



## CLASSIFICAÇÃO DE DISTÚRBIOS EM RELAÇÃO À QUALIDADE DE ENERGIA USANDO REDE NEURAL ARTIFICIAL

Rafael Santos Freire Ferraz<sup>\*1</sup>, Renato Santos Freire Ferraz<sup>2</sup>, Aniel Silva de Morais<sup>3</sup>, Adjeferson Custódio Gomes<sup>2,3</sup>

<sup>1</sup>DEE – Universidade Federal de Campina Grande

<sup>2</sup>DCET – Universidade Estadual de Santa Cruz

<sup>3</sup>FEELT – Universidade Federal de Uberlândia

**Resumo** - A partir do aumento da utilização de equipamentos mais sensíveis a variação de tensão, corrente e frequência, os consumidores passaram a exigir uma maior qualidade de energia das concessionárias, resultando no desenvolvimento de normas regulamentadoras dos índices da qualidade da energia. Com isso, tem-se início os estudos para aprimorar a energia que é fornecida pelas concessionárias, dentre eles, tem-se a utilização de ferramentas computacionais com o intuito de classificar distúrbios que ocorrem em um sistema como *wavelet* e rede neural artificial. Para esse trabalho, utilizou-se um classificador da rede neural para um chaveamento de um banco de capacitor no *SIMULINK* com o intuito de gerar dados de transitórios, além da utilização do *MATLAB* para gerar dados de distúrbios como sobretensão e subtensão para o treinamento da rede. Com isso, obteve-se uma eficiência de 97,5%.

**Palavras-Chave** - Distúrbios, qualidade da energia, rede neural artificial, sobretensão, subtensão, transitórios eletromagnéticos.

### CLASSIFICATION OF DISTURBANCES IN RELATION TO POWER QUALITY USING ARTIFICIAL NEURAL NETWORK

**Abstract** - From the increased use of sensitive equipment to the voltage, current and frequency variation, consumers started to request a higher quality of energy from the electricity concessionaires, resulting in the development of norms regulating the energy quality indexes. Thus, studies were developed in order to improve the energy quality that is provided by utilities, so, it is possible to use computational tools in order to classify disturbances that occur in the electrical network such as *wavelet* and artificial neural network. For this work, the neural network classifier and the disturbances data were generated by using the software *MATLAB*. The electromagnetic transient data was generated using a capacitor bank switching in the simulink, and it was rafael.ferraz@ee.ufcg.edu.br

generated random data for others disturbances such as overvoltage and undervoltage for the network training. The efficiency obtained was 97.5%.

**Keywords** – Artificial neural network, disturbances, electromagnetic transients, power quality, overvoltage, undervoltage

### I. INTRODUÇÃO

Com o advento dos equipamentos computadorizados e sensíveis às perturbações do sistema elétrico, consumidores passaram a exigir da concessionária uma maior qualidade da energia elétrica [1]. A partir daí, pode-se observar a importância do estudo desse tema na área de sistemas de potência a fim de melhorar o fornecimento da energia. Então, na literatura, tem-se diversos conceitos para a qualidade da energia, referente as alterações do sistema elétrico.

Em [2], tem-se que a falta da qualidade como qualquer problema manifestado na tensão, corrente ou desvio de frequência, que resulta em falha ou má operação de algum equipamento dos consumidores, podendo ocorrer em várias partes do sistema desde as concessionárias até nas instalações de consumidores. Outro fato importante, foi a necessidade de regulamentar esses distúrbios causados na rede com o intuito de melhorar a qualidade da energia.

No Brasil entrou em vigor em 31 de dezembro de 2008, o módulo 8, do PRODIST (Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional), apresentando todas as normas referentes à qualidade da energia, sendo a versão vigente, a décima, desde o dia 01 de janeiro de 2018 [3].

Portanto, o desenvolvimento e o aperfeiçoamento de sistemas de monitoramento da qualidade da energia passaram a ser um dos focos da área de sistema de potência, abrangendo sistemas de detecção e de classificação de distúrbios [4]. Com isso, diversas ferramentas de processamento de sinais são utilizadas com o intuito de classificar esses problemas na rede, como por exemplo, a transformada de *wavelet*, assim como a utilização de redes neurais artificiais.

A referência [4], apresentou um método utilizando a rede neural para classificar a presença de harmônicos,

afundamentos de tensão, elevações de tensão, transitórios oscilatórios, efeito *notch* e *spike*, obtendo eficiências superiores a 96%. Já em [5], a rede neural apresentou um índice de acerto de 86,63% dos distúrbios do sistema de energia para uma baixa taxa de amostras por ciclo. Quando esse valor é elevado, tem-se um maior índice de acerto, sendo este de 92,44%.

Esse trabalho tem o objetivo de classificar os distúrbios: transitório, elevação de tensão, afundamento de tensão. Para isso, utilizou-se a ferramenta computacional, rede neural artificial. Ademais, o trabalho está organizado em fundamentação teórica, discussão dos resultados e a conclusão.

## II. FUNDAMENTAÇÃO TEÓRICA

A fundamentação teórica está dividida em tópicos abrangendo os seguintes temas: Distúrbios do sistema elétrico (elevação de tensão, afundamento de tensão e transitório) e rede neural artificial.

### A. Distúrbios do sistema elétrico

É notório que no sistema elétrico, pode-se ocorrer vários tipos de distúrbios, porém esse trabalho teve ênfase em elevação de tensão, afundamento de tensão e transitório oscilatório.

#### A1. Elevação de tensão

Para essa categoria, tem-se elevação temporária de tensão, em que se tem um valor eficaz da tensão superior a 1,1 pu da tensão nominal, durante um intervalo de tempo superior a três segundos e inferior a um minuto. Já a elevação momentânea de tensão é referente a um intervalo de tempo com duração superior ou igual a um ciclo e inferior ou igual a três segundos [6].

#### A2. Afundamento de tensão

O afundamento de tensão pode ser temporário ou momentâneo, sendo a duração similar às duas categorias da elevação de tensão, diferindo na intensidade, em que se tem um valor de tensão eficaz superior ou igual a 0,1 pu e inferior a 0,9 pu [6].

#### A2. Transitório

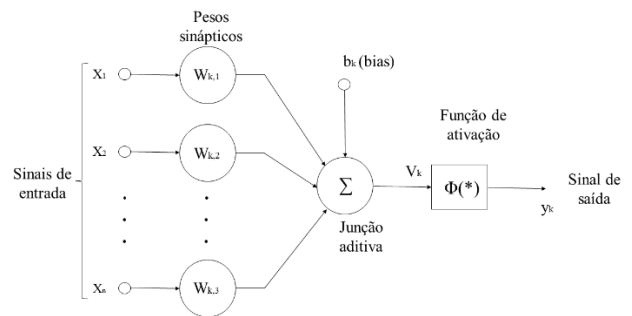
Transitório é uma variação rápida da tensão e corrente causada por exemplo, por um chaveamento ou mudanças bruscas de estado. Esse distúrbio pode ser classificado de duas formas: impulsivo e oscilatório. O primeiro é uma variação súbita e unidirecional da tensão ou corrente, porém são amortecidos rapidamente em função da alta frequência; um exemplo é descarga atmosférica. Já o transitório oscilatório apresenta valores de polaridade positivas e negativas de tensão e/ou corrente, podendo ser de alta, média ou baixa frequência.

### B. Rede Neural Artificial

As redes neurais são compostas de elementos simples operando em paralelo, inspirando-se no sistema nervoso humano já que ambos se baseiam em diversas conexões entre os elementos, que adquirem conhecimento por meio da experiência [7].

A Figura 1, ilustra um neurônio, no qual pode ser observado um conjunto de sinapses ou elos de conexão, cada uma caracterizada por um peso. Especificamente, um sinal  $x_j$  na entrada da sinapse  $j$  conectada ao neurônio  $k$  é multiplicada pelo peso sináptico  $w_{kj}$ . A outra etapa consiste em um combinador linear, ou seja, a soma dos sinais de entrada, ponderados pelas respectivas sinapses do neurônio. Por fim, tem-se a função de ativação para restringir a amplitude da saída, podendo ser um intervalo unitário fechado  $[0, 1]$  ou alternativamente  $[-1, 1]$  [7].

Figura 1: Modelo não-linear de um neurônio.



Portanto, pode-se expressar o neurônio visualizado na Figura 1 a partir de termos matemáticos, como demonstrado nas Equação (1) e (2).

$$v_k = \sum_{k=1}^m w_{kj} x_j \quad (1)$$

$$y_k = \varphi(v_k + b_k) \quad (2)$$

Onde  $b_k$  é o bias, podendo ser um valor positivo ou negativo, influenciando na relação entre o campo local induzido, ou seja, o potencial de ativação  $v_k$  do neurônio  $k$  e a saída do combinador linear [7].

Além disso, pode-se afirmar que a rede é composta por camadas, sendo a primeira de entrada, seguida das intermediárias ou ocultas que é onde é realizado o processamento através de conexões ponderadas, porém utilizam-se geralmente até duas camadas ocultas, e por fim, tem-se a camada de saída.

A arquitetura da rede neural pode variar a depender do problema, podendo ser uma rede alimentada adiante com camada única, que é o modelo mais simples em que se tem a camada de entrada de nós de fonte que se projeta sobre uma camada de saída de neurônios, mas não vice-versa. Além dela, tem-se as alimentadas diretamente com múltiplas camadas que apresenta uma ou mais camadas ocultas, apresentando a vantagem de que essa camada oculta irá intervir entre a camada externa e a saída da rede de uma maneira útil, pois torna a rede capaz de extrair características de ordem elevada, sendo mais utilizada quando a camada de entrada é grande. E por fim, tem-se as redes recorrentes que diferem de uma alimentada adiante por ter pelo menos um laço de realimentação [7]. Para a utilização na classificação de distúrbios do sistema elétrico escolhe-se a alimentada adiante multicamadas pois ela é capaz de reconhecer padrões através de uma regra de aprendizagem supervisionada, ficando

conhecida como *perceptron*. Para que ela reconheça esses padrões, ela deve ser treinada, adquirindo conhecimento, ajustando assim os pesos das conexões sinápticas a cada iteração, para que o erro seja cada vez menor e a saída torne-se cada vez mais próxima da desejada [8].

### III. METODOLOGIA

A primeira etapa consistiu na aquisição dos dados, sendo que para a obtenção de transitórios utilizou um modelo simples de um gerador síncrono conectado a uma carga de  $1.10^6 W$ , e após um instante de tempo, é inserida banco de capacitor. Essa situação é comum em indústrias, por exemplo, quando se deseja elevar o fator de potência para valores superiores a 0,92, que é o valor mínimo exigido pelas normas de concessionárias para que as indústrias não sejam penalizadas. Nas Figuras 2 e 3, pode-se observar o gerador síncrono e o banco de capacitor em paralelo com a carga. Vale ressaltar que a simulação não representa uma situação comumente observada na prática, por causa da proximidade do banco com a geração, porém optou-se na sua escolha em função da sua simplicidade, além de que a ênfase está voltada para a aquisição de dados com comportamento transitório a fim de utilizá-los para o treinamento da rede neural.

Figura 2: Gerador síncrono.


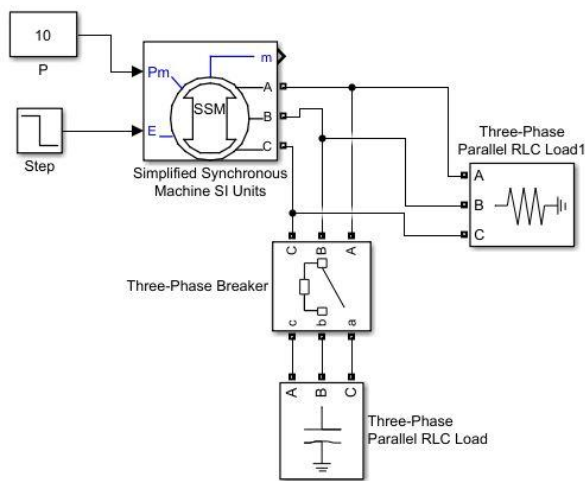



Figura 3: Carga e banco de capacitor.



Para o treinamento da rede, é necessária uma grande quantidade de dados, então simulou-se diversas possibilidades de potência reativa capacitiva no banco de capacitor, obtendo


cinco diferentes possibilidades de transitórios. Vale ressaltar que os transitórios obtidos no *simulink* não apresentaram uma oscilação elevada, então acrescentou uma soma de senóides de diferentes frequências no momento do chaveamento, resultando, por exemplo, na Figura 4.

Figura 4: Transitório



Com relação ao conjunto de dados para o treinamento referente a sobretensão, utilizou-se um o *software* MATLAB para gerar nove vetores com 360 valores de tensão superior a 1,1 pu, e o mesmo foi feito para o afundamento de tensão só que se gerou valores entre 0,1 e 0,9 pu.

Figura 5: Sobretensão.



E por fim, gerou-se dois conjuntos de dados para o sistema sem a apresentação de distúrbios. Nas Figuras 5 e 6, tem-se exemplo de sobretensão e subtensão utilizados para o treinamento e, na Tabela I, tem-se cada situação com a quantidade de conjuntos de dados, respectivamente.

Figura 6: Subtensão.




Tabela 1: Conjunto de dados

Situação	Conjunto de dados
Normal	2
Transitório	5
Sobretensão	9
Subtensão	9

A saída da rede era composta de 4 vetores, sendo cada um associado a uma situação do sistema elétrico, como observado na Tabela II.

Tabela 2: Saída da rede neural

Situação	Vetor de saída
Normal	[1 0 0 0]
Transitório	[0 1 0 0]
Sobretensão	[0 0 1 0]
Subtensão	[0 0 0 1]

Para o treinamento da rede neural, utilizou a função do MATLAB, *nprtool*, sendo o algoritmo de otimização utilizado, o gradiente conjugado escalonado que é o padrão para a função escolhida. Essa metodologia evita o elevado esforço computacional ocasionado pela busca unidimensional para a determinação da taxa de aprendizagem, o que resultaria em um grande número de avaliações da função ou de sua derivada.

Além disso, é importante a escolha da quantidade de neurônios na camada oculta, pois a escolha de um número abaixo do necessário pode resultar em baixa eficiência na classificação, enquanto que escolher além do esperado resulta em *overfitting*, ocorrendo um esforço computacional desnecessário.

#### IV. RESULTADOS E DISCUSSÕES


Em função da utilização de poucos dados para o treinamento e para evitar o *overfitting*, utilizou-se apenas 5 neurônios na camada oculta. A separação dos dados para treino, validação e teste pode ser observada na Tabela III.

Tabela 3: Treinamento da Rede Neural

Treinamento	Quantidade de dados
Treino	80%
Validação	10%
Teste	10%

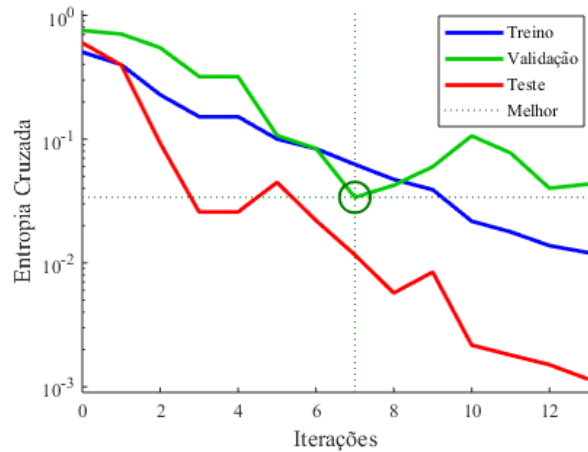
Portanto, utilizando o *toolbox* do MATLAB, tem-se a Figura 7, em que se pode observar 360 características de cada vetor de tensão, ademais, a presença de 5 neurônios na camada oculta (*Hidden layer*), como já foi citado, e na camada saída, 4 classes.

Figura 7: Toolbox rede neural.



A avaliação da rede neural baseia-se na entropia cruzada que interpreta o sinal de treinamento e as saídas da rede como probabilidades e o algoritmo minimiza a diferença entre estas probabilidades [9]. Na Figura 8, pode-se observar as iterações com entropia cruzada para o treino, validação e teste, vale ressaltar que o menor erro para a validação foi na sétima iteração com valor de 0,033874. Além disso, observa-se que o teste e o treino apresentaram decaimento com o aumento das iterações.

Figura 8: Entropia Cruzada.



Já na Figura 9, tem-se o histograma referente ao erro relacionado com o alvo que se deseja e as saídas. Pode-se observar que o treino e validação apresentaram mais valores de erro similares a -0,01017, enquanto que o teste apresentou significância no erro em -0,01017 e 0,0535, sendo valores satisfatórios para o treinamento da rede neural, já que o resultado foi inferior a  $10^{-1}$ .

Após o treinamento da rede, pode-se utilizar novos dados para verificar a eficiência da rede neural artificial, utilizou-se um conjunto de quarenta dados, sendo estes dez para cada classe, sobretensão, subtensão, transitório e tensão sem a presença de distúrbio. E, na Tabela IV, pode-se observar o índice de acerto, além da média total de acertos.

Figura 9: Histograma do erro.

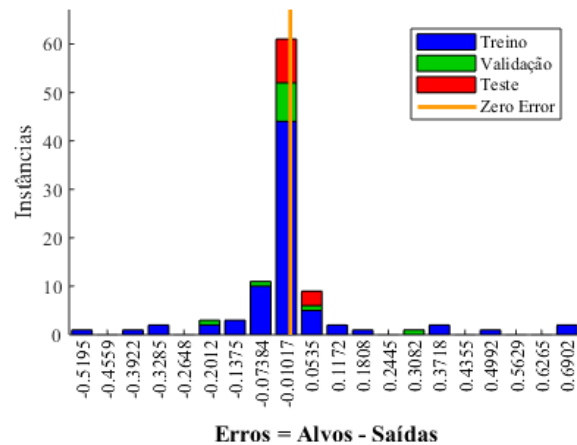


Tabela 4: Índice de acerto

Situação	Índice de acerto
Normal	100%
Transitório	90%
Sobretensão	100%
Subtensão	100%
Média	97,5%

## V. CONCLUSÃO

Pode-se afirmar, portanto, que a aplicação da rede neural artificial apresentou elevada eficiência na classificação, apresentando resultados similares às das referências [4] e [5], apesar de que para esse trabalho utilizou-se um sistema mais simples, porém foram utilizados uma quantidade inferior de dados.

Vale ressaltar também que durante a etapa de utilização de novos dados, a classificação do transitório apresentou um menor índice de acerto quando comparado com casos de sobretensão, subtensão e sistema sem distúrbios. Isso se deve ao fato de que o transitório apresenta uma oscilação grande, e com a utilização de poucos dados, a rede neural treinada tornou-se propícia a erro, dependendo do novo dado que fosse inserido nela.

Além disso, pode-se afirmar que para trabalhos futuros, pode-se utilizar outros softwares para simular o transitório que apresentam melhor eficiência de simulação como o *ATPDraw*. Outra possibilidade, é a utilização de um banco de dados reais para o treinamento da rede, e em seguida, aplicar para um novo conjunto de dados. E por fim, também pode-se utilizar outros problemas da qualidade da energia para a classificação como os harmônicos, efeito *notch*.

## REFERÊNCIAS

- [1] Heydt, G. T. Electric power quality: a tutorial introduction, IEEE Comput Applcat Power. Pp. 15-19, 1998.
- [2] Oleskovicz, M. Apostila de Qualidade de Energia. Escola de Engenharia de São Carlos, 2004.
- [3] Agência Nacional de Energia Elétrica – ANEEL; PRODIT- Módulo 8. Disponível em: <<http://www.aneel.gov.br/modulo-8>> Acesso em 19 de Junho de 2018.
- [4] Ferreira, D. D.; Marques, C. A. G; Cerqueira, A. S.; Duque, C. A; Ribeiro, M. V. “Sistema Automático de Detecção e Classificação de Distúrbios Elétricos em Qualidade da Energia Elétrica. Controle & Automação. Vol. 20, pp. 53-62, 2008.
- [5] Cândido, C. K. S. S. Classificação de distúrbios na rede elétrica usando redes neurais e wavelets. Tese de doutorado – Universidade Federal do Rio Grande do Norte, Natal, 2008.
- [6] Agência Nacional de Energia Elétrica – ANEEL; “Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST, Módulo 8 – Qualidade da Energia Elétrica.
- [7] Haykin, S. “Redes Neurais: Princípios e prática”. Porto Alegre - RS:Bookman, 2001.
- [8] Dutra, V. P. Redes Neurais e o Reconhecimento de padrões de texto. Universidade de São Francisco, 2011.
- [9] Engel, P. M. Redes Neurais, Métodos Híbridos de Aprendizagem. A rede KBANN. Notas de Aula. Universidade Federal do Rio Grande do Sul.