

Redes Neurais Artificiais Aplicadas ao Problema de Variação de Tensão de Longa Duração em Sistemas de Distribuição de Energia Elétrica

Marina Sibim Fávaro, Murilo da Silva
Universidade Tecnológica Federal do Paraná
marinasibim@hotmail.com, murilosilva@utfpr.edu.br

Reginaldo Leopoldino, Rogério Cesar S. Silva,
Vinícios Thomaz Medeiros, Alexandre M. de Gois
Companhia Paulista de Força e Luz
rleopoldino@cpfl.com.br, rcssilva@cpfl.com.br,
viniciosthomaz@cpfl.com.br, alexgois@cpfl.com.br

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

Palavras-chaves — Qualidade de Energia Elétrica, Redes Neurais Artificiais, Variações de Tensão de Longa Duração, Sistemas de Distribuição de Energia.

I. INTRODUÇÃO

A energia elétrica é uma das formas de energia mais utilizadas atualmente. Em consequência disso, existe uma grande preocupação em se manter a qualidade dessa energia devido as perdas financeiras a ela associadas, tanto do ponto de vista do consumidor, quanto da distribuidora de energia elétrica.

A qualidade de energia é avaliada por dois pontos importantes: a qualidade do produto e a qualidade do serviço. A qualidade do produto diz respeito à capacidade do sistema elétrico fornecer energia com tensões equilibradas e sem deformações da forma de onda da tensão e corrente. Já a qualidade do serviço é medida segundo a continuidade do fornecimento da energia elétrica [1].

No Brasil a Qualidade de Energia Elétrica (QEE) é regulamentada pelo Módulo 8 do PRODIST (Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional) [2], documento este proposto pela Agência Nacional

de Energia Elétrica (ANEEL). Dentre os parâmetros abordados para a qualidade do produto por este módulo, a tensão em regime permanente é um dos que são penalizados pela ANEEL atualmente.

Para a tensão em regime permanente são estabelecidos os limites adequados, precários e críticos para os níveis de tensão, indicadores individuais e coletivos de conformidade de tensão elétrica, critérios de medição, de registro e prazos para compensação ao consumidor, caso as medições de tensão excedam os limites determinados. Essas medições são estabelecidas pela ANEEL e compreendem o registro de 1008 leituras válidas obtidas em intervalos consecutivos de 10 minutos cada, durante 7 dias, de forma a determinar o comportamento da tensão nesse período. Após a obtenção do conjunto de leituras válidas, devem ser calculados os indicadores individuais de conformidade de tensão elétrica, sendo eles: i) Índice de duração relativa da transgressão para tensão precária (DRP) e ii) Índice de duração relativa da transgressão para tensão crítica (DRC).

A Revisão 8 do Módulo 8 do PRODIST [2] estabelece a duração relativa da transgressão máxima para os índices em 3% para o DRP e 0,5% para o DRC. Caso estes limites sejam ultrapassados, a distribuidora deverá tomar providências para regularizar a tensão de atendimento e pagará uma compensação financeira ao consumidor prejudicado até que o problema seja resolvido e comprovado por uma nova medição.

As medições e as análises dos indicadores, entretanto, permitem apenas a verificação da existência ou não de transgressão dos níveis adequados de tensão. A identificação dos problemas que causam essas variações de tensão é feita partindo-se da premissa de sobrecarga no sistema.

A dificuldade em se identificar a fonte causadora do problema acaba por elevar o tempo para restabelecimento do padrão adequado de nível de tensão, acarretando períodos de ressarcimento mais longos para a concessionária e exposição do consumidor ao problema [3].

Sendo assim, este artigo propõe uma alternativa para a análise e classificação das causas dos problemas que levam a variações de tensão de longa duração, utilizando Redes Neurais Artificiais (RNAs), treinadas e testadas com dados reais de tensão obtidos em campo e fornecidos pela Companhia Paulista de Força e Luz (CPFL), para que com essa ferramenta as concessionárias possam identificar e corrigir o problema de forma mais rápida e efetiva, trazendo assim benefícios financeiros, além de melhorias no processo e no atendimento aos clientes.

II. REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso de seres vivos, cuja principal propriedade é sua habilidade de aprender a partir de seu ambiente e de melhorar seu desempenho através de aprendizagem [4].

As RNAs podem ser definidas como um conjunto de unidades de processamento (neurônios artificiais), que são interligados por um grande número de interconexões (sinapses artificiais) [5]. Cada neurônio artificial efetua um certo número de operações simples e transmite seus resultados aos neurônios vizinhos com os quais possui conexão [6].

Uma RNA é composta por três diferentes camadas, como pode ser visto na Fig. 1, as quais são interligadas e apresentam diferentes funções. A camada de entrada é responsável pelo recebimento de informações, enquanto que as camadas intermediárias são encarregadas de extrair as características associadas ao processo e a camada de saída é responsável pela produção e apresentação dos resultados finais da rede [5].




Fig. 1. Representação das camadas que compõem uma RNA, usando como exemplo uma RNA com duas camadas intermediárias.

A forma como os diversos neurônios de uma rede neural são arranjados determina o tipo de arquitetura da rede. Cada arquitetura pode possuir diversas topologias, dependendo do número de camadas intermediárias e número de neurônios nessas camadas [5].

A arquitetura de rede escolhida para este artigo foi a *Perceptron* Multicamadas (PMC) ou *Multilayer Perceptron* (MLP), por apresentar grande aplicabilidade como classificadora de padrões visto que o escopo deste trabalho é a identificação dos padrões de problemas que geram variações de tensão de longa duração. Este tipo de arquitetura tem como

principal característica a existência de pelo menos uma camada intermediária entre a camada de entrada e a camada de saída.

O treinamento utilizado foi o supervisionado. Neste tipo de treinamento é necessário apresentar para a rede os dados de entrada e suas respectivas saídas desejadas para que, dessa forma, os pesos sinápticos e limiares da rede sejam ajustados, e a saída real da rede se encaminhe estatisticamente para a saída desejada. Durante o treinamento, a igualdade entre a saída real e a desejada é avaliada pelo cálculo do *Mean Square Error* (MSE). Quanto menor for o MSE, mais próximo do desejado estará a saída real da rede.

O algoritmo de aprendizado utilizado no processo de treinamento foi o *Levenberg-Marquardt* por apresentar maior velocidade de convergência em relação a outros algoritmos deste tipo, sendo assim considerado um dos algoritmos de treinamento mais eficientes [7].

III. DESENVOLVIMENTO

No treinamento e teste das redes deste trabalho são utilizados dados reais de tensão obtidos em campo e fornecidos pela Companhia Paulista de Força e Luz (CPFL). Tais dados foram obtidos seguindo os requisitos de medição propostos pelo PRODIST [2] e fornecem valores eficazes de tensão integralizados a cada 10 minutos, medidos entre cada fase e o neutro do consumidor. A implementação da rede PMC foi feita utilizando-se linhas de comando e a ferramenta de interface gráfica da *toolbox nntool* do *Mallab*®.

Durante a etapa de treinamento, foram apresentados os dados de entrada e os dados desejados na saída para a rede de forma simultânea para ajustar os pesos sinápticos. Como em cada treinamento os pesos sinápticos são inicializados de forma aleatória e isso interfere na performance final, para evitar que se tenha um treinamento inadequado e, conseqüentemente, uma rede mal treinada, fez-se para cada topologia testada, 10 treinamentos consecutivos antes de prosseguir para a fase de teste. Nesta etapa, utilizou-se então apenas a rede com as configurações obtidas após o melhor treinamento dentre todos os realizados. Classificou-se como melhor treinamento aquele que possuía o menor erro quadrático médio (MSE), ou seja, o que apresentou resultado mais próximo do desejado.

Na fase de teste são apresentados novos dados à rede, ou seja, dados diferentes dos utilizados durante o treinamento. O resultado esperado na saída não é mostrado para a rede, mas sim comparado com o resultado real da rede a fim de determinar a porcentagem de acerto obtida. A Fig. 2 ilustra de forma simplificada os procedimentos realizados com a RNA.

Para analisar a capacidade da RNA de classificar os padrões, foram considerados 7 problemas que frequentemente causam variação de tensão na rede de distribuição, sendo eles:

- Sobrecarga;
- Transformador avariado (trafo avariado);
- Ajuste do regulador de tensão (ajuste RT);
- Falha em conexões;
- Ramal de entrada com problema;
- Tap do transformador subdimensionado;
- Tap do transformador sobredimensionado.




Fig. 2. Fluxograma dos procedimentos realizados com a RNA.


Vale ressaltar que a condição normal, ou seja, quando o valor da amostra de tensão está dentro dos limites estabelecidos, também é considerado um padrão. Estes limites foram estabelecidos empiricamente e compreendem o intervalo de 120 a 133 V. Os dados de entrada são classificados primeiramente levando em consideração esse intervalo, de modo que, para cada amostra analisada, se o valor de tensão estiver dentro do limite, o respectivo vetor de saída recebe o vetor da condição normal. Caso contrário, mantém o vetor de problema prévio, uma vez que ao utilizar-se o treinamento do tipo supervisionado sabe-se antecipadamente, para cada amostra de tensão, qual distúrbio está relacionado a esta. Tem-se, dessa forma, para cada dado de entrada, um vetor desejado na saída pré-determinado.

Buscando-se apresentar um intervalo maior de dados para a RNA, a fim de caracterizar melhor as mudanças nos padrões, fez-se o janelamento desses dados para apresentá-los a entrada da rede.

O janelamento dos dados apresentados à RNA foi feito utilizando janelas de 6 amostras (correspondendo a um intervalo de 60 minutos de medição) e passo de 1 amostra. Este tipo de processamento dos dados traz um aumento da complexidade da rede. Para amenizar esse problema, visando uma diminuição dessa complexidade, utilizou-se redes especialistas para cada um dos problemas citados anteriormente. Este tipo de rede classifica as entradas apenas como pertencentes ao problema ao qual ela é especialista, ou não. Dessa forma, na saída da rede, tem-se apenas um neurônio para apresentar a resposta da RNA. A saída apresenta o valor 1 (positivo) quando a entrada corresponder ao problema que a rede é especialista, ou então, apresenta o valor 0 (negativo) quando a entrada corresponder a qualquer outro problema, ou à condição normal.

Como dito anteriormente, os dados possuem originalmente, para cada amostra de tensão, um respectivo vetor desejado na saída. Após o janelamento dos dados, entretanto, tem-se apenas um vetor desejado na saída referente à janela toda. A

determinação do valor desse vetor segue a seguinte regra: se uma das 6 amostras da janela apresentar condição anormal, ou seja, valor 1, a janela toda é considerada anormal e o vetor desejado na saída correspondente àquela janela recebe o valor 1. Se todas as 6 amostras da janela apresentarem condição normal (valor 0), o vetor desejado na saída correspondente à janela recebe valor 0. O processo de ajuste dos vetores desejados na saída para cada janela é representado na Fig. 3.



Saídas desejadas de cada amostra

Saídas desejadas de cada janela

Fig. 3. Representação do arranjo dos dados desejados na saída da RNA após o janelamento.

A apresentação dos dados na entrada da RNA também é feita de forma específica para os dados janelados. A rede deve possuir 18 entradas, de forma que sejam apresentadas simultaneamente as amostras de uma janela da fase A (6 amostras), seguidas das amostras de uma janela da fase B e da fase C, respectivamente. A Fig. 4 apresenta o processo de arranjo dos dados de entrada da rede após o janelamento.




Fig. 4. Representação do arranjo dos dados de entrada da RNA após o janelamento.

Os testes com a rede, foram feitos de forma a verificar diferentes topologias, ou seja, diferentes formas de arranjo dos neurônios na RNA, a fim de analisar qual delas apresentava melhor resultado, o que é determinado pelo maior percentual de acerto. Treinou-se e testou-se a rede variando o número de camadas intermediárias entre 1 e 2, além do número de

neurônios nessas camadas de 1 a 10. A Fig. 5 apresenta de forma generalizada a topologia da rede utilizada neste artigo.




Fig. 5. Representação da RNA utilizando dados janelados: 18 entradas e 1 neurônio na saída.

Ao final do processo tem-se, então, para cada janela, um vetor de saída que será comparado com o vetor desejado para determinar o percentual de acerto da rede. Por se utilizar redes especialistas analisa-se de forma individual, a presença ou não de determinado distúrbio. Se o vetor de saída assume valor 1 (positivo), sabe-se que existe o distúrbio e que ele corresponde ao problema que a rede é especialista. Se o vetor de saída assume valor 0 (negativo), sabe-se que não existe distúrbio naquele intervalo, correspondendo, dessa forma, à condição normal ou a qualquer outro problema que a rede não é especialista.

Os procedimentos citados anteriormente foram feitos de forma individual para cada rede especialista e os resultados obtidos nos testes estão apresentados na seção Resultados.

IV. RESULTADOS

A. Testes realizados e resultados obtidos

O janelamento foi feito tanto com os dados de treinamento, quanto com os dados de teste e a quantidade de amostras utilizadas para cada um foi de 13619 e 1475, respectivamente.

Após realizar os 10 treinamentos com cada topologia de rede proposta, verificou-se qual deles apresenta o menor erro quadrático médio (MSE) para cada uma delas e, assim, selecionou-se a melhor configuração de rede para realizar o teste.

Da Tabela I a Tabela VII são apresentados os resultados obtidos para cada rede especialista, demonstrando o percentual de acerto obtido no teste para cada topologia. É especificado para cada topologia a quantidade de entradas, de camadas intermediárias e o número de neurônios nessas camadas, bem como o número de neurônios na saída. A topologia [18 1 1], por exemplo, apresenta dezoito entradas, duas camadas

intermediárias, cada uma com um neurônio e um neurônio na saída.

Na Tabela I é possível observar que a topologia [18 1 1] é a que apresenta melhor resultado, com um percentual de acerto de 98,4407%. Embora outras topologias tenham tido o mesmo resultado, assume-se essa como a melhor dentre elas, seguindo a regra de escolha da rede mais compacta possível.

TABELA I. RELAÇÃO DAS TOPOLOGIAS TESTADAS E DO PERCENTUAL DE ACERTO NA FASE DE TESTE, UTILIZANDO REDE ESPECIALISTA PARA O PROBLEMA DE SOBRECARGA.

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

Analisando-se a Tabela II percebe-se que a topologia [18 3 1] é a que apresenta melhor resultado, com um percentual de acerto de 98,2373% para o problema transformador avariado.

Por meio da Tabela III observa-se que a topologia [18 1 1 1] é a que apresenta melhor resultado, com um percentual de acerto de 86,9831% para o problema de ajuste de RT.

TABELA II. RELAÇÃO DAS TOPOLOGIAS TESTADAS E DO PERCENTUAL DE ACERTO NA FASE DE TESTE, UTILIZANDO REDE ESPECIALISTA PARA O PROBLEMA DE TRAFÓ AVARIADO.

TRAFO AVARIADO	
Topologia	Acerto no Teste (%)
[18 1 1]	95,7288
[18 2 1]	96,5424
[18 3 1]	98,2373
[18 4 1]	96,8814
[18 5 1]	96,8136
[18 6 1]	97,1525
[18 7 1]	96,8814
[18 8 1]	97,0169
[18 9 1]	97,3559
[18 10 1]	97,1525
[18 1 1 1]	96,0000
[18 1 8 1]	94,9153

TABELA III. RELAÇÃO DAS TOPOLOGIAS TESTADAS E DO PERCENTUAL DE ACERTO NA FASE DE TESTE, UTILIZANDO REDE ESPECIALISTA PARA O PROBLEMA DE AJUSTE RT.

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

Pelos dados obtidos na Tabela IV, é possível observar que a topologia [18 8 1] é a que apresenta melhor resultado, com um percentual de acerto de 88,9492% para o problema de falha em conexões do ramal de entrada.

TABELA IV. RELAÇÃO DAS TOPOLOGIAS TESTADAS E DO PERCENTUAL DE ACERTO NA FASE DE TESTE, UTILIZANDO REDE ESPECIALISTA PARA O PROBLEMA DE FALHA EM CONEXÕES.

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

Analisando os dados da Tabela V, percebe-se que a topologia [18 5 1] é a que apresenta melhor resultado, com um percentual de acerto de 97,6201% considerando-se o problema no ramal de entrada.

TABELA V. RELAÇÃO DAS TOPOLOGIAS TESTADAS E DO PERCENTUAL DE ACERTO NA FASE DE TESTE, UTILIZANDO REDE ESPECIALISTA PARA O PROBLEMA DE RAMAL DE ENTRADA.

RAMAL DE ENTRADA	
Topologia	Acerto no Teste (%)
[18 1 1]	76,5424
[18 2 1]	95,1864
[18 3 1]	97,1525
[18 4 1]	93,0847
[18 5 1]	97,6201
[18 6 1]	97,3559
[18 7 1]	97,2203
[18 8 1]	97,4915
[18 9 1]	96,8136
[18 10 1]	95,5932
[18 1 1 1]	76,5424
[18 1 8 1]	93,3559

Na Tabela VI é possível observar que a topologia [18 2 1] é a que apresenta melhor resultado, com um percentual de acerto de 98,2373% para problema de tap subdimensionado. Para este caso, a maioria das topologias apresentam percentuais de acerto similares, porém, percebe-se que aumentar a complexidade da rede não melhora significativamente os resultados.

Os resultados da Tabela VII demonstram que a topologia [18 6 1] é a que apresenta melhor resultado, com um percentual de acerto de 97,4915% considerando-se o problema de tap sobredimensionado. Embora a topologia [18 9 1] tenha tido o mesmo resultado, assume-se a [18 6 1] como a melhor dentre elas, seguindo a regra de escolha da rede mais compacta possível.

TABELA VI. RELAÇÃO DAS TOPOLOGIAS TESTADAS E DO PERCENTUAL DE ACERTO NA FASE DE TESTE, UTILIZANDO REDE ESPECIALISTA PARA O PROBLEMA DE TAP SUBDIMENSIONADO.

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

TABELA VII. RELAÇÃO DAS TOPOLOGIAS TESTADAS E DO PERCENTUAL DE ACERTO NA FASE DE TESTE, UTILIZANDO REDE ESPECIALISTA PARA O PROBLEMA DE TAP SOBREDIMENSIONADO.

TAP SOBREDIMENSIONADO	
Topologia	Acerto no Teste (%)
[18 1 1]	66,5085
[18 2 1]	83,8644
[18 3 1]	82,6441
[18 4 1]	96,2034
[18 5 1]	94,5763
[18 6 1]	97,4915
[18 7 1]	96,9492
[18 8 1]	97,1525
[18 9 1]	97,4915
[18 10 1]	97,2203
[18 1 1 1]	66,5085
[18 1 8 1]	91,6610

A Tabela VIII relaciona a melhor topologia de cada rede especialista, bem como, o percentual dos falsos positivos encontrados para cada uma delas, possibilitando uma análise geral dos melhores resultados obtidos pela rede utilizando o janelamento dos dados.

TABELA VIII. RELAÇÃO DA MELHOR TOPOLOGIA DE CADA REDE ESPECIALISTA, TESTADAS COM A REDE DE ENTRADA JANELADA, COM SEU RESPECTIVO ERRO NO MELHOR TREINAMENTO E PERCENTUAL DE ACERTO NO TESTE.

Rede Especialista	Melhor Topologia	Acerto no Teste (%)	Falsos Positivos (%)
Sobrecarga	[18 1 1]	98,4407	1,5593
Trafo Avariado	[18 3 1]	98,2373	0,4068
Ajuste RT	[18 1 1 1]	86,9831	12,5424
Falha em Conex.	[18 8 1]	88,9492	9,2203
Ramal de Entr.	[18 5 1]	97,6201	0,7458
TAP Subdim.	[18 2 1]	98,2373	0,6102
TAP Sobredim.	[18 6 1]	97,4915	0,6780

Dentre todos os casos abordados na Tabela VIII, destaca-se o resultado obtido para o problema de sobrecarga, com 98,4407% de acerto no teste, enquanto que no caso de problema de ajuste RT a RNA apresentou 86,9831% de acerto. A acurácia global é de 95,1% de acerto.

De forma geral pode-se inferir que as redes neurais especialistas com entrada de dados janelada apresentaram alta capacidade de generalização dos padrões de problemas testados que acarretam variações de tensão de longa duração e aplicabilidade da metodologia proposta.

B. Viabilidade Técnica e Econômica

O módulo 8 do PRODIST [2] descreve todo o procedimento para atendimento a uma reclamação de nível de tensão desde o atendimento, medição, diagnóstico, ressarcimento ao consumidor e regularização do problema caso haja transgressão dos padrões (DRP e DRC). Tais padrões são auferidos por meio de medições realizadas nas instalações dos consumidores durante sete dias.

A análise dos indicadores de transgressão de tensão (DRP e DRC), bem como, do histograma de tensão durante o processo de análise não permitem a identificação de todos os distúrbios que podem levar a transgressão de tensão tais como: tap errado do transformador, problemas nas conexões da rede (mau contato), problemas no ramal de entrada (parcialmente partido ou com mau contato), transformador avariado, problemas com regulador de tensão, problemas com aterramento, etc, podendo estes serem tratados como sobrecarga do sistema.

A identificação destes casos requer grande experiência do profissional na análise os dados da medição, tempo para análise e inspeções detalhadas das redes.

Uma inspeção refinada da rede requer a disponibilidade de uma equipe de eletricitas e equipamentos específicos. Supondo um custo médio da equipe de R\$340,00 por evento/hora, dois eventos anormais no mês em uma única região, duas horas para deslocamento, inspeção e regularização, teríamos no ano um custo de R\$ 16.340,00. Utilizando a ferramenta proposta, ainda precisaríamos disponibilizar uma equipe, porém o tempo de atendimento seria menor, uma vez que, a ferramenta apontaria a causa, evitando assim a inspeção completa da rede de distribuição secundária. Considerando-se uma redução no tempo para 1h, o custo anual cairia 50%, ou seja, para R\$ 8.160,00.

Do ponto de vista técnico, caso os eventos anormais na medição passem despercebidos sendo tratados como uma sobrecarga, considerando-se um custo médio do melhoramento secundário por volta de R\$ 20.000,00, no ano teríamos um custo médio de R\$ 480.000,00, referente a duas ocorrências mês. Neste caso, suponhamos que a ferramenta proposta apontasse que a maioria destes problemas fosse função de tap errado, conexões e ramais com problema, teríamos apenas o custo da equipe para regularização, caindo o custo para R\$ 8.160,00/ano, desconsiderando o custo do material. Nas duas situações descritas anteriormente os ganhos poderiam ser ainda mais significativos quando se eleva a análise para esfera de toda a concessão.

Nesta análise hipotética, não levamos em conta os custos com as penalizações devido a transgressão dos prazos de regularização do nível de tensão compensadas diretamente ao consumidor até a regularização do problema, as quais se elevam de acordo com o nível de tensão, uso do sistema e nível de transgressão. Podem haver também penalizações oriundas da fiscalização do processo de nível de tensão por parte da ANEEL, cujos valores podem variar de alguns centavos a milhares de reais. Acredita-se também que estes custos poderiam ser atenuados com a aplicação da metodologia proposta neste trabalho, tendo em vista a diminuição do tempo de transgressão e tratamento assertivo do problema.

No tocante ao consumidor, a aplicação da técnica proposta diminuiria o tempo de exposição do consumidor ao problema, garantindo melhorias no que tange ao atendimento e qualidade do serviço e do produto.

A metodologia pode ser utilizada via *software* para análises das reclamações dos consumidores ou ser inserida a um sistema Big Data, considerando-se dados advindos de telemedições e *smartmeters*, para análise preventiva e corretiva da concessionária antes mesmo que haja reclamação por parte do consumidor. Acredita-se que a metodologia proposta também possa ser embarcada nos medidores de tensão e faturamento para análise local e remota.

V. CONCLUSÕES

As perdas financeiras associadas à qualidade de energia são motivo de grande interesse na melhoria contínua do fornecimento de energia elétrica. A ferramenta proposta nesse artigo é uma alternativa para as distribuidoras de energia elétrica, a ser utilizada no diagnóstico dos problemas que causam variação de tensão, uma vez que o sistema de análise utilizado atualmente não fornece uma classificação clara dos problemas.

Analisando-se os resultados obtidos, observa-se que as redes especializadas com entrada janelada apresentaram resultados encorajadores, visto que se obteve, em média, um percentual de acerto de 95,1%, considerando-se todas as redes.

A aplicação desta proposta pode trazer também benefícios técnicos e econômicos as concessionárias de distribuição de energia elétrica, bem como, aos consumidores.

Tais resultados apontam para uma promissora viabilidade da aplicação desta proposta para classificação de problemas que frequentemente causam variação de tensão de longa duração em sistemas de distribuição de energia elétrica.

VI. REFERÊNCIAS

- [1] B. F. Barros; R. Borelli; R. L. Gedra, Gerenciamento de Energia: ações administrativas e técnicas de uso adequado da energia elétrica. 1 ed. São Paulo: Érica, 2010.
- [2] ANEEL, "Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST), Módulo 8, Revisão 8".
- [3] MEDEIROS, V. T. SILVA, M. SILVA, H. J. B. LEOPOLDINO, R. SIVA, R. C. S. Identificação Das Causas de Problemas de Nível de Tensão Inadequados Utilizando Redes Neurais Artificiais e Dados Reais da CPFL. Conferência Brasileira sobre Qualidade de Energia Elétrica. CBQEE, 2015.
- [4] S. Haykin. Redes neurais: princípios e práticas. 2. ed. Porto Alegre: Bookman, 2001.
- [5] I. N. Silva; D. H. Spatti; R. A. Flauzino, Redes Neurais Artificiais: para Engenharia e Ciências Aplicadas. 1. ed. São Paulo: Artliber Editora Ltda, 2010.
- [6] M. Brumatti, Redes Neurais Artificiais. Departamento de Engenharia Elétrica - Universidade Federal do Espírito Santo.
- [7] YU, H. WILAMOWSKI, B. M. Levenberg–Marquardt Training. Auburn University, 2010.