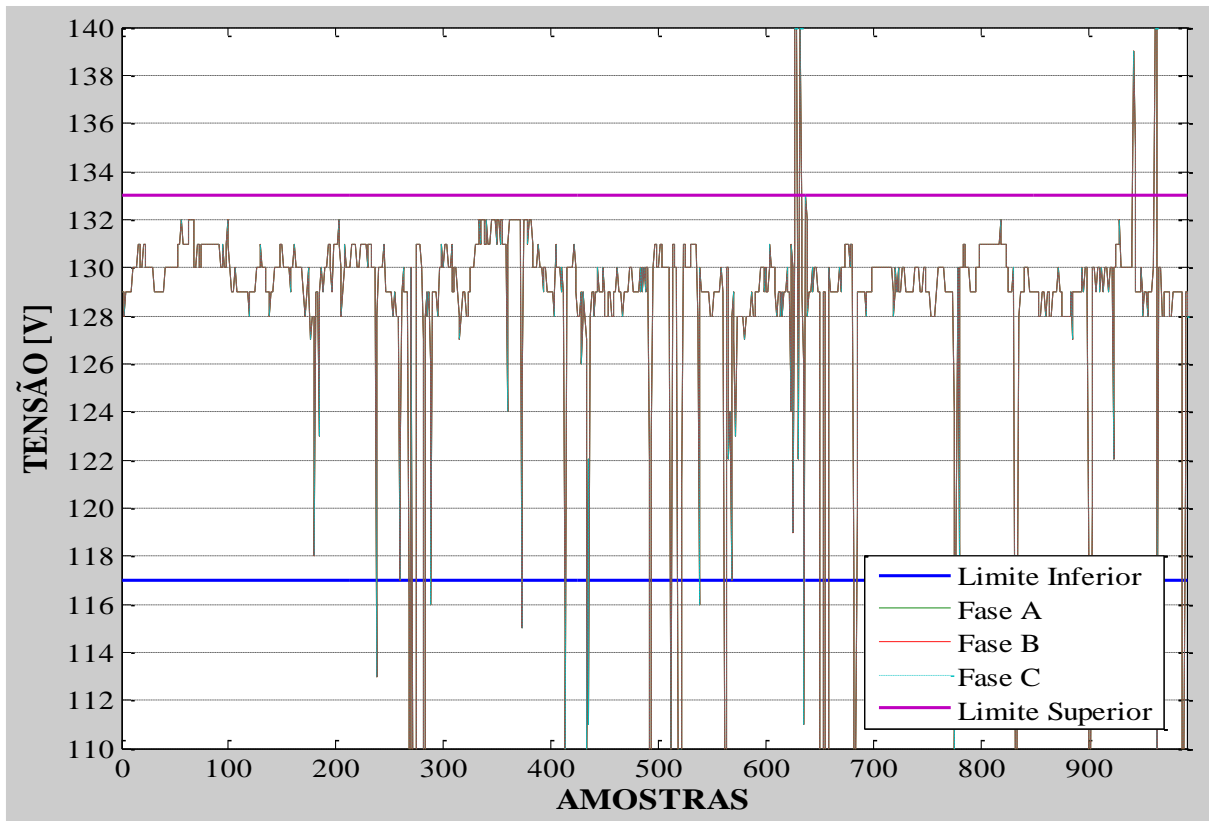


**Figura 2: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um Setor Sobrecarregado.**

**Fonte: Próprio Autor.**


Todavia, em algumas situações, como em casos onde tem-se uma avaria no transformador, ramal de entrega parcialmente ou totalmente rompido, conexões dos ramais com problemas, transformador com TAP regulado erroneamente, regulador de tensão com problemas, dentre outros, o padrão normal de queda de tensão é alterado, de acordo com cada problema, ou seja, cada causa apresenta uma assinatura característica da forma de onda da tensão. Tal fato é ilustrado por meio da Figura 3, que apresenta um padrão de medição de tensão real, realizada em um consumidor da área de concessão da CPFL, onde foi constatado problema na conexão do ramal de entrada. Já na Figura 4, pode-se observar um padrão de medição realizado no mesmo consumidor após regularização da conexão com problema.





**Figura 3: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um setor com problema de Conexão de Ramal.**

Fonte: Próprio Autor.



**Figura 4: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um Setor com problema de Conexão de Ramal após regularização.**

Fonte: Próprio Autor.

Analisando as Figuras 3 e 4, fica evidente que um problema de nível de tensão causado por uma falha na conexão pode passar despercebido em uma análise conforme rege o PRODIST e ser tratado como um problema de nível de tensão padrão, que muitas vezes requer uma solução mais onerosa e demorada, acarretando penalizações por parte do órgão regulador. Mesmo quando percebida a alteração na medição, é necessário muita experiência e conhecimento do profissional envolvido para identificar a causa daquele determinado problema, deste modo, muitas vezes está pré-avaliação do problema é realizada por tentativa e erro, por meio de uma inspeção minuciosa da rede, tornando o processo de identificação e regularização do problema mais lento e relativamente caro.

Dado a dificuldade de se identificar e analisar as causas de situações anormais de problemas de nível de tensão, verificou-se a possibilidade de desenvolver uma ferramenta computacional para auxílio destas análises, baseada na identificação da causa pela análise do padrão do nível de tensão apresentado por cada problema.

Existem várias ferramentas computacionais citadas na literatura por Marques (2000) que podem resolver problemas com reconhecimento de padrões, tais como: modelos probabilísticos, processamento de sinais, sistemas adaptativos, lógica fuzzy, RNA, entre outros. Dentre as ferramentas citadas para identificação de padrões optou-se por utilizar redes neurais artificiais (RNAs), dada a sua grande aplicação em reconhecimento de padrões conforme Silva, Spatti e Flauzino (2010) e a disponibilidade de dados reais para treinamento, validação e teste das redes.

### 3 FUNDAMENTAÇÃO TEÓRICA

#### 3.1 VARIAÇÃO DE TENSÃO DE LONGA DURAÇÃO

As cargas ligadas à rede de distribuição de energia elétrica variam no decorrer do dia devido, principalmente, às manobras e oscilações na demanda de consumo. Tanto os equipamentos da concessionária como os pertencentes aos consumidores são projetados para operar em determinado nível de tensão. A operação prolongada desses equipamentos em uma tensão fora de limites aceitáveis pode afetar o seu correto funcionamento, reduzindo a sua vida útil ou até mesmo causando interrupções não programadas.

As quedas de tensão da rede primária e secundária podem ser ajustadas para que o circuito tenha níveis apropriados de tensões. A principal dificuldade de fornecer tensões em faixas apropriadas é o problema da queda de tensão durante o transporte da energia, ou seja, o nível de tensão no circuito não é o mesmo no ponto de entrega, conforme Figura 5.

A queda de tensão é dada com boa aproximação, conforme (KAGAN; OLIVEIRA; ROBBA, 2010), pela equação (1):

$$\Delta V = l I_c |z| \quad (1)$$

Sendo:

$$|z| = (r \cos \varphi + x \sin \varphi)$$

Sendo que:  $\Delta V$  é a queda de tensão no cabo,  $l$  é o comprimento do cabo,  $I_c$  corrente de carga,  $|z|$  é o módulo da impedância equivalente da linha  $r$  a resistência do cabo e  $x$  a reatância do cabo.




Figura 5: Queda de tensão ao longo do transporte da energia elétrica.  
Fonte: Próprio Autor

A queda de tensão apresenta maior atenuação nos sistemas de baixa tensão com baixo fator de potência, circuitos monofásicos e circuitos desbalanceados. A magnitude da queda de tensão fornecida aos circuitos situados ao longo dos alimentadores é dependente da demanda atual da rede consumidora, pois a queda de tensão pode ser mais elevada em horários de maior consumo de energia.

Como há diversas cargas ligadas na rede de distribuição, elas são agrupadas em circuitos. Cada circuito dessa unidade consumidora é representado como uma carga equivalente. A modelagem dos circuitos dentro dessa unidade é importante para se definir o nível de tensão a ser fornecido no barramento secundário da subestação primária, de forma que a tensão tanto no circuito mais próximo quanto no mais distante esteja dentro dos limites aceitáveis.

Somada as quedas de tensão inerentes ao sistema de distribuição, pode-se ter variações de tensão decorrentes de outras fontes tais como: TAP errado de transformadores, transformadores avariados, mau contato devido a conexões nos ramais, rompimento parcial ou total de ramal de entrada, etc. Esses fatores deterioram de forma contínua ou aleatória o nível de tensão fornecido aos consumidores. Tais problemas podem passar despercebidos em uma análise menos apurada e serem tratados como queda de tensão devido ao carregamento do circuito, cuja solução é mais demorada e dispendiosa.

## 3.2 REDES NEURAIS ARTIFICIAIS

### 3.2.1 Definição de Rede Neural Artificial

Uma rede neural artificial é definida, conforme Silva, Spatti e Flauzino (2010), por um modelo computacional, que contém um conjunto de neurônios artificiais interligados entre si por conexões sinápticas artificiais. Cada conjunto de neurônios artificiais armazena informações na forma de matrizes ou vetores coluna de pesos sinápticos.

Estas estruturas se assemelham ao sistema nervoso biológico, com capacidade de ponderar informações de acordo com sua necessidade (HAYKIN, 1999).

Uma rede neural também pode ser tratada como um método de inteligência computacional que consiste em tentar simular o funcionamento do cérebro humano, ou seja, através de equacionamentos não lineares, realizado computacionalmente por neurônios artificiais, desta maneira é possível implementar um neurônio artificial, bem como suas conexões sinápticas artificiais. Estas conexões tem o propósito de transmitir impulsos que

podem ou não ativar outros neurônios, esses impulsos são normalmente transmitidos no sentido dos neurônios antecessores para os posteriores.

Uma vez que se tenha um conjunto de neurônios artificiais interligados por conexões sinápticas artificiais, pode-se dizer que se tem uma rede neural artificial. Uma rede deve possuir necessariamente um conjunto de neurônios de entrada, que são normalmente chamados de camada de entrada, bem como, um conjunto de neurônios de saída, que é dita camada neural de saída. Redes mais complexas podem ainda possuir camadas intermediárias de neurônios, que são dispostas entre a camada de entrada e a camada de saída. Uma camada de neurônios pode ser compreendida como um estágio de processamento da RNA, que pode possuir um ou mais neurônios dispostos paralelamente entre si.

Uma RNA possui basicamente duas fases de implementação. Na primeira fase ela deve ser treinada. Uma vez que a rede esteja devidamente treinada passa-se para segunda fase, onde a mesma será testada.


Existem dois métodos de treinamento de uma RNA, sendo eles, supervisionado e não supervisionado. No algoritmo supervisionado um conjunto de amostras é apresentado como entrada para rede, assim como um conjunto de dados esperados, que o usuário define como resposta ideal para rede a partir da entrada que foi apresentada. Desta maneira a RNA tentará relacionar os dados de entrada com os dados esperados. Este tipo de treinamento tem como característica um aprendizado com base em dados pré-estabelecidos, ou seja, inicialmente a rede possui uma entrada e uma saída desejada. Então, os pesos associados aos neurônios serão ajustados até que a rede consiga obter uma saída tão próxima da desejada possível. Um algoritmo de treinamento não supervisionado consiste em apresentar a rede apenas dados de entrada. Então, espera-se que a rede obtenha uma saída fixa, portanto, neste caso a saída da rede não pode ser previamente conhecida.

Uma vez que a rede tenha realizado o treinamento, pode-se dizer que a rede está apta para uma determinada função, que lhe será imposta na fase de teste. Então, se forem apresentados um novo conjunto de amostras de entrada para rede, que esteja relacionado com o que a rede foi treinada, ela será capaz de realizar ponderações, a fim de obter a melhor resposta de acordo com a nova entrada que lhe foi apresentada.

Portanto, percebe-se que assim como o cérebro humano, quanto maior o número de informações apresentada a rede no treinamento, maior será sua capacidade de compreensão de novas informações quando for testada.

### 3.2.2 Neurônio Artificial

A Figura 6, representa o modelo de um neurônio artificial e como ele deve ser implementado computacionalmente, sua estrutura é composta por sete elementos principais conforme Silva, Spatti e Flauzino (2010), sendo eles:



**Figura 6: Neurônio Artificial.**  
**Fonte: Barra (2013)**

- a) Dados de entrada  $\{x_1, x_2, \dots, x_n\}$ : são os dados fornecidos pelo usuário de acordo com a aplicação do problema;
- b) Pesos sinápticos  $\{w_1, w_2, \dots, w_n\}$ : são os coeficientes de ponderação associado a cada dado de entrada, ou seja, valores que representam quão importante um dado de entrada é para o neurônio em relação aos demais;
- c) Combinador linear  $\{\Sigma\}$ : realiza operações a fim de gerar um potencial de ativação;
- d) Limiar de ativação  $\{\theta\}$ : é um valor fixo de referência que será comparado pelo combinador linear com as entradas multiplicadas por suas respectivas ponderações, gerando um valor de disparo para saída do neurônio;
- e) Potencial de ativação  $\{u\}$ : é o valor gerado pelo combinador linear. Se a diferença calculada pelo combinador for positiva, então o neurônio produz um potencial excitatório para a saída, se  $u$  for menor que zero então o potencial será inibitório;
- f) Função de ativação  $\{g(\cdot)\}$ : limita o valor de saída do Neurônio a um intervalo desejado, normalmente definido entre -1 e 1 ou 0 e 1.
- g) Saída do neurônio  $\{y\}$ : valor final produzido pelo Neurônio em relação a um conjunto de entrada.

O modelo de um neurônio mostrado na Figura 6 foi proposto por McCulloch e Pitts (1943) que definiram que o potencial de ativação e a saída do neurônio podem ser calculadas pelas equações (2) e (3) respectivamente:

$$u = \sum_{i=1}^n w_i \cdot x_i - \theta \quad (2)$$

$$y = g(u) \quad (3)$$

Tendo em vista as equações acima pode-se dizer que o princípio de funcionamento de um Neurônio é baseado nas seguintes etapas, conforme Silva, Spatti e Flauzino (2010):

- Apresentação do conjunto de entradas ao neurônio;
- Multiplicação das entradas pelo seu respectivo peso sináptico;
- Obtenção do potencial de ativação  $u$  dado pela equação (2);
- Limitação do potencial de ativação por uma função de ativação;
- Definição de uma saída limitada pela função de ativação em relação ao potencial de ativação.

### 3.2.3 Função de Ativação

Existem diferentes tipos de funções de ativação que são divididas em duas classes, sendo elas, parcialmente deriváveis e totalmente deriváveis. Uma função é dita totalmente derivável, se somente se, para todo ponto em seu domínio existe uma derivada de primeira ordem (SILVA; SPATTI; FLAUZINO, 2010). Neste trabalho foi utilizado uma função totalmente derivável chamada tangente hiperbólica, dada pela equação (4), além desta, na equação (5) apresenta-se um outro exemplo de função de ativação totalmente derivável, chamada logística:

$$g(u) = \frac{1}{1 + e^{-\beta \cdot u}} \quad (4)$$


$$g(u) = \frac{1 - e^{-\beta \cdot u}}{1 + e^{-\beta \cdot u}} \quad (5)$$

onde  $\beta$  é uma constante que está associada ao nível de inclinação da curva e  $u$  é o potencial de ativação.

De acordo com as equações (4) e (5), pode-se dizer que a função tangente hiperbólica está definida no intervalo  $\{-1,1\}$  e a função logística é limitada pelos intervalos  $\{0,1\}$ . Neste caso, optou-se pela utilização da função dada na equação (4), pois treinamentos iniciais das redes realizados neste trabalho com as duas funções apresentadas, mostraram que a tangente hiperbólica é mais eficiente, pois obteve resultados mais satisfatórios no âmbito do trabalho.

### 3.2.4 Rede MLP

Conforme Silva, Spatti, Flauzino, (2010), existem muitas configurações de redes neurais artificiais, porém a topologia *Feed-Forward* de camadas múltiplas, *Multi-Layer Perceptron (MLP)* é amplamente utilizada em problemas relacionados a reconhecimento de padrões. Por isso, neste trabalho, optou-se por utilizar este tipo de rede, que tem como característica principal a presença de uma ou mais camadas intermediárias de neurônios. A Figura 7, ilustra a estrutura de uma Rede MLP com duas camadas intermediárias. A primeira camada é dita camada de entrada, alimentada pelos dados fornecidos pelo usuário de acordo com o problema que será tratado pela rede. As outras duas camadas subsequentes são camadas intermediárias de neurônios, normalmente possuem um número de neurônios diferente da camada de entrada.



**Figura 7: Estrutura de uma Rede MLP com duas camadas intermediárias.**  
**Fonte: Fiorin et al (2011).**

O número de neurônios das camadas intermediárias e a quantidade das mesmas não está associado a quantidade de amostras ou padrões de entrada, nem mesmo ao número de classes que os dados de entrada serão classificados, mas sim, com o nível de complexidade do problema que será avaliado e a qualidade dos dados fornecidos, ou seja, se os dados de entrada estão adequados e relacionados aos dados esperados pela rede a complexidade do problema



diminui, conseqüentemente o número de neurônios necessário nas camadas intermediárias e o número de camadas também diminui. Por último, tem-se a camada de neurônios de saída da rede, que está relacionada com os dados esperados do problema. Vale ressaltar, que o número de neurônios na camada de saída da rede sempre será igual a quantidade de valores esperados para o problema, porém, nem sempre o número de neurônios na camada de saída é o mesmo que o número de classes que serão classificadas pela rede.

Tendo em vista que uma rede é composta por um conjunto de camadas de neurônios interligados por conexões sinápticas artificiais, para compreender o princípio de funcionamento de uma rede MLP, deve-se inicialmente ter conhecimento do princípio de funcionamento de um neurônio separado, conforme está descrito na seção 3.2.2 deste trabalho. Dito isto, sabe-se que cada neurônio da rede possui uma saída  $y$ , portanto, as saídas dos neurônios da camada de entrada se propagam para a camada subsequente. Assim, as saídas dos neurônios da camada de entrada serão a entrada dos neurônios da primeira camada intermediária, e as saídas da primeira camada intermediária serão as entradas da segunda camada e desta maneira as saídas da última camada intermediária se propagam tornando-se as entradas dos neurônios da camada de saída.

Em redes MLP o sentido de propagação dos dados de saída dos neurônios é sempre na direção da camada de saída da rede (SILVA; PATTI; FLAUZINO, 2010).

O princípio de funcionamento da rede MLP descrito acima, pode ser compreendido como um sistema em malha aberta, ou seja, não existe um método iterativo para ajustar os pesos sinápticos dos neurônios de acordo com o erro obtido na saída da rede. Para tornar uma rede neural um sistema de malha fechada, existe o algoritmo de treinamento.

### 3.2.5 Algoritmo de treinamento

A função do algoritmo de treinamento é justamente tornar uma rede neural um sistema de malha fechada em sua fase de treinamento. Inicialmente para resolver um problema utilizando redes neurais o usuário deve obter três conjuntos de dados, sendo eles: dados de entrada, dados esperados de saída e dados de teste. Na fase de treinamento, deve-se fornecer para a rede um conjunto de dados de entrada e os dados esperados de saída, que devem estar relacionados com a aplicação.

Dentre os algoritmos de treinamento supervisionados existentes, neste trabalho optou-se por utilizar o *Levenberg-Marquardt* (LEVENBERG, 1944), que é uma variação do bem conhecido algoritmo *Backpropagation* (HECHT-NIELSEN, 1989). O princípio de

funcionamento do *Levenberg-Marquardt* é baseado no *Backpropagation* (SILVA; SPATTI; FLAUZINO, 2010).

Na primeira etapa do princípio de funcionamento do algoritmo o peso sináptico de cada neurônio é iniciado aleatoriamente e os dados são propagados gerando uma saída para a rede. Esta fase é conhecida como propagação para frente (*forward*). Nesta etapa os pesos permanecem inalterados. Uma vez obtido uma saída para rede, então ela será comparada com os dados esperados. Assim, no caso deste trabalho, um erro é calculado pela função MSE (*Mean Squared Error*), dado pela equação (6):

$$MSE = \frac{1}{n} * \sum_{i=1}^n (\theta_i - \theta'_i)^2 \quad (6)$$

onde  $n$  é o número de amostras,  $\theta_i$  é o valor esperado pela rede e  $\theta'_i$  é o valor obtido pela rede.

Se o erro calculado não for satisfatório, inicia-se a etapa seguinte do algoritmo conhecida como propagação para trás (*Backward*). Nesta etapa os pesos são alterados a partir da camada de saída até a camada de entrada de acordo com a necessidade de cada neurônio, a fim de diminuir o erro dos dados de saída em relação aos dados esperados (SILVA; SPATTI; FLAUZINO, 2010).

A principal diferença do *Levenberg-Marquardt* para o *Backpropagation* é o tempo de convergência. Por conta das mudanças algébricas presentes no método *Levenberg-Marquardt* em relação ao *Backpropagation* é comprovado que em Redes MLP a convergência do algoritmo *Levenberg-Marquardt* é de 10 à 100 vezes mais rápida, diminuindo assim o esforço computacional da etapa de treinamento (HAGAN; MENHAJ, 1994).

### 3.2.5.1 Método Levenberg-Marquardt

Nesta seção é apresentado um exemplo de implementação do algoritmo Levenberg-Marquardt para encontrar um ponto mínimo para uma determinada função  $F(x)$ , dado por (MAFFRA; GATTASS, 2008).

Assim como os métodos de Newton e Gauss-Newton, o método de Levenberg-Marquardt é iterativo. Sendo que, dado um ponto inicial  $x_0$ , o método tende a produzir uma série de vetores  $x_1, x_2, \dots, x_n$  que espera-se que vá convergir para  $x^*$ , um mínimo local para a função de entrada a ser ajustada.

O método de Newton é baseado no fato de que se  $x^*$  é um ponto crítico da função  $F$ , então  $F'(x^*) = 0$ . Expandindo-se  $F$  em uma série de Taylor tem-se a equação (7):

$$F(x + h) = F(x) + F'(x)h + O(\|h\|^2) \quad (7)$$

Para valores de  $\|h\|$  muito pequenos obtém-se a equação (8):

$$F'(x + h) = F'(x) + F''(x)h \quad (8)$$

Sabendo-se que  $F'(x^*) = 0$  e  $F'(x + h) = F'(x) + F''(x)h$ , pode-se encontrar o valor da direção de busca  $h_n$  no método de Newton, resolvendo-se o seguinte sistema da equação (9):

$$Hh_n = -F'(x) \quad (9)$$

$$\text{onde } H = F''(x) = H(x) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2}(x) & \frac{\partial^2 f}{\partial x_1 \partial x_2}(x) & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n}(x) \\ \frac{\partial^2 f}{\partial x_2 \partial x_1}(x) & \frac{\partial^2 f}{\partial x_2^2}(x) & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_n}(x) \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1}(x) & \frac{\partial^2 f}{\partial x_n \partial x_2}(x) & \cdots & \frac{\partial^2 f}{\partial x_n^2}(x) \end{bmatrix},$$

cujo  $H$  é conhecida como a matriz Hessiana.

Calculando a direção do passo  $h_n$  a próxima iteração do método de Newton é dada por:

$$x \leftarrow x + h_n$$

No entanto, a avaliação da matriz Hessiana pode ser extremamente complexa para alguns problemas. Para contornar esse problema, propõe-se métodos que utilizam aproximações para a matriz Hessiana, conhecidos como *Quasi-Newton*, dentre os quais encontra-se o método de Gauss-Newton e Levenberg-Marquardt.

O método de Gauss-Newton é baseado na aproximação para os valores das componentes de  $f$  em uma vizinhança de  $x$ . Deste modo, a partir da expansão em série de Taylor encontra-se a equação (10):

$$f(x + h) \approx l(h) \equiv f(x) + J(x)h \quad (10)$$

onde  $J \in \mathbf{R}^{m \times n}$  é a matriz Jacobiana, isto é, a matriz que contém as derivadas parciais de primeira ordem de cada componente da função vetorial  $f$ .

Substituindo-se (10) em (11) obtém-se a equação (12):

$$F(x) = \frac{1}{2} f(x)^T f(x) \quad (11)$$

$$F(x + h) \approx L(h) \equiv \frac{1}{2} l(h)^T l(h) \quad (12)$$

onde  $f = f(x)$  e  $J = J(x)$ .

Nota-se que o gradiente e a matriz Hessiana de  $L$  são dados respectivamente pela equação (13):

$$L'(h) = J^T f + J^T J h \text{ e } L''(h) = J^T J. \quad (13)$$

Portanto, a direção do passo calculada por meio do método de Gauss-Newton é dada pela equação (14):

$$(J^T J) h_{gn} = -J^T f. \quad (14)$$

Encontrando o valor de  $h_{gn}$  tem-se que a próxima iteração do método de Gauss-Newton é dada por:

$$x \leftarrow x + h_{gn}$$

Apesar do método de Gauss-Newton resolver de maneira mais fácil a matriz Hessiana, pode-se perceber que, da mesma forma que acontecia no método de Newton, não é garantido que exista a inversa dessa matriz, necessária para o cálculo de  $h_{gn}$ .

O método de Levenberg-Marquardt, para contornar essa situação, propõe somar uma parcela  $\mu I$  à matriz Hessiana, aproximada pelo método de Gauss-Newton, onde  $\mu$  é um escalar denominado parâmetro de *damping* e  $I$  é a matriz identidade.

Com essa modificação, a direção do passo do método de Levenberg-Marquardt pode ser calculada pela equação (15):

$$(J^T J + \mu I)h_{lm} = -g \quad (15)$$

onde  $g = J^T f$  e  $\mu \geq 0$ .

O parâmetro de *damping*  $\mu$  promove diferentes comportamentos do método, sendo que:

1 - Para todo  $\mu > 0$  a matriz de coeficientes  $(J^T J + \mu I)$  é positiva definida, o que implica que  $h_{lm}$  é uma direção de descida.

2 - Para valores grandes de  $\mu$  tem-se:

$$h_{lm} = -\frac{1}{\mu}g = -\frac{1}{\mu}F'(x), \text{ que é um pequeno passo na direção máxima de descida.}$$

3 - Se  $\mu$  é muito pequeno temos que  $h_{lm} \approx h_{gn}$ , o que é bom nos estágios finais da iteração quando  $x$  está próximo de  $x^*$ , pois quando isso ocorre, o método de Levenberg-Marquardt consegue convergência quadrática.

Nota-se que o parâmetro  $\mu$  influencia tanto na direção quanto no tamanho do passo, permitindo assim que o método de Levenberg-Marquardt não necessite de uma busca linear para descobrir o tamanho ótimo do passo a ser dado em cada iteração aumentando a velocidade de processamento.

O valor inicial de  $\mu$  pode ser relacionado ao tamanho dos elementos da matriz Hessiana aproximada, que é calculada no método de Levenberg-Marquardt, ou seja,  $\mu$  depende do tamanho dos elementos de  $A_0 = J(x_0)^T J(x_0)$ , deste modo, tem-se a equação (16).

$$\mu_0 = \tau \max_i \{a_{ii}^{(0)}\} \quad (16)$$

onde  $\tau$  é escolhido pelo usuário.

Para determinados problemas em que o valor de  $x_0$  é uma boa aproximação de  $x^*$  pode-se adotar  $\tau = 10^{-6}$ . Caso contrário recomenda-se  $\tau = 1$ .

O valor de  $\mu$  pode ser modificado durante as iterações e isso é feito em função de um outro parâmetro  $\rho$ , conhecido como *gain ratio*, dado pela equação (17):

$$\rho = \frac{F(x) - F(x + h_{lm})}{L(0) - L(h_{lm})} \quad (17)$$

onde  $L(0) - L(h_{lm})$  é o ganho obtido através do modelo linear, assim, tem-se a equação (18):

$$L(0) - L(h_{lm}) = 1/2 h_{lm}^T (\mu h_{lm} - g) \quad (18)$$

Pode-se dizer que como  $h_{lm}^T h_{lm}$  e  $-h_{lm}^T g$  são positivos, então  $L(0) - L(h_{lm})$  também é positivo.

Se o valor de  $\rho$  for grande, isso indica que  $L(h_{lm})$  é uma boa aproximação para  $F(x + h_{lm})$  e pode-se diminuir o valor de  $\mu$  de modo que o próximo passo do Levenberg-Marquardt esteja próximo do passo de Gauss-Newton. Se  $\rho$  for pequeno isso significa que  $L(h_{lm})$  é uma aproximação ruim e precisa-se aumentar  $\mu$  para buscar a direção máxima de descida e reduzir o tamanho do passo.

O valor de  $\mu$  pode ser alterado de acordo com a seguinte regra:

se  $\rho > 0$ ,  $v = 2$ . Caso contrário  $\mu = \mu v$  e  $v = 2v$ , onde  $v$  é inicializado com o valor igual a 2.

Os critérios de convergência ou critérios de parada mais usuais são:

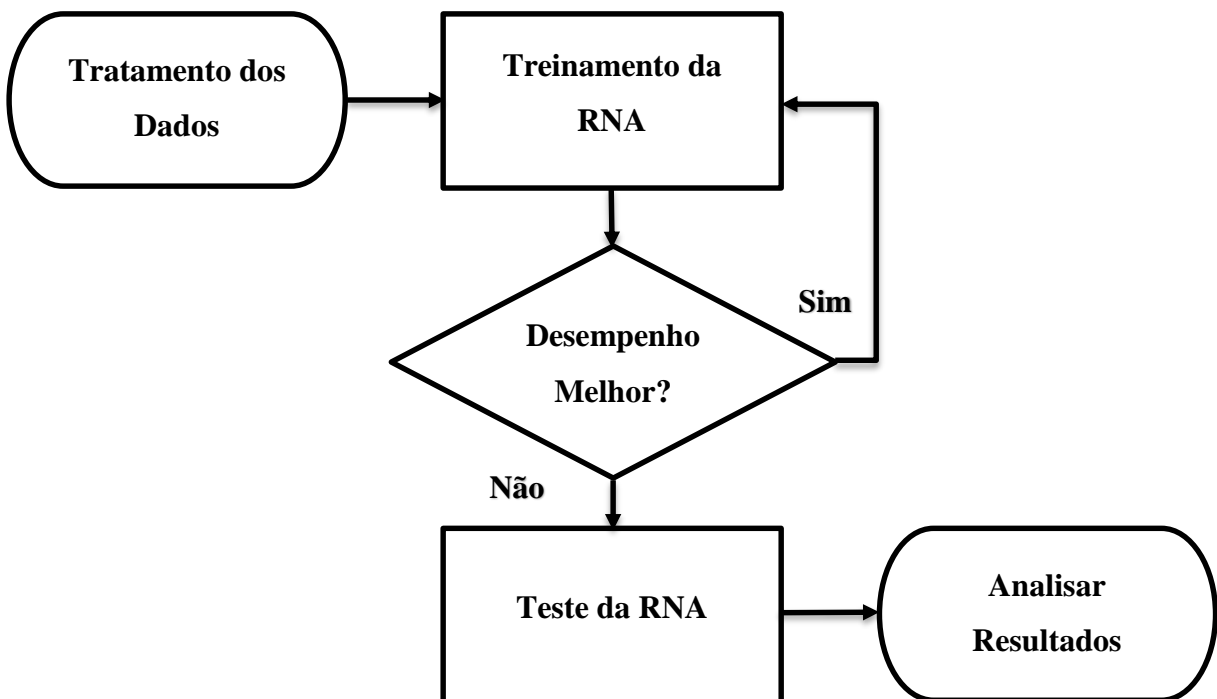
1. Norma do gradiente menor do que um determinado valor pré-determinado, isto é,  $g_\infty \leq \varepsilon_1$ , onde  $\varepsilon_1$  é um número positivo pequeno escolhido pelo usuário de modo a refletir que  $F'(x^*) = g(x^*) = 0$ .

2. Variação no valor de  $x$  muito pequena, isto é,  $\|x_{new} - x\| \leq \varepsilon_2 (\|x\| + \varepsilon_2)$ .

3. Número máximo de iterações determinado pelo usuário. Isto é importante para evitar que o algoritmo entre em loop infinito:  $k \geq k_{m\acute{a}x}$ , onde  $k$  é o número de iterações.

## 4 METODOLOGIA

O desenvolvimento deste trabalho pode ser subdividido em: aquisição e tratamento dos sinais de tensão eficaz, relativos a medições normais e anormais que serão apresentados para a RNA; definição do tipo e arquitetura da RNA a ser utilizada; treinamento da RNA; validação e teste da RNA e, por fim, análise dos resultados obtidos. Estas etapas serão descritas a seguir nas subdivisões deste capítulo e seguem o fluxograma da Figura 8.



**Figura 8:** Fluxograma do Processo que será utilizado para gerar os resultados.

Fonte: Próprio Autor

### 4.1 TRATAMENTO DOS DADOS

Neste trabalho utilizou-se medidas reais de tensão eficaz das três fases em relação ao neutro, fornecidas pela CPFL. Tais dados foram coletados em medições realizadas em unidades consumidoras dentro da área de concessão da CPFL utilizando os protocolos exigidos pelo módulo 8 do PRODIST. Os sinais trifásicos de tensão integralizados de 10 em 10 minutos foram normalizados dentro da faixa de 0 a 1, para facilitar o processamento da RNA. Como neste trabalho dispõe-se de sinais trifásicos, cada fase representa uma entrada da RNA, bem como, cada amostra do sinal trifásico representa um padrão diferente de entrada para a RNA.

Como mencionado na Seção 3.2.4, neste trabalho optou-se em utilizar redes MLP com treinamento supervisionado. Neste tipo de treinamento é necessário apresentar os padrões de entrada e seu respectivo padrão de saída que caracteriza a causa do problema de nível de tensão. Com base nos dados disponíveis, são estabelecidos oito tipos de causas de problemas diferentes definidos a seguir:

- 1 - Normal ou Adequado;
- 2 - Anormal – Sobrecarga do Sistema;
- 3 - Anormal – Transformador Avariado;
- 4 - Anormal – Ajuste Regulador de Tensão;
- 5 - Anormal – Falha em Conexões;
- 6 - Anormal – Ramal de Entrada Rompido;
- 7 - Anormal – TAP Transformador – Sub tensão;
- 8 - Anormal – TAP Transformador – Sobre tensão.

Uma vez definido os tipos relativos a causa ou não dos problemas de nível de tensão, estabeleceu-se os padrões de saída com oito características de problemas que causam variação de tensão de longa duração. Para que a tensão seja considerada adequada, utilizou-se faixas de tensão pré-definidas, sendo a tensão nominal fase-neutro igual a 127 Volts. Valores fora da faixa estabelecida são considerados anormais e classificados de acordo com a causa do problema previamente conhecido.

Como está previsto nos objetivos específicos deste trabalho, testou-se diferentes metodologias no tratamento dos dados de entrada e esperados pela rede, a fim de encontrar a forma mais eficiente para resolver o problema proposto. Todos os métodos de tratamento dos dados serão descritos nas subseções seguintes e os resultados apresentados ao final do trabalho.

#### 4.1.1 Método 1

Na primeira metodologia proposta, utilizou-se os dados de entrada normalizados e classificados como normal se estiverem dentro da faixa de 116 a 133V. Deste modo a saída da RNA foi definida da seguinte forma, cada amostra de tensão trifásica de entrada representa um padrão de saída.

Assim, a rede avaliará 8 padrões diferentes de saída. Se a amostra vista pela rede estiver em condições normais, espera-se que a resposta seja um vetor coluna do tipo [1; 1; 1; 1; 1; 1; 1; 1], onde o primeiro termo do vetor representa a condição normal (1) ou anormal (-1) e os outros termos representam as sete condições anormais delineadas anteriormente. Por



exemplo, para um padrão normal de tensão tem-se um padrão de saída do tipo [1; 1; 1; 1; 1; 1; 1; 1], para um padrão de entrada anormal onde a causa do problema seja sobrecarga do setor, tem-se um padrão de saída do tipo [-1; -1; 1; 1; 1; 1; 1; 1] e assim sucessivamente para cada tipo de causa do problema. Assim, um arquivo foi montado unindo todos os dados coletados e relacionando cada amostra com seu respectivo padrão de saída. Do conjunto total de dados fornecidos pela CPFL sendo 15175 amostras, considerando os limites de 116 a 133V cerca de 80% das amostras estão dentro dos limites impostos, ou seja, a maioria das medidas estão dentro da faixa aceitável, por isso, optou-se por reduzir a quantidade de amostras normais, para que estivessem próximos da quantidade de amostras anormais. Com isso o arquivo de entrada da rede para o treinamento passou a ter 5706 amostras no total. Deste conjunto de dados, cerca de 90% das amostras utilizou-se para validação e treinamento e 10% para teste.

No Quadro 1 tem-se as definições das causas e seus respectivos padrões de saída esperado da rede neural para o método 1.

Nº	Causa do Problema	Padrão de Saída da RNA
1	Normal ou Adequado;	[ 1; 1; 1; 1; 1; 1; 1; 1 ]
2	Sobrecarga;	[-1; -1; 1; 1; 1; 1; 1; 1]
3	Transformador Avariado;	[-1; 1; -1; 1; 1; 1; 1; 1]
4	Ajuste Regulador de Tensão;	[-1; 1; 1; -1; 1; 1; 1; 1]
5	Falha em conexões;	[-1; 1; 1; 1; -1; 1; 1; 1]
6	Ramal de Entrada;	[-1; 1; 1; 1; 1; -1; 1; 1]
7	Tap transformador – sobretensão	[-1; 1; 1; 1; 1; 1; -1; 1]
8	Tap transformador – subtensão	[-1; 1; 1; 1; 1; 1; 1; -1]

**Quadro 1: Padrão de saída da rede neural para cada problema de acordo com o método 1.**

#### 4.1.2 Método 2

Na segunda metodologia proposta, assim como no primeiro método, os dados de entrada foram normalizados, porém, neste caso eles foram classificados como normal se estiverem dentro da faixa de 122 a 132V. Isto porque, analisou-se que a diferença de 5V da tensão nominal que caracteriza uma escala de TAP do Trafo que possa estar sobre dimensionada ou subdimensionada. Neste caso, não houve necessidade de expurgar nenhum dado do arquivo original fornecido pela CPFL, pois, alterando os limites o número de medidas consideradas normais passou a ser metade do total de amostras. Deste modo o arquivo de entrada da rede

para treinamento ficou com 13596 amostras e o arquivo de teste com 1467 amostras, aproximadamente 10% do total.

Além disso, outro aspecto que foi alterado com relação ao primeiro método é a representação do padrão de saída. Assim como, no primeiro método, cada amostra de entrada representa um padrão de saída, ou seja, a rede avaliou 8 padrões diferentes de saída. Porém, a saída esperada pela rede neste caso, foi definida a partir da regra *one of c-classes* de Duda et al. (2001), essa regra consiste em associar o número de padrões que será classificado pela rede à um conjunto de neurônios da camada neural de saída da rede, onde cada padrão será classificado por uma saída binária contendo apenas um neurônio ativo e todos os demais na condição zero. Desta forma, se a amostra vista pela rede estiver em condições normais, espera-se que a resposta seja um vetor coluna do tipo [1; 0; 0; 0; 0; 0; 0; 0], onde o primeiro termo do vetor representa a condição normal (1) e os outros termos representam as sete condições anormais delineada anteriormente. Por exemplo, para um padrão normal de tensão tem-se o padrão de saída visto acima, já para um padrão de entrada anormal onde a causa do problema seja sobrecarga do setor, tem-se um padrão de saída [0; 1; 0; 0; 0; 0; 0; 0] e assim sucessivamente para cada tipo de causa do problema. Desta forma, novamente um arquivo foi montado unindo todos os dados coletados e relacionando cada amostra com seu respectivo padrão de saída.

No Quadro 2 tem-se as definições das causas e seus respectivos padrões de saída esperado da rede neural para o método 2.

<b>Nº</b>	<b>Causa do Problema</b>	<b>Padrão de Saída da RNA</b>
1	Normal ou Adequado;	[1; 0; 0; 0; 0; 0; 0; 0]
2	Sobrecarga;	[0; 1; 0; 0; 0; 0; 0; 0]
3	Transformador Avariado;	[0; 0; 1; 0; 0; 0; 0; 0]
4	Ajuste Regulador de Tensão;	[0; 0; 0; 1; 0; 0; 0; 0]
5	Falha em conexões;	[0; 0; 0; 0; 1; 0; 0; 0]
6	Ramal de Entrada;	[0; 0; 0; 0; 0; 1; 0; 0]
7	Tap transformador – sobretensão	[0; 0; 0; 0; 0; 0; 1; 0]
8	Tap transformador – subtensão	[0; 0; 0; 0; 0; 0; 0; 1]

**Quadro 2: Padrão de saída da rede neural para cada problema de acordo com o método 2.**

#### 4.1.3 Método 3


Na terceira metodologia proposta, assim como, no primeiro método, os dados de entrada foram normalizados. Porém, percebeu-se que ao alterar os limites de classificação, a rede se comportava melhor na validação do treinamento, então, utilizando as mesmas técnicas do método 2 testou-se dois novos casos com limites diferentes. No método 3 os dados foram classificados como normal se estiverem dentro da faixa de 120 a 133V. Assim, novamente um arquivo foi montado unindo todos os dados coletados e relacionando cada amostra com seu respectivo padrão de saída, conforme o Quadro 2. Para o treinamento utilizou-se um arquivo de entrada com 13624 amostras e para o teste um total de 1480 amostras.

#### 4.1.4 Método 4

Na quarta metodologia proposta, os dados de entrada foram normalizados. E como destacado na Seção 4.1.3, uma nova faixa de classificação dos dados foi testada. Neste caso os dados foram classificados como normal se estiverem dentro da faixa de 122 a 133V.

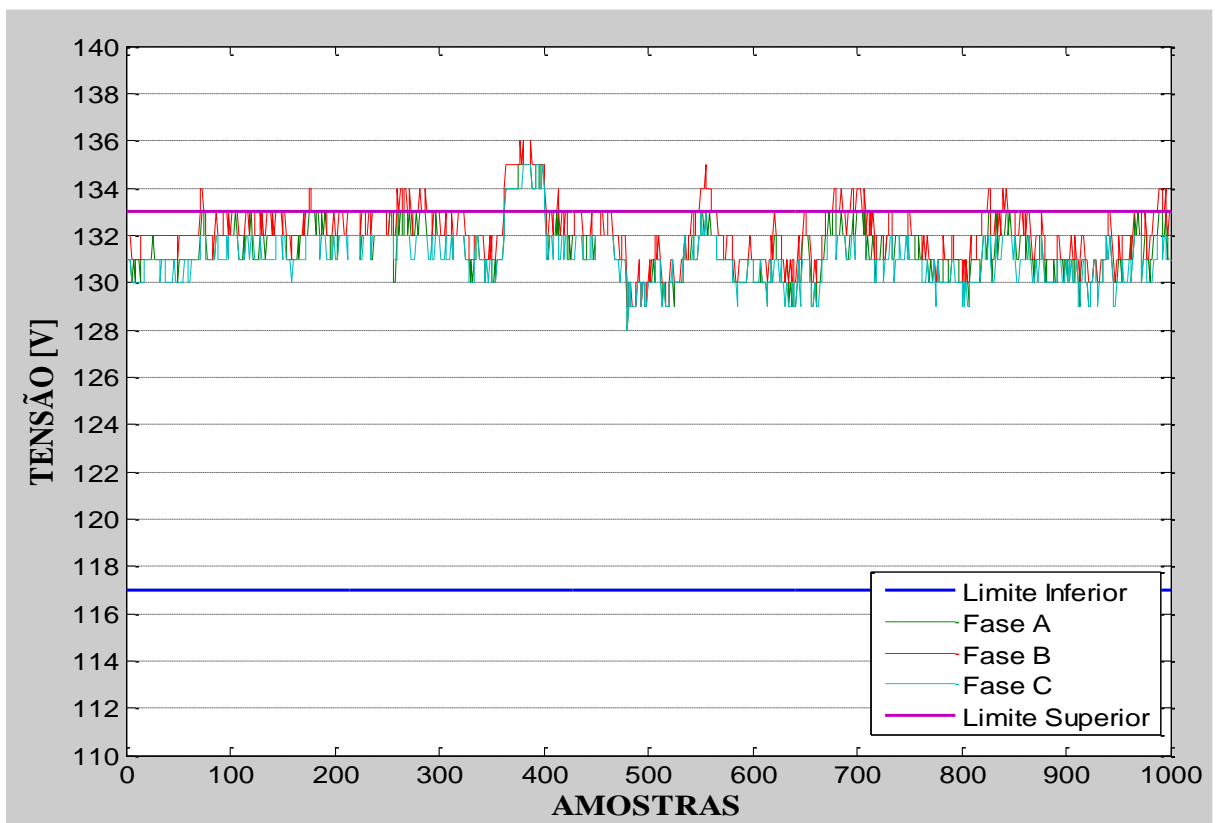
#### 4.1.5 Método 5

Analisando as curvas características de cada problema, percebeu-se que o problema de TAP do transformador sobre dimensionado tem características de curva parecidas com a do problema de ajuste do regulador de tensão, como mostrados nas Figuras 9 e 10, isso porque nas amostras do banco de dados fornecido pela CPFL, só constam medidas em locais com problema de ajuste de RT sobre dimensionado, deste modo, a fim de diminuir a complexidade da rede, ou seja, diminuir a quantidade de casos que a rede deve classificar simultaneamente, decidiu-se unir o conjunto de dados de TAP sobre dimensionado com ajuste RT. Caso houvesse amostras de problema de ajuste RT subdimensionado, então estes seriam associados à TAP subdimensionado. Deste modo, os mesmos procedimentos utilizados no método 4 aplicou-se no método 5.



**Figura 9: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um setor com problema de TAP de transformador sobre dimensionado.**

Fonte: Próprio Autor



**Figura 10: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um setor com problema de RT sobre dimensionado.**

Fonte: Próprio Autor.

Desta forma, se a amostra vista pela rede estiver em condições normais, espera-se que a resposta seja um vetor coluna do tipo [1; 0; 0; 0; 0; 0; 0], ou seja, a rede passa a ter 7 neurônios na camada de saída e não mais oito, como nos casos anteriores. Assim como nos outros métodos apresentados o primeiro termo do vetor representa a condição normal (1) e os outros termos representam as seis condições anormais delineada anteriormente, porém, com a diferença de que o caso de ajuste RT e TAP sobre dimensionado formam um único padrão de saída. Por exemplo, para um padrão normal de tensão tem-se o padrão de saída visto acima, já para um padrão de entrada anormal onde a causa do problema seja ajuste RT, tem-se um padrão de saída [0; 0; 0; 0; 0; 0; 1; 0], que indica que o problema pode ser ajuste do RT ou TAP sobre dimensionado. E assim sucessivamente para cada tipo de causa do problema.

No Quadro 3 tem-se as definições das causas e seus respectivos padrões de saída esperado da rede neural para o método 5.

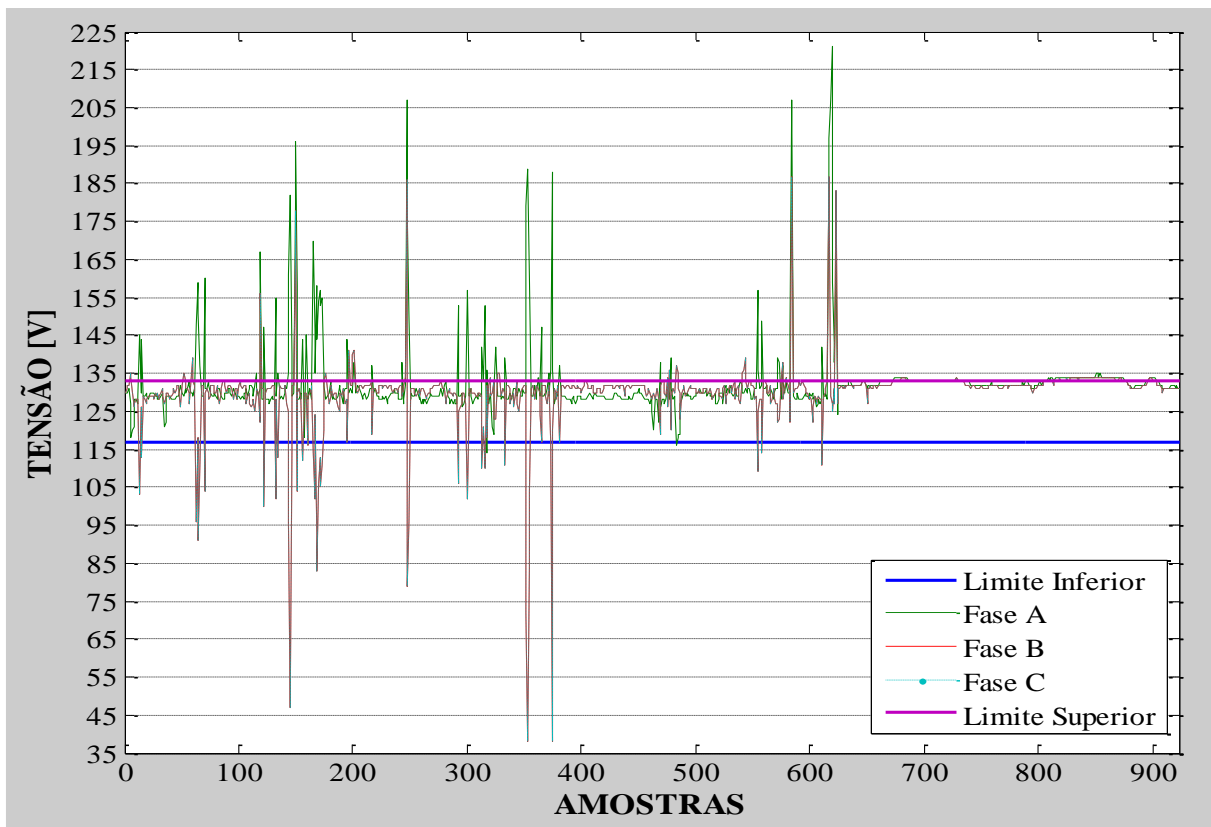
<b>Nº</b>	<b>Causa do Problema</b>	<b>Padrão de Saída da RNA</b>
1	Normal ou Adequado;	[1; 0; 0; 0; 0; 0; 0]
2	Sobrecarga;	[0; 1; 0; 0; 0; 0; 0]
3	Transformador Avariado;	[0; 0; 1; 0; 0; 0; 0]
4	Falha em conexões;	[0; 0; 0; 1; 0; 0; 0]
5	Ramal de Entrada;	[0; 0; 0; 0; 1; 0; 0]
6	TAP transformador ou RT – sobretensão	[0; 0; 0; 0; 0; 1; 0]
7	TAP transformador ou RT – subtensão	[0; 0; 0; 0; 0; 0; 1]

**Quadro 3: Padrão de saída da rede neural para cada problema de acordo com o método 5.**

#### 4.1.6 Método 6

Uma vez treinado as redes neurais, utilizando todos os métodos de tratamento de dados descritos anteriormente, analisou-se os resultados obtidos e percebeu-se que em todos os métodos propostos a rede obteve maior dificuldade em classificar o padrão de problema com Trafo avariado. Desta maneira observou-se a curva característica do problema, mostrado na Figura 11, e notou-se que a mesma se sobrepõe a todos os outros problemas avaliados pela rede. Ou seja, neste caso quando se realiza o treinamento da rede a tendência é que a mesma confunda os padrões de Trafo avariado com outros problemas, gerando um erro considerável. Dado o fato

observado, um novo método foi proposto. Retirou-se as amostras de Trafo avariado do banco de dados, assim, o número de amostras de entrada da rede neural no treinamento ficou com 12701. Desta maneira, assim como no método 5, se a amostra vista pela rede estiver em condições normais, espera-se que a resposta seja um vetor coluna do tipo  $[1; 0; 0; 0; 0; 0; 0]$ , ou seja, a rede continua tendo 7 neurônios na camada de saída, isso porque, eliminou-se o padrão de Trafo avariado, porém, ajuste RT e TAP sobre dimensionado passou a ser dois padrões distintos, ou seja, não estão mais conexos como no método 5. Assim, para um padrão de entrada anormal onde a causa do problema seja ajuste RT, tem-se um padrão de saída  $[0; 0; 1; 0; 0; 0; 0]$ , que indica que o problema é ajuste do RT exclusivamente, no caso de um problema de TAP sobre dimensionado, espera-se que a resposta seja do tipo  $[0; 0; 0; 0; 0; 1; 0]$ .



**Figura 11: Padrão de Tensão Nominal medido em intervalos de 10 minutos por amostra em um setor com problema de Trafo Avariado.**

Fonte: Próprio Autor.

No Quadro 4 tem-se as definições das causas e seus respectivos padrões de saída esperado da rede neural para o método 6.

Nº	Causa do Problema	Padrão de Saída da RNA
1	Normal ou Adequado;	[1; 0; 0; 0; 0; 0; 0]
2	Sobrecarga;	[0; 1; 0; 0; 0; 0; 0]
3	Ajuste Regulador de Tensão;	[0; 0; 1; 0; 0; 0; 0]
4	Falha em conexões;	[0; 0; 0; 1; 0; 0; 0]
5	Ramal de Entrada;	[0; 0; 0; 0; 1; 0; 0]
6	TAP transformador – sobretensão	[0; 0; 0; 0; 0; 1; 0]
7	TAP transformador – subtensão	[0; 0; 0; 0; 0; 0; 1]

**Quadro 4: Padrão de saída da rede neural para cada problema de acordo com o método 6.**

#### 4.1.7 Método 7

Uma preocupação deste trabalho é que os testes realizados viabilizem uma aplicação prática, para isso é de extrema importância que os resultados sejam validados com uma taxa de erro aceitável e a rede proposta seja de complexidade razoável, possibilitando uma implementação em hardware.

Dado o exposto, o método 7 foi proposto justamente para reduzir a complexidade da rede, utilizando não somente uma rede muito grande, capaz de classificar 7 padrões simultaneamente, mas sim 7 redes pequenas que são especialistas em cada padrão. Deste modo, o mesmo conjunto de amostras é apresentado para cada rede na fase de treinamento, totalizando 12701 amostras, porém, os dados esperados são diferentes para cada caso. Um único vetor coluna foi montado como dados esperados para o treinamento, composto por valores binários 0 e 1. Para cada rede, somente onde o limite de 122 a 133 é transgredido e o conjunto de amostras representa a especialidade da rede que o valor esperado é 1, caso contrário a rede indica uma situação normal do sistema ou que o problema não é especialidade da rede e então o valor esperado é 0. Por exemplo, do total de 12701 amostras presente no sinal completo de entrada, os 2256 primeiros dados são relativos ao problema de setor sobrecarregado, então no caso da rede especialista em setor sobrecarregado, se alguma amostra entre as 2256 primeiras transgredir os limites espera-se que a saída seja um único bit ativo (1), para todo o resto das amostras a saída esperada é um bit 0. Com isso a complexidade das redes diminui, pois, a camada de saída de cada rede passa a ter apenas 1 neurônio.

## 4.2 TREINAMENTO DA RNA

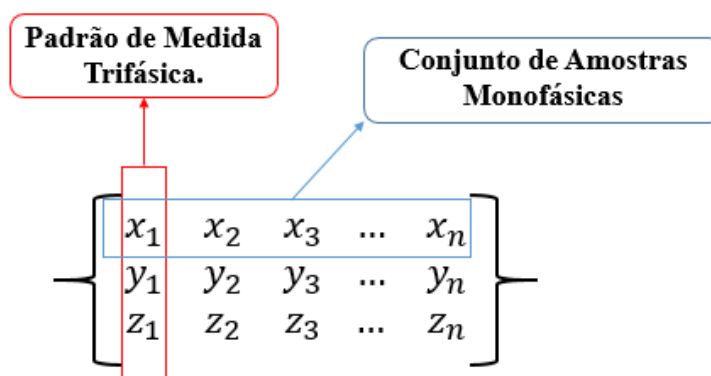
Estabelecido o conjunto de dados, realizou-se de 5 a 10 treinamentos para cada topologia de rede, variando um a um o número de neurônios das camadas intermediárias da rede, inicialmente começando com apenas 1 neurônio em uma única camada intermediária, com o objetivo de detectar a melhor topologia da rede. Tal procedimento foi utilizado para detectar-se uma topologia que resultasse boa performance e baixa complexidade, visto que redes muito complexas podem inviabilizar uma aplicação prática. Sabe-se que uma rede com apenas uma camada de neurônios intermediária é capaz de resolver problemas extremamente complexos, portanto, para esse trabalho não foi necessário utilizar mais de uma camada intermediária de neurônios em nenhum caso.

Ressalta-se, que não se deve fazer apenas um treinamento com a mesma rede, pois, como foi dito anteriormente nesta seção, em cada treinamento os pesos sinápticos dos neurônios são iniciados aleatoriamente interferindo na performance final do treinamento. Visto isto, serão realizados 10 treinamentos com a mesma rede, afim de obter-se a melhor performance entre eles.

A topologia de RNA escolhida para este trabalho é a *Multi-Layer Perceptron* com o algoritmo de treinamento *Levenberg-Marquardt* e para avaliar o desempenho utilizou-se o *Mean Squared Error* (MSE) em todas as metodologias de tratamento dos dados proposta. É importante notar que para a primeira metodologia as saídas esperadas estão limitadas em -1 a 1, tornando inviável a utilização de uma função de ativação que esteja entre 0 e 1 como a logarítmica. Portanto, neste caso, a função de ativação utilizada deve ser a tangente hiperbólica. Porém mesmo nos casos onde a saída foi definida como 0 e 1 a função de ativação utilizada foi a tangente hiperbólica, isso porque, ao longo do trabalho percebeu-se que a mesma se comportava melhor em relação a função logarítmica, ou seja, os erros obtidos entre a saída da rede e os dados esperados é menor.

Uma vez que a rede esteja configurada para o treinamento inserem-se os dados de entrada e os dados esperados, completando assim a estrutura da rede. Neste caso, conforme os dados foram tratados, a entrada da rede possuirá 3 neurônios, sendo que, cada neurônio corresponde a um conjunto de amostras de tensão monofásica como mostrado na Figura 12. Então, cada medida trifásica representa um padrão que será avaliado pela rede.





**Figura 12: Modelo matemático de entrada da rede.**  
**Fonte: Próprio Autor**

Deste modo, como foi dito na seção anterior, em cada tipo de metodologia de tratamento de dados, a camada neural de saída, com dados esperados, possuirá um número específico de neurônios. Cada neurônio possui um conjunto de valores entre -1 e 1 ou 0 e 1 que corresponde ao número de padrões apresentados na entrada da rede. Assim, cada padrão de medida trifásica da camada de entrada corresponde a uma saída, que está relacionada com um problema.

Após serem realizados cerca de 10 treinamentos com a rede devidamente configurada, salvam-se todos os resultados obtidos, bem como a rede treinada que teve a melhor performance entre os 10 treinamentos. Feito isto, aumenta-se um neurônio na camada intermediária, mantendo todas as outras configurações da rede e realiza-se novos treinamentos, deste modo a nova performance obtida será comparada com a performance da rede anterior. Se o MSE entre os dados esperados e os dados de saída da rede anterior for menor, ou igual que da rede com maior complexidade, então, utiliza-se a rede menos complexa para realizar testes e se encerra a fase de treinamentos, senão, continua-se o processo até que a condição seja válida.

### 4.3 TESTE DA RNA

Uma vez definido todos os parâmetros e características da RNA, sua melhor topologia e treinando a mesma, obtêm-se os pesos sinápticos de cada neurônio, com valores ponderados, a fim de obter a saída mais próxima possível da esperada. Feito isto, inicia-se a fase de testes, onde novos padrões de entrada serão mostrados à RNA final, para validação dos resultados. Ressalta-se que os dados de teste não foram utilizados na fase de treinamento.

Vale ressaltar, que nesta etapa apresentou-se para rede apenas dados de entrada e espera-se que a rede já treinada, seja capaz de identificar quais problemas estão relacionados com a entrada que lhe foi apresentada. Na fase de teste, os dados esperados não são mostrados para rede, porém, eles estão pré-definidos de acordo com cada método proposto. Deste modo, os dados de saída foram comparados com os dados esperados no teste, para levantamento da estatística de erros.

A implementação da RNA, bem como, treinamentos e testes foram realizados utilizando a interface gráfica *nntool* do *MatLab® 2013a* e a validação dos resultados obtidos foi realizada a partir de um algoritmo desenvolvido para comparar os dados de saída dos testes com os dados esperados que são pré-definidos.

## 5 RESULTADOS E DISCUSSÃO

### 5.1 ANÁLISE DOS RESULTADOS OBTIDOS A PARTIR DO MÉTODO 1

Na Tabela 1 são descritos os melhores resultados obtidos para 10 topologias diferentes de RNA, as quais foram treinadas 10 vezes cada uma, utilizando o método 1 para tratamento dos dados, descrito na Seção 4.1.1. Pela análise dos resultados comprova-se que a topologia [3 9 8] obteve o maior número de acertos na validação, por volta de 93,7% de acertos. A época para convergência caracteriza o número de iterações que algoritmo de treinamento teve para convergir.

**TABELA 1 - RESULTADOS DOS TREINAMENTOS PARA DIFERENTES TOPOLOGIAS DE REDES NEURAIS UTILIZANDO O MÉTODO 1 DE TRATAMENTO DOS DADOS**

<b>Configuração da RNA</b>	<b>Épocas para Convergência</b>	<b>Erro (MSE)</b>	<b>Validação (%)</b>
[3 1 8]	69	0,2531	66,7
[3 2 8]	83	0,0925	88,4
[3 3 8]	96	0,0803	90,0
[3 4 8]	272	0,0741	91,3
[3 5 8]	484	0,0700	91,5
[3 6 8]	296	0,0551	93,6
[3 7 8]	453	0,0551	93,5
[3 8 8]	104	0,0523	93,4
[3 9 8]	213	0,0530	93,7
[3 10 8]	251	0,0560	93,4

Durante a fase de teste foram apresentados a RNA que obteve a melhor performance no treinamento 618 novos padrões, contendo 263 amostras normais e 355 amostras anormais com todos os tipos de causas estabelecidas para este trabalho. Nesta situação, a RNA apresentou uma média de 60,2% de acerto dos casos apresentados. Os conjuntos de testes foram apresentados todos separadamente e o nível de acerto individual para cada caso pode ser visto na Tabela 2.

Com base nos resultados obtidos utilizando o método 1, percebe-se que para padrões como falha de conexão, substituição do ramal de entrada e TAP de transformador mau dimensionado a rede teve uma porcentagem aceitável de acertos, conforme Tabela 2, porém, em casos como ajuste RT, setor sobrecarregado e Trafo avariado o percentual de acerto da rede foi baixo, isso deve-se a alguns fatores, como número de amostras apresentados no treinamento e testes reduzido, ou seja, quanto maior a quantidade de amostras apresentadas para a rede no

treinamento, maior é a capacidade de reconhecimento de padrões que a rede terá na fase de teste. Outro fator importante que pode influenciar na eficiência da rede é a maneira que os dados de saída são apresentados, no método 1, os dados de saída são classificados como -1 e 1, nos métodos seguintes, percebeu-se que quando a rede converge para uma saída contendo valores sendo 0 e 1 a eficiência dos resultados é maior. O que pode ter causado um erro excessivo nos resultados, também pode ter sido por conta dos limites que se definiram como normais e anormais, a variação destes limites, como poderá ser observado nos métodos subsequentes, influencia positivamente nos resultados. Outro problema encontrado inicialmente neste trabalho foi a sobreposição de padrões e a complexidade da rede, porém isto será explicado com detalhes em seções posteriores.

**TABELA 2 – RESULTADOS DOS TESTES PARA DIFERENTES PADRÕES DE PROBLEMAS DE ACORDO COM O MÉTODO 1**

<b>Causa do Problema</b>	<b>Nº de Amostras de Teste</b>	<b>Validação (%)</b>
Ajuste RT	50	40,0
Falha de Conexão	50	94,0
Setor Sobrecarregado	10	20,0
Substituição de Ramal	40	100,0
TAP Sobre dimensionado	175	83,4
TAP Subdimensionado	224	79,9
Trafo Avariado	69	4,3

## 5.2 ANÁLISE DOS RESULTADOS OBTIDOS A PARTIR DO MÉTODO 2

Na Tabela 3 são descritos os melhores resultados obtidos para 10 topologias diferentes de RNAs, as quais foram treinadas 10 vezes cada uma, utilizando o método 2 de tratamento dos dados, descrito na Seção 4.1.2. Pela análise dos resultados comprova-se que a topologia [3 9 8] obteve o maior número de acertos na validação, por volta de 95,0% de acertos.

Durante a fase de teste foi apresentado a RNA o novo conjunto de amostras, constituído por 10,8% das amostras do conjunto total. Para cada teste a rede identifica se as amostras são normais ou anormais, no caso de amostras anormais a rede identifica qual a causa do problema. Os resultados obtidos na fase de testes para o método 2, são apresentados na Tabela 4.

**TABELA 3 - RESULTADOS DOS TREINAMENTOS PARA DIFERENTES TOPOLOGIAS DE REDES NEURAIS UTILIZANDO O MÉTODO 2 DE TRATAMENTO DOS DADOS**

<b>Configuração da RNA</b>	<b>Épocas para Convergência</b>	<b>Erro (MSE)</b>	<b>Validação (%)</b>
[3 1 8]	270	0,0442	76,0
[3 2 8]	394	0,0226	89,0
[3 3 8]	284	0,0176	91,6
[3 4 8]	257	0,0154	93,0
[3 5 8]	134	0,0139	93,7
[3 6 8]	154	0,0138	94,2
[3 7 8]	179	0,0126	94,6
[3 8 8]	294	0,0114	94,9
[3 9 8]	311	0,0106	95,0
[3 10 8]	172	0,0112	94,7

Os resultados apresentados na Tabela 4 demonstram a capacidade de generalização da RNA, possibilitando estimar soluções para os casos desconhecidos apresentados na fase de teste. Em alguns casos, como falha de conexão, a rede apresentou uma taxa de acerto de 98% dos padrões desta causa. O menor nível de acerto obtido foi para o teste de transformador avariado, sendo 66% de amostras classificadas corretamente.

Realizou-se ainda, um teste com todos os padrões juntos, a fim de verificar a capacidade da rede em diferenciar os padrões a partir de um único teste, neste caso a RNA apresentou um nível médio de acerto da ordem de 90,6% de um total de 1467 amostras apresentadas.

**TABELA 4 - RESULTADOS DOS TESTES PARA DIFERENTES PADRÕES DE PROBLEMAS DE ACORDO COM O MÉTODO 2**

<b>Causa do Problema</b>	<b>Nº de Amostras de Teste</b>	<b>Validação (%)</b>
Ajuste RT	354	89,3
Falha de Conexão	107	98,1
Setor Sobrecarregado	92	93,5
Substituição de Ramal	97	96,6
TAP Sobre dimensionado	351	93,4
TAP Subdimensionado	371	93,8
Trafo Avariado	98	66,3

Analisando a Tabela 4, percebe-se que os resultados de teste melhoraram consideravelmente em relação ao método 1, isso porque, aumentou-se a quantidade de amostras, melhorando o desempenho da rede, além disso, os limites que definidos como normais e anormais foram alterados e o padrão de saída da rede foi definido apenas com valores

binários. Estas estratégias foram suficientes para aumentar consideravelmente o percentual de acerto da rede na fase de testes.

### 5.3 ANÁLISE DOS RESULTADOS OBTIDOS PARA O MÉTODO 3 E 4.

Na Tabela 5, são apresentados os melhores resultados obtidos no treinamento das redes neurais utilizando os métodos 3 e 4, descritos nas Seções 4.1.3 e 4.1.4 respectivamente. Assim como nos métodos 1 e 2, a rede que obteve a melhor performance foi a configuração [3 9 8].

**TABELA 5 - RESULTADOS DO MELHOR TREINAMENTO REALIZADO UTILIZANDO OS MÉTODOS 3 E 4 DE TRATAMENTO DOS DADOS**

<b>Método</b>	<b>Configuração da RNA</b>	<b>Épocas para Convergência</b>	<b>Erro (MSE)</b>	<b>Validação (%)</b>
3	[3 9 8]	103	0,0041	97,9
4	[3 9 8]	129	0,0043	98,0

Durante a fase de teste foi apresentado a RNA o novo conjunto de amostras, constituído por 9,8% das amostras do conjunto total. Os resultados obtidos na fase de testes para os métodos 3 e 4, são apresentados na Tabela 6.

Nos dois métodos, assim como no método 2, realizou-se ainda um teste com todos os padrões juntos, a fim de verificar a capacidade da rede em diferenciar os padrões a partir de um único teste, os resultados obtidos também estão apresentados na Tabela 6 para cada método respectivamente.

**TABELA 6 - RESULTADOS DOS TESTES PARA DIFERENTES PADRÕES DE PROBLEMAS DE ACORDO COM OS MÉTODOS 3 e 4**

<b>Causa do Problema</b>	<b>Nº de Amostras de Teste</b>	<b>Validação (%) Método 3</b>	<b>Validação (%) Método 4</b>
Ajuste RT	340	99,7	98,5
Falha de Conexão	100	99,0	94,0
Setor Sobrecarregado	250	98,0	97,6
Substituição de Ramal	120	100,0	100,0
TAP Sobre dimensionado	340	99,7	99,4
TAP Subdimensionado	230	99,6	99,6
Trafo Avariado	100	88,0	81,0
Todos os Casos Juntos	1480	98,6	97,4

Nos métodos 3 e 4, variou-se apenas os limites pré-definidos dos dados, afim de obter o mais eficaz. De acordo com a Tabela 6, observa-se que o método 3, onde definiu-se os limites entre 120 a 133 Volts, foi ligeiramente melhor que o método 4, o qual também apresentou um excelente resultado.

#### 5.4 ANÁLISE DOS RESULTADOS OBTIDOS A PARTIR DO MÉTODO 5.

Para o método 5 descrito na Seção 4.1.5, o melhor resultado obtido no treinamento da rede, foi utilizando a topologia [3 9 7]. Percebe-se que o número de neurônios da última camada diminuiu com relação aos métodos anteriores. Para esta topologia de rede o melhor resultado obtido foi em 233 épocas para convergência com um MSE de 0,004 e um percentual de validação dos resultados esperados de 98,1%.

Durante a fase de teste foi apresentado a RNA o novo conjunto de 1480 amostras, equivalente 9,8% das amostras do conjunto total. Os resultados obtidos na fase de testes para o método 5, são apresentados na Tabela 7. Vale ressaltar que para este método os problemas de Ajuste RT e TAP Sobre dimensionado são um único padrão de saída.

**TABELA 7 – RESULTADOS DOS TESTES PARA DIFERENTES PADRÕES DE PROBLEMAS DE ACORDO COM O MÉTODO 5**

<b>Causa do Problema</b>	<b>Nº de Amostras de Teste</b>	<b>Validação (%)</b>
Falha de Conexão	100	96,0
Setor Sobrecarregado	250	96,8
Substituição de Ramal	120	100,0
TAP ou RT Sobre dimensionado	640	99,6
TAP ou RT Subdimensionado	230	100,0
Trafo Avariado	100	83,0
Todos os Casos Juntos	1480	97,8

Os resultados obtidos no método 5, mostrou-se satisfatórios, pois o erro obtido em todos os padrões se manteve reduzido, assim como nos métodos 2, 3 e 4, porém, a complexidade da rede foi reduzida, ou seja, a camada neural de saída passou a ter apenas 7 neurônios, visto que, os padrões de problemas como TAP e RT mau diminuídos são um único caso, pois possuem características de curvas semelhantes.

Nota-se nos resultados obtidos, que o padrão Trafo avariado continua com um erro consideravelmente maior que os demais, cerca de 17%, isso explica-se analisando a curva característica do padrão mostrada na Figura 11, nota-se que a curva oscila bastante, tanto para sobre tensão, como para sub tensão, neste caso a rede tende a confundir os resultados esperados com outros padrões, já que a curva de Trafo avariado se sobrepõe em determinados momentos a todos os outros padrões avaliados. Para corrigir este problema foi proposto os métodos 6 e 7.

## 5.5 ANÁLISE DOS RESULTADOS OBTIDOS A PARTIR DO MÉTODO 6.

Para o método 6 descrito na Seção 4.1.5, o melhor resultado obtido no treinamento da rede, foi utilizando a topologia [3 8 7]. Para esta topologia de rede o melhor resultado obtido foi em 118 épocas para convergência com um MSE de 0,003 e um percentual de validação dos resultados esperados de 99,0%.

Durante a fase de teste foi apresentado a RNA o novo conjunto de 1380 amostras. Os resultados obtidos na fase de testes para o método 6, são apresentados na Tabela 8. Vale ressaltar que para este método o problema de Trafo avariado foi excluído.

**TABELA 8 – RESULTADOS DOS TESTES PARA DIFERENTES PADRÕES DE PROBLEMAS DE ACORDO COM O MÉTODO 6**

<b>Causa do Problema</b>	<b>Nº de Amostras de Teste</b>	<b>Validação (%)</b>
Ajuste RT	340	99,1
Falha de Conexão	100	96,0
Setor Sobrecarregado	250	98,0
Substituição de Ramal	120	100,0
TAP Sobre dimensionado	340	99,7
TAP Subdimensionado	230	99,6
Todos os Casos Juntos	1380	99,0

Com intuito de minimizar os erros obtidos nos métodos anteriores, no método 6 decidiu-se retirar o padrão Trafo avariado do banco de dados, para que a rede não viesse a confundir os padrões. Analisando-se os resultados obtidos para o teste com todos os casos de uma só vez, nota-se uma redução do erro em relação aos métodos citados até aqui, ou seja, de um total de 1380 amostras apresentados a rede no teste, contendo 6 padrões de problemas diferentes, além de um padrão normal, a rede não acertou em apenas 1% das amostras. Para os métodos anteriores, o melhor resultado foi no método 3, onde a rede obteve um erro de 1,4%.

## 5.6 ANÁLISE DOS RESULTADOS OBTIDOS A PARTIR DO MÉTODO 7.

Para o método 7 descrito na Seção 4.1.7, utilizou-se redes individuais para cada padrão. O melhor resultado obtido nos treinamentos de todas as redes, foi utilizando a topologia [3 3 1]. Para esta topologia de rede o melhor resultado obtido em todos os treinamentos é apresentado na Tabela 9.



**TABELA 9 - MELHORES RESULTADOS NO TREINAMENTO PARA TODAS AS REDES NEURAIAS INDIVIDUAIS UTILIZANDO O MÉTODO 7 DE TRATAMENTO DOS DADOS**

<b>Rede Especialista</b>	<b>Configuração da RNA</b>	<b>Épocas para Convergência</b>	<b>Erro (MSE)</b>	<b>Validação (%)</b>
Ajuste RT	[3 3 1]	170	0,0066	67,0
Falha de Conexão	[3 3 1]	32	0,0018	82,2
Setor Sobrecarregado	[3 3 1]	72	0,0015	97,7
Substituição de Ramal	[3 3 1]	78	0,0004	96,4
TAP Sobre dimensionado	[3 3 1]	110	0,0056	95,0
TAP Subdimensionado	[3 3 1]	73	0,0017	99,2
Trafo Avariado	[3 3 1]	111	0,0066	71,4

Durante a fase de teste foi apresentado a RNA novos conjuntos de amostras totalizando 1480. Para cada rede apresentou-se um conjunto de amostras referente à especialidade da rede, esse tipo de teste foi chamado de teste exclusivo, ou seja, cada rede especialista deve identificar se existe o problema em que a mesma é especialista ou não.

Outra maneira de avaliar o desempenho das redes individuais foi apresentar para cada rede um conjunto contendo amostras de todos os padrões tratados neste trabalho, ao mesmo tempo, esperando assim, que cada rede conseguisse avaliar o problema em que a mesma é especialista ou não. Nos casos que não representam a especialidade da rede, a mesma deve indicar uma condição zero, ou seja, normal, mesmo que as medidas transgridam os limites impostos. Este modelo de teste foi chamado de teste geral.

Os resultados obtidos na fase de testes para o método 7, são apresentados na Tabela 10. No último método, percebem-se resultados extremamente satisfatórios, pois os erros mantiveram-se reduzido em todos os casos. A pior situação continuou sendo o padrão Trafo avariado com cerca de 13% de erro no teste realizado contendo apenas amostras relativas à sua especialidade e amostras normais, porém, no teste realizado com a mesma rede, mas com todos os casos de uma só vez, a rede especialista em Trafo avariado foi capaz de identificar as amostras com problema de Trafo avariado e reconhecer todas as outras como normais, neste caso a rede errou em apenas 0,9% das 1480 amostras avaliadas.

As redes especialistas quando testadas com padrões diferentes do que elas haviam sido treinadas diferenciaram bem casos normais e de sua especialidade. A técnica de utilizar redes separadas ainda reduz a complexidade computacional, viabilizando uma aplicação prática. Além disso, com redes especialistas, pode-se aumentar o banco de dados do treinamento, inclusive com novos padrões, a fim de melhorar a capacidade de reconhecimento de problemas da rede, sem aumentar a complexidade computacional da rede neural artificial.

**TABELA 10 – RESULTADOS DOS TESTES PARA DIFERENTES PADRÕES DE PROBLEMAS DE ACORDO COM O MÉTODO 7**

<b>Rede Especialista</b>	<b>Nº de Amostras no Teste Exclusivo</b>	<b>Nº de Amostras no Teste Geral</b>	<b>Validação Teste Exclusivo (%)</b>	<b>Validação Teste Geral (%)</b>
Ajuste RT	340	1480	99,4	99,9
Falha de Conexão	100	1480	96,0	99,7
Trafo Avariado	100	1480	87,0	99,1
Setor Sobrecarregado	250	1480	98,8	99,8
Substituição de Ramal	120	1480	100,0	99,5
TAP Sobre dimensionado	340	1480	99,7	99,9
TAP Subdimensionado	230	1480	99,6	99,7

## 5.7 ANALISE GERAL DOS RESULTADOS

A Tabela 11 apresenta um resultado geral dos testes realizados para todos os métodos de tratamento dos dados. Estes resultados descrevem o percentual médio de acerto das redes quando submetidas a tarefa de identificar a causa do problema de variação de tensão do sinal avaliado. Para o método 1 não houve um teste geral, com todas as amostras ao mesmo tempo, por isso será utilizado como resultado a média dos testes separados. No caso do método 7, está apresentado na Tabela 11 a média de todos os testes gerais realizados com todas as redes.

**TABELA 11 – RESULTADO GERAL DOS TESTES PARA TODOS OS MÉTODOS**

<b>Causa do Problema</b>	<b>Nº de Amostras de Teste</b>	<b>Validação (%)</b>
Método 1	618	60,2
Método 2	1467	90,6
Método 3	1480	98,6
Método 4	1480	97,4
Método 5	1480	97,8
Método 6	1380	99,0
Método 7	1480	99,6

De acordo com os resultados apresentados na Tabela 11, percebe-se que método 1, apresentou a menor performance entre os métodos propostos, vis o erro médio de 39,8% na classificação dos casos. Os demais métodos obtiveram erros menores do que 10%. O método que se mostrou mais eficaz foi o método 7, que consiste em utilizar redes separadas para cada padrão de dados. Neste caso, quando apresentado para cada rede especialista todos as amostras de teste de uma só vez, contendo diferentes padrões, as redes obtiveram uma média de 0,4% de erro na classificação do problema em que a mesma foi treinada.

Com base nos resultados gerais do trabalho, comprova-se a eficiência de redes neurais artificiais para generalização dos casos relativos a variações de tensão em regime permanente, bem como, sua promissora aplicabilidade prática, cuja utilização auxiliará as concessionárias de energia elétrica identificar problemas que estão causando variações de tensão de longa duração, de maneira rápida e confiável, durante o processo de análise de nível de tensão.

## 6 CONSIDERAÇÕES FINAIS

A tempos que o sistema elétrico de potência passa por uma grande readaptação funcional e estrutural, isso porque, nos últimos anos o desenvolvimento tecnológico mundial tem sido acelerado. Impulsionada pelo grande aumento da inserção de cargas sensíveis a variações de tensão e com características não-lineares no sistema, as concessionárias de distribuição têm se preocupado cada vez mais com a qualidade de energia elétrica ofertada aos consumidores.

No mesmo ritmo acelerado de readaptação das empresas de distribuição a nova realidade energética mundial, caminham os órgãos reguladores do setor elétrico, realizando mudanças em suas normas, afim de garantir que a qualidade de energia do sistema seja cada vez melhor, sempre buscando um equilíbrio entre o crescimento das concessionárias e os direitos dos consumidores. No Brasil o órgão responsável pela normatização do sistema elétrico de potência é a ANEEL, que regulamenta todos os procedimentos de distribuição de acordo com o PRODIST em seu módulo 8. A partir do ano de 2015, passou a vigorar com base nas novas exigências da ANEEL a versão 6 do PRODIST, dentre várias mudanças que aconteceram nesta versão, destaca-se neste trabalho a extinção dos prazos para regularização de problemas com variação de tensão de longa duração. Com isso, as concessionárias do Brasil passaram a ter um aumento significativo de custos, relativos a multas pagas a ANEEL por não garantirem níveis adequados de tensão aos consumidores, bem como, ressarcimentos financeiros previstos pelo PRODIST.

O intuito deste trabalho foi justamente propor uma ferramenta de inteligência computacional que auxilie as concessionárias a se adequarem as novas exigências da ANEEL, ou seja, uma vez que seja realizado a medição dos níveis de tensão em uma unidade consumidora, possa-se caracterizar simultaneamente, se há ou não problema de variação de tensão em regime permanente e caso haja, qual a causa do mesmo.

Os resultados obtidos neste trabalho foram muito satisfatórios, apontando que é possível desenvolver um *hardware* ou *software* fundamentado em RNA para análise de sinais de nível de tensão em regime permanente, que poderá auxiliar as empresas de distribuição de energia elétrica a se adequarem no que tange as novas exigências da ANEEL, previstas na versão 6 do módulo 8 do PRODIST, reduzindo assim, custos por parte das concessionárias, com multas pagas para ANEEL, ressarcimento ao consumidor e manutenções desnecessárias.

No caso dos consumidores, a ferramenta proposta também trará importantes contribuições, pois o tempo em que o consumidor será afetado com uma qualidade de energia fora dos padrões diminuirá. Por exemplo, em processos comerciais, como caixa eletrônico, caixas de mercado, bolsa de valores, entre outros, uma qualidade de energia abaixo do padrão pode levar ao desligamento de equipamentos elétricos, podendo acarretar grandes perdas financeiras ao consumidor, além de transtorno e insatisfação dos clientes. No caso de indústrias, problemas com variações de tensão de longa duração, podem gerar prejuízos ainda mais relevantes. Elevações ou afundamentos de tensão podem reiniciar, ou até mesmo parar processos lógicos controláveis das indústrias. Desta forma, mesmo que a ANEEL exija que a concessionária faça o ressarcimento aos consumidores afetados, ainda assim, os prejuízos somados que a indústria terá devido ao tempo necessário para reestabelecer o processo, normalmente será maior do que a multa paga pela concessionária.

Conforme o previsto nos objetivos deste trabalho, treinaram-se diferentes redes neurais, a fim de encontrar a que mais se adequasse ao problema proposto. Com base nos resultados obtidos, evidenciou-se que a rede mais sugestiva para reconhecimento de padrão de problemas que causam variações de tensão no sistema elétrico são as redes individuais, pois apresentam maior capacidade de generalização dos padrões, além de baixa complexidade, o que viabiliza uma aplicação prática.

## 7 PERSPECTIVAS PARA TRABALHOS FUTUROS

Os resultados obtidos neste trabalho apontam a eficiência das redes neurais artificiais no reconhecimento dos padrões de problemas que causam variações de tensão de longa duração em regime permanente e potencial para uma promissora aplicação prática. Tendo em vista a aplicação prática desta proposta, maiores estudos devem ser realizados, portanto em trabalhos futuros espera-se:

- Aumentar o banco de dados, visando aumentar a capacidade de generalização da rede no reconhecimento dos problemas que causam variação de tensão, pois uma quantidade maior de amostras apresentadas para rede no treinamento pode torna-la mais eficiente na etapa de teste;
- Apresentar para a rede os dados de entrada a partir de um janelamento. Tal procedimento pode auxiliar a rede a identificar as características de cada problema, pois, deste modo a rede passará a avaliar uma quantidade maior de dados por vez, podendo caracterizar melhor o início, meio e fim do distúrbio.
- Individualizar o treinamento para cada fase, ou seja, propor redes para análise individual das fases do sistema visto a existência de consumidores bifásicos e monofásicos;
- Adequar os dados e treinar as redes para diversas classes de tensão de fornecimento.
- Desenvolver o software e/ou hardware para aplicação profissional;

## REFERÊNCIAS

BARRA, Fernanda. (2013). **Redes neurais artificiais**. Disponível em: < <http://blogdopetcivil.com/2013/07/05/redes-neurais-artificiais/>>. Acesso em: 28 abril 2015.

CERQUEIRA, A. S.; DUQUE, C. A.; RIBEIRO, M. V.; ROGERIO, M. T. *Digital system for detection and classification of power quality disturbances*. In: **Latin America Transactions, Ieee (Revista Ieee America Latina)**, V. 4, N. 5, P. 345-352, 2006.

CHANDEL, A. K.; GULERIA, G.; CHANDEL, R. *Classification of power quality problems using wavelet based artificial neural network*. **IEEE/PES Transmission and Distribution Conference and Exposition**, Chicago, p. 1-5, Abr, 2008.

DELMONT, F. O.; OLESKOVICZ, M.; ARRUDA, E. F. Classificação e Análise de Múltiplos Distúrbios Relacionados a Qualidade da Energia Elétrica Utilizando as Transformadas Wavelet e de Fourier. In: **Congresso Latino-americano de Geração e Transmissão de Energia Elétrica**, 2007, Vinã del Mar. Clagtee, 2007.

DUDA, R. O.; HART P. E., STORK D. G. (2001). *Pattern Classification*. John Wiley, New York, USA.

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

FIORIN, Daniel V.; MARTINS, Fernando R.; SCHUCH, Nelson J.; PEREIRA, Enio B. Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. **Revista Brasileira de Ensino de Física**, São Paulo, v. 33, n. 1, Jan/Mar. 2011. Disponível em: < <http://dx.doi.org/10.1590/S1806-11172011000100009>>. Acesso em: 28 abril 2015.

GAOUDA, A. M. ET AL. *Power quality detection and classification using wavelet-multiresolution signal decomposition*. In: **IEEE Transactions On Power Delivery**, V. 14, N. 4, P. 1469-1476, 1999.

GOIS, A. M.; AMARAL, R.; RIBEIRO, J. H.; HENRIQUE, A. L.; SILVA, M. Proposta para Detecção e Classificação de Distúrbios de Qualidade da Energia Elétrica utilizando a Transformada Wavelet Estacionária. In: **8th Latin American Congress: Electricity Generation and Transmission**, 2009, Ubatuba-Brasil. 2009.

GRANADOS, Lieberman D.; ROMERO Troncoso R. J.; OSORNIO, Rios R. A.; GARCIA, Perez A.; CABAL, Yopez E. *Techniques And Methodologies For Power Quality Analysis And Disturbances Classification In Power Systems: A Review. In: Generation, Transmission & Distribution, IET*, v. 5, n. 4, p. 519-529, 2011.

HAGAN, M. T.; MENHAJ, M. B. *Training feedforward networks with the Marquardt algorithm. IEEE*. v. 5, n. 6. p. 989-993. 1994.

HAYKIN, Simon. *Neural networks - a comprehensive foundation*. 2. ed. Prentice Hall, 1999.

HECHT-NIELSEN, Robert. *Theory of the backpropagation neural network*. In: **Neural Networks, 1989. IJCNN., International Joint Conference on. IEEE**, 1989. p. 593-605.

KAGAN, N.; OLIVEIRA, C. C. de B.; ROBBA, E. J. *Introdução aos Sistemas de Distribuição de Energia Elétrica*, 2. ed. Editora Blucher, São Paulo, 2010.

KJOLLE, Gerd H.; SAMDAL, Knut; SINGH, B.; KVITASTEIN, O. A. *Customer Costs Related to Interruptions and Voltage Problems: Methodology and Results*. In: **IEEE Transactions on Power Systems**, v. 23, n. 3, Ago. 2008.

MAFFRA, Fabíola. A.; GATTASS, Marcelo. Uma implementação do método de Levenberg-Marquardt em C. 2008. Disponível em: < [http://webserver2.tecgraf.puc-rio.br/~mgattass/LM\\_Fabiola/](http://webserver2.tecgraf.puc-rio.br/~mgattass/LM_Fabiola/)>. Acesso em: 17 novembro 2015.

MARQUES, de Sá J. P. Reconhecimento de Padrões. 2000. Disponível em: < <https://web.fe.up.pt/~jmsa/recpad/>>. Acesso em: 17 novembro 2015.

McCulloch, W.; Pitts, W. *A logical of the ideas immanent in nervous activity*. In: **Bulletin Of Mathematical Biophysics**, S. 1, N. 5, P. 115-133, 1943.

LEVENBERG, Kenneth. *A method for the solution of certain non-linear problems in least squares*. p. 164-168, 1944.

OLESKOVICZ, M.; FILHO, O. D.; CARNEIRO, A. A. F. M.; USIDA, W. F.; COURRY, D. V. Um Sistema Híbrido para a Análise da Qualidade da Energia Elétrica Dispondo da Transformada Wavelet Aliada a Sistemas Fuzzy. In: **Congresso Latino-americano de Geração e Transmissão de Energia Elétrica**, 2007, Vinã del Mar. Clagtee, 2007.

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



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

RODRIGUEZ, M. V.; TRONCOSO, R. J. R.; RIOS, R. A. O.; PEREZ, A. G. **IEEE Transactions on Industrial Electronics**, v. 61, p. 2473-2482, Mai, 2014.

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