

## Identificação de Processos de Ensaios de Alta Tensão Através de Redes Neurais Artificiais

André Nunes de Souza, Ivan Nunes da Silva e Mário Eduardo Bordon

Universidade Estadual Paulista – UNESP

Departamento de Engenharia Elétrica

CP 473, CEP 17033-360, Bauru - SP

e-mail: andrejau@bauru.unesp.br

### Abstract

*This paper demonstrates that artificial neural networks can be used effectively for the identification and estimation of parameters related to analysis and design of high-voltage substations. More specifically, the neural networks are used to compute electrical field intensity and critical disruptive voltage in substations taking into account several atmospheric and structural factors, such as pressure, temperature, humidity, distance between phases, height of bus bars, and wave forms. Simulation examples of tests are presented to validate the proposed approach. The results that were obtained by experimental evidences and numerical simulations allowed the proposition of new rules about the specification of substations.*

### 1. Introdução

O Brasil devido a sua grande extensão territorial e estar próximo ao Equador Geográfico, é um dos países de maior incidência de descargas atmosféricas (raios), cerca de 100 milhões de descargas anualmente.

Os sistemas de energia elétrica, que a cada dia aumentam em tamanho e complexidade, são muito vulneráveis as descargas atmosféricas, e a credibilidade destes sistemas ainda depende muito da eficiência da proteção contra descargas atmosféricas e do conhecimento dos processos que envolvem estas descargas.

Diante deste fato, um crescente interesse está sendo dispensado para identificar com precisão o comportamento destas descargas em linhas de transmissões, subestações e edificações.

Na prática, a simulação artificial das descargas atmosféricas é realizada em laboratórios oficiais de alta tensão, mediante o emprego de ensaios normalizados.

O ensaio de alta tensão que representa o comportamento das descargas atmosféricas é denominado de Ensaio de Impulso Atmosférico, onde a forma de onda, que representa a duração do fenômeno, é especificada pelo tempo de crescimento (frente) e pelo tempo de valor médio (cauda) [1].

O objetivo de estudar as descargas atmosféricas é compreender o efeito físico destas descargas em instalações elétricas ou em alguns de seus componentes individuais que fazem parte do sistema elétrico.

Como os processos físicos envolvidos na formação das descargas compreendem fenômenos aleatórios e não determinísticos, é necessário analisar o mesmo de forma probabilística.

A Figura 1 apresenta a função de probabilidade da descarga elétrica  $P(v)$ , identificando a tensão crítica ( $V_{50\%}$ ) e a tensão suportável ( $V_{10\%}$ ).

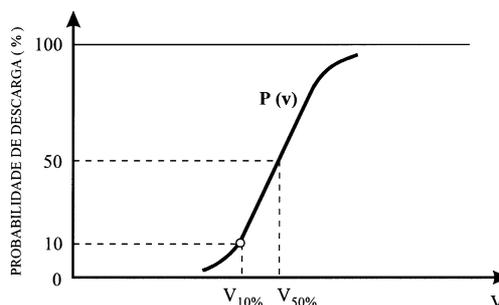


Figura 1. Função de Probabilidade

Usualmente, as normas técnicas de alta tensão recomendam a aplicação de um certo número de aplicações de tensão no objeto sob ensaio, consumindo assim, um grande tempo de utilização do laboratório, o qual influi diretamente no custo final do projeto.

Existem vários fatores que influenciam na intensidade de uma descarga atmosférica, tais como, forma de onda, polaridade, configuração de campo elétrico, ionização do solo, temperatura, pressão entre outras. Sendo assim, muito difícil estabelecer e visualizar um relacionamento destas grandezas através de ferramentas clássicas.

Neste contexto, a identificação de processos de alta tensão através das Redes Neurais Artificiais (RNA) pode ser visto como uma ferramenta que fornece alternativas às metodologias convencionais de ensaios de alta tensão, gerando resultados motivadores, principalmente devido as características intrínsecas da técnica, como a capacidade de generalização e integração com outras ferramentas computacionais.

A habilidade de Redes Neurais Artificiais (RNA) em mapear funções não-lineares complexas as tornam uma ferramenta atrativa para identificar e estimar modelos de processos de alta tensão.

Uma rede neural artificial é um sistema dinâmico que consiste de vários elementos processadores simples que exploram arquiteturas de computação inerentemente paralelas e adaptativas

Os principais benefícios em utilizar RNA em processos de alta tensão são:

- i-) habilidade de aprender e de generalizar conceitos;
- ii-) facilidade de implementação em hardware;
- iii-) capacidade de mapear sistemas complexos sem necessidade de conhecimento sobre eventuais modelos matemáticos que descrevem o seu comportamento;
- iv-) possibilidade de redução do tempo envolvido com testes em laboratórios.

Este artigo é organizado como segue. Na Seção 2, um histórico sucinto sobre as pesquisas relacionadas à identificação de processos de alta-tensão é apresentada. Na Seção 3, os procedimentos experimentais utilizados em laboratórios são descritos. A Seção 4 fornece os resultados experimentais obtidos em laboratório e que serão utilizados no treinamento das redes neurais. A Seção 5 fornece uma introdução do processo de identificação com redes neurais artificiais. Na Seção 6, resultados de simulações são apresentados para validar a abordagem proposta. Finalmente, as conclusões e o pontos chaves deste artigo são apresentados na Seção 7.

## 2. Histórico

Por muitos anos, vários estudos foram realizados com a premissa de descrever os principais aspectos relacionados com a formação das descargas, alguns considerando simplesmente dados estatísticos, outros efetuando medições em campo, e por fim, estudos investigando a física natural do fenômeno [2]-[4].

A maioria das pesquisas desenvolvidas em laboratórios de alta tensão, tiveram como tônica, o estudo e identificação de processos que influenciam no comportamento da descarga atmosférica no ar.

Os equacionamentos físicos e matemáticos foram elaborados a partir da teoria do desenvolvimento da descarga piloto [5]-[6].

Estes trabalhos foram fundamentados na construção de curvas (tensão x tempo), obtidas nos ensaios de impulso atmosférico com ondas padronizadas e não padronizadas.

A expressão (1) apresenta uma formulação generalizada para este critério:

$$I = \int_{t_0}^{t_b} (U(t) - U_0)^n dt \quad (1)$$

onde:

$U(t)$  é a tensão aplicada em função de  $t$ ;

$t_b$  é o tempo de interrupção;

$t_0$  é o tempo entre  $U(t)$  que excede o primeiro  $U_0$ ; e

$I$ ,  $U_0$  e 'n' são constantes predefinidas.

Atualmente, tem havido uma preocupação muito acentuada no sentido de identificar exatamente os processos que envolvem a formação das descargas elétricas, tendo em vista os expressivos avanços ocorridos na arte de modelar o fenômeno, tanto do ponto de vista analítico como numérico, e que estão permitindo novos estudos computacionais [7].

## 3. Procedimentos experimentais

Os procedimentos e especificações gerais relativos aos ensaios de alta tensão, encontram-se descritos na série de normas vigentes da NBR 6936-1992.

Para realizar a investigação experimental e posteriormente identificar os processos que envolvem o desenvolvimento das descargas, foi adotado o Ensaio de Impulso Atmosférico em barramentos paralelos previamente escolhidos, que representam aproximadamente 80% dos barramentos instalados nas subestações de energia elétrica [8].

A Figura 2 apresenta a topologia dos barramentos ensaiados (vista superior), considerando várias distâncias entre as fases e também a altura até o solo.

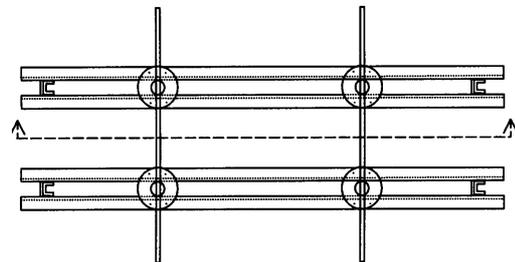


Figura 2. Topologia dos Barramentos Paralelos

Nos barramentos foram aplicados impulsos de polaridade positiva em um lado do barramento sendo o outro lado aterrado juntamente com a base.

A Figura 3 apresenta os parâmetros que foram considerados na medição da forma de onda.

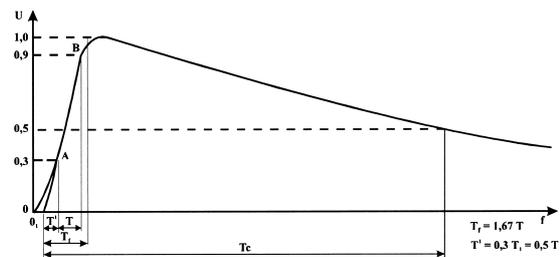


Figura 3. Onda Normalizada 1,2X50µs.

onde:

$O_1$  é a origem virtual, o instante que precede o tempo correspondente ao ponto A de  $0,3 T_1$ ;

$T_f$  é o tempo de frente, parâmetro definido como 1,67 vezes o intervalo de tempo T entre os instantes 30% e 90%;

$T_c$  é o tempo até o meio valor (cauda).

A tensão suportável ( $V_{10\%}$ ) que representa o valor de tensão com probabilidade de 10% de ocorrer a descarga disruptiva, foi calculada de acordo com a expressão (2):

$$V_{10\%} = V_{50\%} (1 - 1,3\sigma) \quad (2)$$

onde:

$V_{10\%}$  é a tensão suportável;

$V_{50\%}$  é a tensão disruptiva experimental; e

$\sigma$  = desvio padrão (3%).

Para a geração artificial das descargas atmosféricas foi utilizado um gerador de impulso com capacidade de três milhões de Volts (3 MV), que consiste basicamente de uma combinação de capacitores, resistores e centelhadores, conforme apresentado na Figura 3.

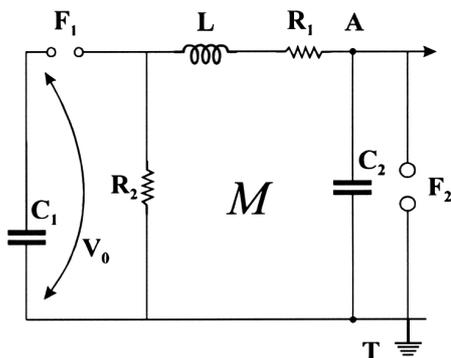


Figura 4. Circuito de Ensaio no Laboratório

onde:

$C_1$  = capacitor de impulso

$C_2$  = capacitor de carga (corpo de prova)

$R_1$  = resistor de frente

$R_2$  = resistor de cauda

M = malha de descarga

L = indutância própria da malha M

$F_1$  = centelhador de excitação

$F_2$  = centelhador de medição (divisor de tensão)

$V_0$  = tensão no capacitor  $C_1$

#### 4. Resultados experimentais

As Figuras 5, 6 e 7 apresentam um resumo dos resultados experimentais, referentes às várias topologias ensaiadas no laboratório de alta tensão. Estes resultados foram posteriormente utilizados para a realização do treinamento das redes neurais artificiais.

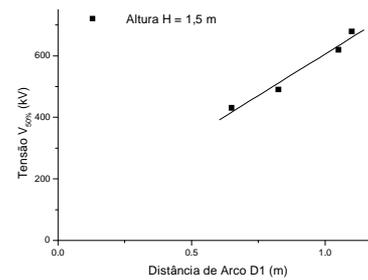


Figura 5. Altura do Barramento ao Solo de 1,5m

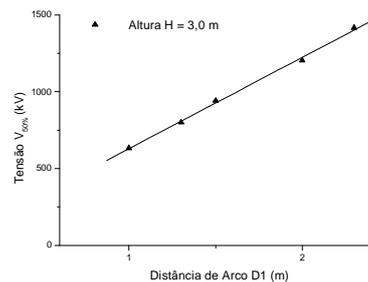


Figura 6. Altura do Barramento ao Solo de 3,0m

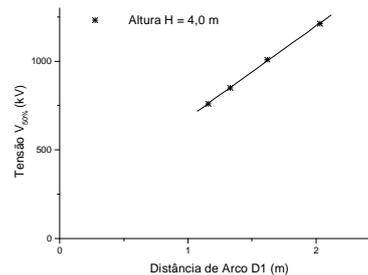


Figura 7. Altura do Barramento ao Solo de 4,0m

Observando as Figuras 5, 6 e 7 constata-se uma linearidade dos pontos ensaiados no laboratório de alta tensão ( $V_{50\%}$ ) que é uma das características das descargas atmosféricas no ar. Os resultados experimentais foram corrigidos para as condições atmosféricas do local: pressão atmosférica 101,3 kPa, temperatura ambiente  $20,0^{\circ}\text{C}$  e umidade absoluta do ar  $11,0 \text{ g/m}^3$ . O ajuste destes valores de  $V_{50\%}$  foi feito utilizando o método dos mínimos quadrados.

Os resultados obtidos confirmaram o sucesso da metodologia experimental. Assim sendo, estes resultados possibilitaram um bom conjunto de treinamento para a rede neural artificial.

#### 5. Identificação com redes neurais artificiais

A agilização da análise e/ou projeto de processos relacionados à engenharia é uma das principais motivações em utilizar redes neurais artificiais. A habilidade de RNA em mapear relacionamentos

funcionais as tornam uma abordagem atrativa que pode ser utilizada em diversos tipos de problemas [9]. Esta característica é particularmente importante quando o relacionamento é não-linear e/ou não bem definido, tornando assim difícil a sua modelagem por técnicas convencionais.

Neste artigo, redes neurais do tipo perceptron são utilizadas para mapear os relacionamentos entre as diversas variáveis associadas com o processo de especificação (identificação) de subestações de energia elétrica

A identificação de sistemas está relacionada com o processo de estimar os parâmetros de um modelo, caracterizando o comportamento de um sistema físico, a partir de informações (medidas) obtidas sobre o respectivo sistema. O processo de identificação consiste usualmente de dois estágios: seleção do modelo e estimação de seus parâmetros.

Na abordagem por redes neurais, a seleção da arquitetura da rede corresponde ao estágio de seleção do modelo, enquanto que o algoritmo de treinamento utilizado para ajustar os pesos da rede corresponde ao estágio de estimação dos parâmetros.

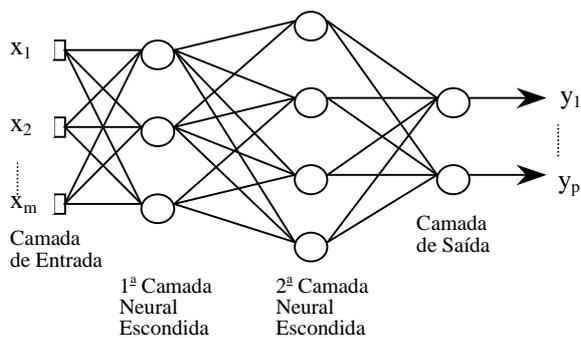


Figura 8. Rede Perceptron Multicamadas

Uma rede perceptron típica, com ‘m’ entradas e ‘p’ saídas, é ilustrada na Figura 8, onde cada círculo representa um neurônio artificial. A arquitetura feedforward da rede perceptron multicamadas implica que o fluxo de informações é executado em um única direção, não possuindo retroalimentação entre os neurônios. A camada inicial onde as informações são introduzidas na rede é denominada camada de entrada; enquanto a última camada, responsável pela resposta da rede, é denominada camada de saída. Todas as outras camadas intermediárias são chamadas de camadas escondidas.

Tem sido mostrado na literatura que redes perceptrons com apenas uma camada escondida é capaz de mapear qualquer função não-linear que relacione variáveis de estradas e saídas [9]. Portanto, em todas as simulações realizadas neste artigo foram utilizadas redes perceptron com uma única camada escondida.

O treinamento da rede, responsável pelo ajuste dos pesos, foi feito utilizando o algoritmo de Levenberg-Marquardt [10].

## 6. Resultados de simulação

Nesta seção, apresenta-se alguns resultados de simulações para a identificação de parâmetros relacionados aos processos de alta tensão descrito nas seções anteriores.

A arquitetura geral do sistema neural é mostrado na Figura 10. Esta arquitetura é composta por duas redes perceptrons multicamadas.

A primeira rede (RNA-1) é responsável pela computação da tensão disruptiva crítica ( $V_{50\%}$ ). Os dados de treinamento da RNA-1 foram diretamente obtidos a partir de valores experimentais obtidos em laboratórios de alta-tensão. Estes dados de treinamento utilizaram aproximadamente 700 valores de  $V_{50\%}$ .

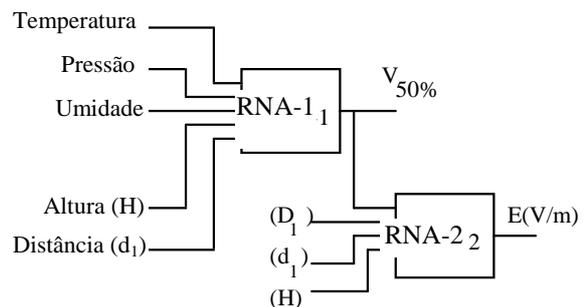
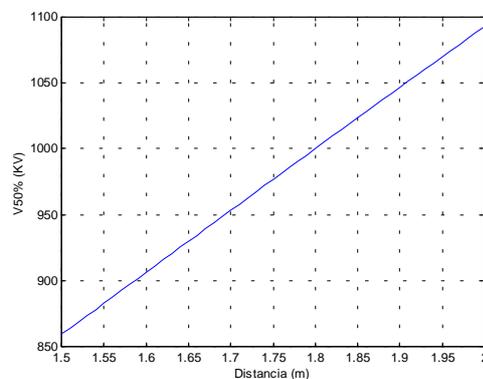


Figura 10. Arquitetura Geral da RNA

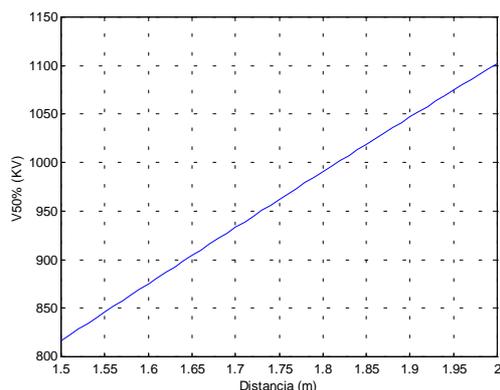
Conforme observado na Figura 10, a RNA-1 possui como entradas alguns fatores atmosféricos tais como: temperatura, pressão e umidade. A altura e a distância entre os barramentos foram os fatores estruturais incluídos nesta topologia.

A Figura 11 mostra a variação de  $V_{50\%}$  computado pela RNA-1 em função de diferentes temperaturas, enquanto a Figura 12 ilustra a variação de  $V_{50\%}$  para dois valores distintos de pressão atmosférica (701 mmHg e 703 mmHg).

É importante observar que todos estes valores foram generalizados pela rede RNA-1 a partir dos dados de treinamento. Sendo assim, a rede conseguiu estimar valores de  $V_{50\%}$  que são diferentes daqueles utilizados em seu treinamento.



(a) Temperatura de 21.4°C



(b) Temperatura de 19°C

Figura 11. Variação de  $V_{50\%}$  Com a Temperatura

A segunda rede (RNA-2) é responsável pela computação da intensidade do campo elétrico entre os barramentos. Nesta rede, os dados de treinamento foram obtidos pelo Método dos Elementos Finitos. Como observado na Figura 10, a saída da RNA-1 é fornecida como parâmetro de entrada para a RNA-2. Assim, todos os fatores atmosféricos e estruturais são também levados em consideração para computar a intensidade do campo elétrico.

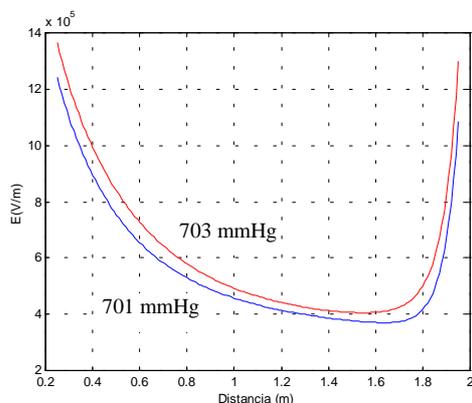


Figura 12. Variação de  $V_{50\%}$  Com a Pressão

A Figura 13 mostra os resultados de simulação computados pela RNA-2 para duas situações. Para a primeira situação, considerou-se barramentos com  $d_1=1.75\text{m}$  e  $H=4\text{m}$ , sendo aplicada uma tensão de 800 kV em seus terminais. A segunda situação considerou barramentos com  $d_1=2.00\text{m}$  e  $H=4\text{m}$ , onde uma tensão de 1000 kV foi aplicada. A intensidade do campo elétrico computada pela rede próximo ao barramento é  $9.7 \times 10^5 \text{ V/m}$  para o arranjo da primeira situação e  $1.19 \times 10^5 \text{ V/m}$  para a segunda situação. Estes resultados não excedem  $3 \times 10^6 \text{ V/m}$ , que é o valor máximo admissível no ar para que não aconteça descargas elétricas.

Estes resultados foram validados pelos ensaios experimentais, onde  $V_{10\%}$  representa a tensão com 10% de probabilidade de ocorrência de descarga elétrica.

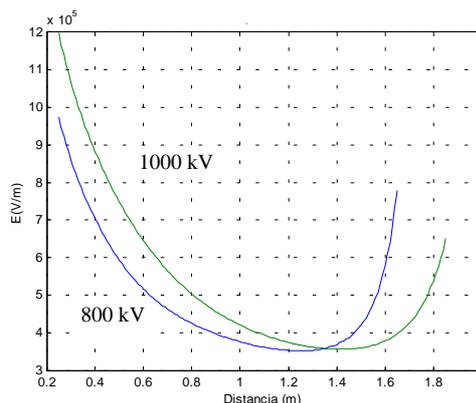


Figura 13. Intensidade do Campo Elétrico ao Longo do Barramento

Assim, a distância entre os barramentos pode ser melhor definida sem diminuir a segurança do sistema.

## 7. Conclusões

Este artigo apresentou uma nova metodologia para projetar subestações através de redes neurais artificiais. Os resultados de simulações podem ser úteis para elaboração de novos critérios, mais consistentes e adequados, para o projeto de subestações.

Redes neurais artificiais foram desenvolvidas com o objetivo de identificar alguns processos de alta tensão.

O treinamento das redes neurais a partir de dados experimentais tem sido feito através do algoritmo de Levenberg-Marquardt, e tem como parâmetros de entrada vários fatores atmosféricos e estruturais. Após o processo de treinamento, a rede é capaz de generalizar novas entradas que não foram simuladas em laboratório. Esta característica permite reduzir o tempo gasto com simulações em laboratórios de alta tensão. Estes resultados confirmam que problemas envolvendo a identificação de processos de alta tensão podem ser efetivamente mapeados através de redes neurais artificiais.

## Agradecimentos

Os autores expressam agradecimentos à FAPESP pelo suporte financeiro (Processo No. 98/08480-0).

## Referências

- [1] ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. Técnicas de ensaios elétricos de alta tensão, Rio de Janeiro, 1992 ( NBR 6936 ).
- [2] M. A. Uman. *The Lightning Discharge*. Academic Press, New York, 1987.

- [3] G. Diendorfer and M. A Uman. "An improved return stroke model with specified channel-base current", *J. Geophys. Res.*, vol. 95, pp. 617-630, 1990.
- [4] C. A. Nucci and F. Rachidi. "Experimental validation of a modification to the transmission line model for LEMP calculations", *Proc. of 8th EMC Symposium*, Zurich, pp. 473-469, 1989.
- [5] L. Deller; and E. Garbagnati, "Lightning stroke simulation by means of the leader progression model, Part I: Description of the model and evaluation of free standing structures", *ibid*, pp. 2009-2022.
- [6] G. Diendorfer; and M.A. Uman, "An improved return stroke model with specified channel-base current" *JGR*, vol. 95, no. D9, pp. 13621-13644, 1990.
- [7] H. W. Dommel. *EMTP Theory book*. Microtran Power System Analysis Corp., Vancouver, Canada, 1996.
- [8] A. N. Souza and P. S. Ribeiro. "Electrical distances dimensioning in distribution systems concerning to atmospheric discharges", *IV International Seminar on Lightning Protection*, São Paulo, Brazil, pp. 57-61, 1997.
- [9] S. Haykin. *Neural Networks - A Comprehensive Foundation*. Macmillan, New York, 1994.
- [10] M. T. Hagan and M. B. Menhaj. "Training feedforward networks with the Marquardt algorithm", *IEEE Trans. on Neural Networks*, vol. 5, no. 6, pp. 989-993, 1994.