



XIX Seminário Nacional de Distribuição de Energia Elétrica

SENDI 2010 – 22 a 26 de novembro

São Paulo - SP - Brasil

Análise do Desempenho de Alimentadores de Redes de Distribuição de Eletricidade Frente à Incidência de Descargas Atmosféricas, usando Redes Neurais Artificiais

Thales Terrola e Lopes	Gilson Santos Junior	Antonio Carlos Pereira	Luis Pereira Calôba
COPPE/UFRJ	ENELTEC	LIGHT SERVIÇOS DE ELETRICIDADE S/A	COPPE/UFRJ
thales.lopes@eletrobras.com	gsantos@eneltec.com.br	antonio.pereira@light.com.br	caloba@lps.ufrj.br

Palavras-chave

Descargas Atmosféricas
Desligamentos
Redes Neurais Artificiais
Retro-propagação do Erro

Resumo

O desenvolvimento de metodologias baseadas na aplicação de dados de Sistemas de Detecção e Localização de Descargas Atmosféricas vem contribuir para a melhoria operacional e suplementa informações para novos projetos. Neste trabalho é descrita a concepção de um sistema de avaliação do desempenho de Linhas de Transmissão (LTs) ou Alimentadores de Redes de Distribuição, submetidas a descargas atmosféricas, considerando a aplicação de Redes Neurais Artificiais (RNAs). Oferecendo uma alternativa ao processo fenomenológico convencional, esta metodologia faz uma abordagem inovadora do problema, ao treinar uma rede neural para identificar descargas atmosféricas responsáveis por desligamentos. A identificação da descarga atmosférica constitui uma informação auxiliar nos projetos de novas linhas, desde que o projetista pode encontrar padrões associados à incidência de descargas atmosféricas, como: tipo e altura da torre, altitude em relação ao nível do mar, distância na cadeia de isoladores associados ao tipo de estrutura, impedância de aterramento, entre outros.

1. INTRODUÇÃO

Atualmente, é crescente o interesse no desenvolvimento de metodologias para o processamento dos dados obtidos por Sistemas de Detecção Automática de Descargas Atmosféricas, com o propósito de melhorar o desempenho do sistema de transmissão/distribuição de eletricidade, aumentando a confiabilidade destas redes frente à incidência de descargas atmosféricas.

As descargas atmosféricas incidentes próximas ou diretamente na torre ou linha de transmissão podem ocasionar desligamentos nas mesmas já que correspondem, em geral, às mais severas solicitações às quais o isolamento é submetido, superando sobretensões a frequência industrial e de frequências médias (faixa dos kHz). Um dos efeitos mais importantes a ser avaliado em estudos de linhas de transmissão é a variação dos parâmetros elétricos da LT com a frequência, inclusive a propagação não-

instantânea das ondas eletromagnéticas. As expressões mais comumente utilizadas para o cálculo da impedância longitudinal da linha, expressões de (CARSON, 1926), aplicam-se adequadamente desde poucos Hz até a faixa de 1 ou 2 MHz. É precisamente neste limite superior da faixa mencionada, que a maioria das descargas atmosféricas se encaixa, o que dá origem a questionamentos sobre a validade das expressões de Carson e similares. O cálculo do desempenho elétrico de linhas de transmissão submetidas a descargas atmosféricas não é, em absoluto, trivial, conduzindo em geral a modelagens e expressões complexas. Deste modo, é relativamente comum um tratamento expedito do problema, com o uso de fórmulas muito simplificadas e gráficos padronizados, o que acaba por conduzir a apenas uma estimativa do problema, muitas vezes grosseira.

A partir das dificuldades e imprecisões verificadas, surgiu a motivação de se proceder ao estudo de desligamentos em LTs, em função de descargas atmosféricas, utilizando a técnica de Redes Neurais Artificiais (RNAs). Oferecendo uma alternativa ao processo fenomenológico convencional, esta metodologia faz uma abordagem inovadora do problema, ao treinar uma rede neural para identificar descargas causadoras ou não de desligamentos em linhas, sem recorrer aos complexos cálculos de ondas trafegantes (CARSON, 1926).

Redes Neurais Artificiais (RNA) podem ser aplicadas em problemas de regressão, classificação e compactação de dados, como também em situações onde existem interações não-lineares entre as variáveis dependentes e as independentes. As redes neurais artificiais, principalmente as redes neurais do tipo *perceptron* de múltiplas camadas, tem sido largamente utilizadas como ferramenta de solução em diversos problemas de engenharia elétrica de potência, como se observa em (KHOTANZAD, 1996), (KHOTANZAD, 1997), (MANSOUR, 1997), (DE AQUINO, 1999), (BRETAS, 2003), (SEGATTO, 2006). A capacidade de aprender através de exemplos e de generalizar a informação aprendida são os grandes atrativos para a escolha de uma solução neural em problemas diversos. A generalização associa-se à capacidade da rede de aprender através de um conjunto de exemplos, representativo do problema que se pretende estudar, e, posteriormente, fornecer respostas coerentes para dados não apresentados anteriormente.

Neste trabalho considera-se uma rede neural do tipo *perceptron* de múltiplas camadas (*feedforward*), com algoritmo de treinamento por retro-propagação do erro (*backpropagation*). O conjunto de treinamento utiliza como dados de entrada a distância da incidência da descarga atmosférica a LT ou alimentador, intensidade de pico de corrente da descarga atmosférica, altitude da incidência da descarga atmosférica e polaridade da mesma. A saída da rede neural é um classificador, indicando se a descarga atmosférica foi à responsável pelo desligamento da linha de transmissão.

O presente trabalho foi resultado de um projeto de Pesquisa e Desenvolvimento, realizado pela Light Serviços de Energia, em parceria com ENELTEC/IBRATE e a COPPE/UFRJ, no período de 07/2005 a 11/2007. Para o desenvolvimento da ferramenta de análise, a concessionária de energia Light S.A. disponibilizou o seguinte conjunto de dados:

- Registro mensal da incidência de descargas atmosféricas na área de concessão da Light, no período de 10/2000 a 08/2005, fornecido pelo aplicativo SisRaios (BENETI, 2002). Este aplicativo é empregado na identificação e visualização de descargas atmosféricas dentro da rede RINDAT (Rede Integrada Nacional de Detecção de Descargas Atmosféricas), desenvolvido pelo Simepar (BENETI, 2002).
- Relatório de desligamentos nas linhas de transmissão da Light para o mesmo período de dados fornecido pelo aplicativo SisRaios.
- Documentação de projeto do alimentador Ilha dos Pombos - São José - Rio da Cidade (ILHSJ-LTRCO), identificando geograficamente a posição em coordenadas UTM de cada torre da linha e a altitude de localização das mesmas. Este alimentador apresenta uma extensão em campo de 160 km, operando em tensão nominal de 138 kV.

Um aplicativo em linguagem C++ e utilizando a técnica de Modelagem Orientada a Objetos foi

desenvolvido para implementação da metodologia proposta, integrando módulos de pré-seleção de descargas atmosféricas, modelagem da rede neural, visualização gráfica e emissão de relatórios.

A minimização do impacto das descargas atmosféricas é atacada mais efetivamente através medidas preventivas bem embasadas. Assim, a identificação da descarga atmosférica responsável pelo desligamento da linha de transmissão possibilita ao projetista encontrar padrões que identifiquem maiores ou menores probabilidades associadas ao evento. Desta forma, permite-se averiguar o efeito de algumas variáveis no desligamento, como: tipo e altura da torre, altitude da linha em relação ao nível do mar, distâncias das cadeias de isoladores associadas ao tipo de estrutura, impedância de aterramento e características do solo, como resistividade e compactação. Os resultados obtidos durante o projeto são extremamente promissores, indicando a viabilidade do método. Uma baixa disponibilidade de dados e imprecisões nos mesmos pode deteriorar o resultado fornecido pela rede neural, levando a incoerências no processo classificatório.

2. PRÉ-SELEÇÃO DO CONJUNTO DE DESCARGAS ATMOSFÉRICAS

O primeiro passo para a avaliação do desempenho de uma linha frente à incidência de descargas atmosféricas é estabelecer quais descargas, dentre o conjunto mensal de dados disponibilizado pelo aplicativo SisRaios, são relevantes no desempenho do alimentador ILHSJ-LTRCO. Em (SANTIAGO, 1982) é definido que descargas atmosféricas que caem dentro de uma elipse formada com a LT ou alimentador, com o valor do semi-eixo maior da mediana superior a 500 m, na grande maioria dos casos, apresentam influência desprezível sobre a mesma.

A determinação da posição de cada torre do alimentador ILHSJ-LTRCO, assim como todo o seu trajeto em campo, foi levantada com auxílio do aplicativo “Google Earth”. Este fato se fez necessário, pois a Light não dispunha destas informações. As coordenadas esféricas de cada torre, obtidas pelo aplicativo “Google Earth”, foram convertidas em coordenadas cartesianas, Universal Transversa de Mercator (coordenadas UTM), semelhante àquela utilizada para o posicionamento das descargas atmosféricas nos arquivos fornecidos pelo aplicativo SisRaios. Em virtude de possíveis incoerências na determinação do posicionamento das torres, através do aplicativo “Google Earth”, trabalhou-se com um erro adicional de 500 metros, mensurado no semi-eixo maior da mediana da elipse de ação da descarga atmosférica. Assim, se trabalhou com um valor igual a 1000 metros. Esta consideração torna a distância referente ao modelo eletro geométrico (distância de salto) desprezível frente à incerteza do posicionamento das torres no campo:

Para que as descargas atmosféricas sejam classificadas como “relevante” ou “irrelevante” quanto ao seu posicionamento em relação à LT, estas devem estar dentro da elipse com valor de semi-eixo maior de no máximo de 1000 metros.

Uma vez que se adotou o referencial cartesiano UTM para o posicionamento das torres da LT em campo e para o local de incidência de descargas atmosféricas, podemos considerar que cada descarga e cada estrutura terão coordenadas planas, lineares, definidas por pares ordenados (x, y) . A figura 1 mostra a representação de um trecho de linha caracterizado por quatro estruturas a, b, c e d . As linhas que conectam esses pontos indicam os vãos da LT.




Figura 1. Trecho de uma linha de transmissão num sistema de coordenadas UTM.

Tomando como exemplo as estruturas a e b , da Figura 1, suas coordenadas seriam (x_a, y_a) e (x_b, y_b) , respectivamente. O comprimento do vão entre estas estruturas, S , é dado por:

$$S = \left[(x_a - x_b)^2 + (y_a - y_b)^2 \right]^{1/2} \quad (1)$$

O ponto médio do vão tem coordenadas (x_m, y_m) , onde:

$$x_m = \frac{x_a + x_b}{2} \quad (2)$$

$$y_m = \frac{y_a + y_b}{2}$$

Pode-se mostrar que o segmento ab é, na verdade, parte de uma reta (reta-suporte) que tem equação:

$$(y_a - y_b) \cdot x + (x_b - x_a) \cdot y + (y_b \cdot x_a - y_a \cdot x_b) = 0 \quad (3)$$

A expressão acima pode ser reescrita em notação vetorial:

$$[W]^t \cdot \begin{bmatrix} x \\ y \end{bmatrix} + W_0 = 0 \quad (4)$$

$$[W] = \begin{bmatrix} W_x \\ W_y \end{bmatrix}$$

$$W_x = \frac{y_a - y_b}{S}$$

$$W_y = \frac{x_b - x_a}{S}$$

$$W_0 = \frac{y_b \cdot x_a - y_a \cdot x_b}{S}$$

É digno de nota que, além da notação vetorial, a expressão (4) também fez uso da norma de vetores, já que $\|[W]\| = 1$. A notação vetorial em (4) permite escrever facilmente a distância de um ponto p qualquer, $[p]^t = [x_p \quad y_p]$, à reta. Este ponto p qualquer pode ser encarado como uma descarga atmosférica incidente no plano cartesiano (x, y) .

$$d = [W]^t \cdot [p] + W_0 \quad (5)$$

Cabe lembrar que a distância expressa em (5) é medida na direção ortogonal à reta. Outra informação de igual utilidade é a distância, na direção paralela à reta, do ponto p ao ponto médio do segmento ab , d_m . Este valor é dado por:

$$d_m = \left| y_p \cdot W_x - x_p \cdot W_y + \frac{1}{2 \cdot S} \cdot (x_b^2 - x_a^2 + y_b^2 - y_a^2) \right| \quad (6)$$

Calculados os valores de interesse a partir das expressões de (1) a (6), é possível estabelecer um critério de classificação das descargas atmosféricas como “relevante” ou “irrelevante” quanto ao seu posicionamento em relação à LT:

- Para cada descarga atmosférica, calcular a distância ortogonal em todos os segmentos da linha (ab , bc , cd e por aí em diante), conforme (5).
- Calcular a distância d_m para o ponto médio de cada vão, de acordo com (6);

A descarga atmosférica será considerada “relevante” se ambas as condições a seguir forem atendidas.

$$d < d_{crit} \quad (7)$$

$$d_m < \frac{S}{2} + d_{crit}$$

O valor d_{crit} representa o semi-eixo maior da mediana da elipse formada com a LT ou alimentador. Destaca-se que o segundo critério a ser atendido, distância média, foi incluído para prevenir casos como o apresentado na figura 2, onde o ponto p está próximo à reta suporte, mas não ao segmento bc . Deve ficar claro que uma descarga incidente em p não é relevante, pois mesmo estando próximo à reta-suporte de bc (tracejada), está a uma distância considerável do vão bc do segmento de reta.

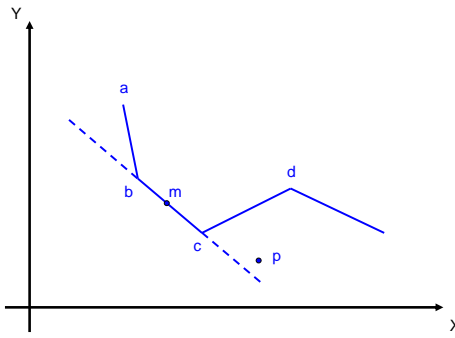


Figura 2. Proximidade do ponto p com a reta-suporte, mas não com o segmento bc .

3. DESENVOLVIMENTO DA REDE NEURAL

Neste trabalho desenvolveu-se uma rede neural artificial (RNA) *feedforward* com algoritmo de treinamento do tipo retro-propagação do erro (*backpropagation*). Uma RNA completa é formada por um conjunto de neurônios dispostos em uma ou mais camadas, conectados por ligações de pesos variados. A rede *feedforward* tem a propagação do sinal para frente, entre neurônios de camadas adjacentes, até a última camada (saída) (HAYKIN, 1999). A primeira camada, ou "camada de entrada", não é composta por neurônios, mas simplesmente pelas conexões dos sinais de entrada. A camada seguinte, conhecida como "camada intermediária", é composta por N neurônios, e realiza algumas transformações. Ao fim existe uma camada conhecida como "camada de saída". Existem tantos neurônios nessa camada quanto o número de saídas desejadas, cada saída representando uma variável que se deseja prever. As camadas são totalmente conectadas, entretanto os neurônios de uma camada estão conectados apenas aos neurônios da camada imediatamente posterior, não havendo realimentação (comunicação unidirecional) nem conexões entre neurônios da mesma camada. Cada grupo de neurônios presentes na camada intermediária e de saída é modelado por uma função de ativação. A função de ativação, também chamada de função de transferência, é uma função matemática que, aplicada à combinação linear entre as variáveis de entrada e ponderações que chegam a determinado neurônio, retorna ao seu valor de saída. Existem diversas funções matemáticas que são utilizadas como função de ativação. As funções de ativação mais comumente usadas são: função logística e a função tangente hiperbólica.

A figura 3 mostra a rede neural do tipo *feedforward* considerada no projeto, apresentando 4 conjuntos de dados de entrada, uma única camada intermediária, com 6 neurônios e um único neurônio na camada de saída. O conjunto de dados de treinamento utiliza como dados de entrada a distância da incidência da descarga atmosférica ao alimentador, intensidade de pico de corrente da descarga atmosférica, altitude da incidência da descarga atmosférica em relação ao nível do mar e polaridade da mesma. A saída da rede neural é um classificador, indicando qual a descarga atmosférica foi à responsável pelo desligamento da linha de transmissão.




Figura 3. Rede neural *feedforward* desenvolvida.

Para os neurônios de todas as camadas da rede neural da figura 3 considerou-se uma *função de ativação tangente hiperbólica*. A função tangente hiperbólica é bastante utilizada em problemas de classificação, devido ao fato de, em algumas situações práticas acelerarem a convergência do algoritmo de treinamento da rede neural (PEREIRA, 1991, p. 121)

Basicamente, o treinamento da rede neural consiste em um problema de minimização não linear sem restrições, em que os pesos sinápticos da rede são iterativamente modificados para minimizar o erro médio quadrático entre a resposta desejada a partir dos dados de entrada, e a saída obtida no neurônio de saída. A característica da RNA é, então, considerar o conhecimento adquirido durante o treinamento e responder a novos dados de entrada da maneira mais apropriada, concluindo assim, uma generalização do problema. Neste trabalho foi considerado um algoritmo de treinamento do tipo retro-propagação do erro (*backpropagation*), com problema de minimização solucionado por um algoritmo do tipo *Gradiente Descendente com Momento* (HAYKIN, 1999).

O critério de parada do treinamento exige considerar a capacidade de generalização da rede neural em fase de treino. Para tanto, adotou-se como critérios de parada do treinamento o aumento do erro do conjunto de teste, caracterizando um sobre treinamento da rede (HAYKIN, 1999), e/ou o número máximo de épocas de apresentação dos dados a rede.

3.1. Preparação dos Dados para a Rede Neural

O conjunto de dados, composto pelas descargas atmosféricas pré-selecionadas, foi separado em dois conjuntos: treinamento e teste. O conjunto de treinamento é utilizado para o treinamento e ajuste dos parâmetros da rede neural, contendo um número estatisticamente significativo de casos em estudo, de modo a constituir uma amostra representativa do problema que se pretende estudar. Para evitarmos o problema de sobre ajuste, aplica-se conjunto de teste, que pode ser encarado como uma subdivisão do conjunto de treinamento, cuja finalidade é verificar a eficiência da rede quanto a sua capacidade de generalização durante o processo de treinamento, e sendo empregado como critério de parada do treinamento da rede neural. A habilidade de generalização da rede se refere ao seu desempenho em classificar padrões do conjunto de avaliação corretamente. Os dados do conjunto de teste não são utilizados para ajuste dos parâmetros da rede.

Como a rede neural desenvolvida considera neurônios do tipo tangente-hiperbólica em todas as suas camadas, os conjuntos de dados de entrada/saída são normalizados entre -1 e 1. Na saída da rede neural, um valor igual a 1 indica que a descarga atmosférica foi a responsável direta pelo desligamento, enquanto -1 indica a situação oposta. Quanto mais próximo da unidade (positiva ou negativa) for o valor da saída da rede neural, mais precisa será a identificação da descarga atmosférica.

Foram contabilizados 18 desligamentos por descargas atmosféricas para o alimentador em questão, no período de dados de 10/2000 a 08/2005. Os desligamentos por descargas atmosféricas representam padrões verdadeiros para o treinamento e teste da rede. Em virtude do baixo número de padrões verdadeiros, realizou-se uma multiplicidade destes dados, aplicando um fator multiplicador igual a 10. Desta forma, passou-se a contar com 180 padrões verdadeiros, replicando os 18 padrões verdadeiros distintos em outros 10 conjuntos de dados semelhantes. Continuam a existir apenas 18 padrões verdadeiros distintos.

Como o número de padrões falsos e verdadeiros é idêntico, foram selecionadas 180 descargas atmosféricas do conjunto pré-selecionado, mas não classificadas como responsáveis pelo desligamento. A multiplicidade dos padrões verdadeiros somente foi realizada após a divisão dos dados nos conjuntos de treinamento e teste. Para o conjunto de padrões verdadeiros utilizados na etapa de treinamento, procurou-se armazenar padrões que cubram todo o espectro de distância, intensidade de corrente, altitude e polaridade. O conjunto de dados com os padrões verdadeiros foi dividido da seguinte forma:

- Treinamento: 15 padrões verdadeiros multiplicados por 10, resultando em um total de 150 padrões verdadeiros;

- Teste: 3 padrões verdadeiros multiplicados por 10, resultando em um total de 30 padrões verdadeiros; O conjunto de padrões falsos foi dividido nos três conjuntos de acordo com critérios de distância da queda da descarga atmosférica ao alimentador e intensidade da mesma, de forma que todo o espectro de valores fosse coberto. Sendo assim, foram selecionadas descargas atmosféricas representando padrões falsos nas seguintes faixas de distância: 0 a 250 metros, 250 a 500 metros, 500 a 750 metros e 750 a 1000 metros. Dentro destas faixas de distância consideraram-se ainda três faixas de intensidade de pico de corrente: 0 a 25 KA, 25 a 50 KA, e acima de 50 KA. O conjunto total de dados com padrões falsos ficou dividido em 12 conjuntos distintos. Foram alocados 150 dados distintos de padrões falsos para o conjunto de treinamento e 30 dados distintos para o conjunto de teste. O conjunto total de dados treinamento e teste ficou constituído por 360 dados, sendo 180 padrões verdadeiros e 180 padrões falsos.

3.2. Classificação das Descargas Atmosféricas

Realizada a seleção das descargas atmosféricas relevantes para o desempenho da linha de transmissão, é de vital importância a identificação das descargas atmosféricas responsáveis diretamente por cada desligamento, para caracterização dos padrões verdadeiros e falsos sobre o evento. Os padrões verdadeiros representam as descargas atmosféricas incididas que resultaram em desligamentos, enquanto os padrões falsos representam descargas atmosféricas relevantes ao desempenho do alimentador, mas que não foram as responsáveis diretas pelo desligamento.

O processo de classificação das descargas atmosféricas mostrou-se muito mais complexo do que o esperado, em virtude da inexatidão no horário registrado para o desligamento da linha de transmissão, para alguns dados constantes no conjunto de dados de desligamento disponibilizado pela Light. Para contornar este inconveniente adotou-se o seguinte critério para a identificação da descarga atmosférica responsável diretamente pelo desligamento.

1. Identificar dentro do conjunto de descargas atmosféricas pré-selecionadas, quais apresentam horário de incidência na faixa de tolerância de +15 minutos em relação ao horário registrado para o desligamento;
2. Analisar a distância da descarga atmosférica a linha e a intensidade de pico de corrente desta descarga, de acordo com a proximidade horária já averiguada;
3. A descarga atmosférica que apresentar menor distância e maior intensidade de pico de corrente, atendendo uma faixa horária mais próxima possível do horário registrado para o desligamento, será classificada como a descarga atmosférica responsável diretamente pelo desligamento da linha de transmissão. A situação mais simples de identificação ocorre quando a descarga atmosférica é incidente sobre a linha e com elevada intensidade de corrente.

Todas as descargas atmosféricas pré-selecionadas, de acordo com a metodologia proposta na seção II, e que não foram classificadas como responsáveis diretas pelo desligamento, são classificadas como candidatas ao desligamento, sendo consideradas como integrantes do conjunto de padrões falsos fornecidos para o treinamento/teste da rede neural.

4. IMPLEMENTAÇÕES E RESULTADOS

4.1. Implementação Computacional

Um aplicativo computacional AIDA (Analisador Integrado de Descargas Atmosféricas) foi desenvolvido para integração de todas as modularidades necessárias para a avaliação do desligamento frente à incidência de descarga atmosférica. O aplicativo integra um módulo de pré-seleção de descargas atmosféricas e um módulo com a implementação da rede neural. Interface amigável ao usuário, visualização gráfica dos resultados e emissão de relatórios, também integram o aplicativo. O

aplicativo AIDA foi escrito em linguagem C++, utilizando a técnica de Modelagem Orientada a Objetos. As figuras 4, 5 e 6 mostram algumas das janelas desenvolvidas para o aplicativo AIDA.

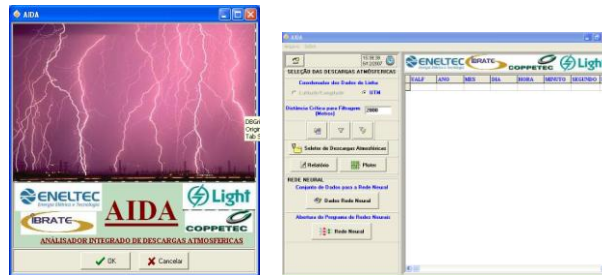


Figura 4. Tela de abertura e tela principal do aplicativo AIDA.




Figura 5. Tela de pré-seleção da descarga atmosférica e tela da etapa de treinamento da rede neural.



Figura 6. Tela com o resultado da pré-seleção de descargas atmosféricas.

4.2. Treinamento da Rede Neural

A figura 7 mostra o resultado do estudo de correlação entre entradas e saída para o conjunto de dados avaliados para a rede neural. A linha em vermelho na figura 7 indica a correlação mínima. As maiores correlações foram verificadas para as entradas distância da descarga a LT e intensidade de pico de corrente. Os dados de polaridade da descarga e altitude da incidência apresentaram uma correlação abaixo do valor mínimo aceitável. Treinamentos foram realizados considerando ou não as entradas altitude e polaridade, sendo muito próximos os resultados em ambas as situações. Contudo, estes dados não foram descartados, uma vez que não dispomos de um número elevado de dados.

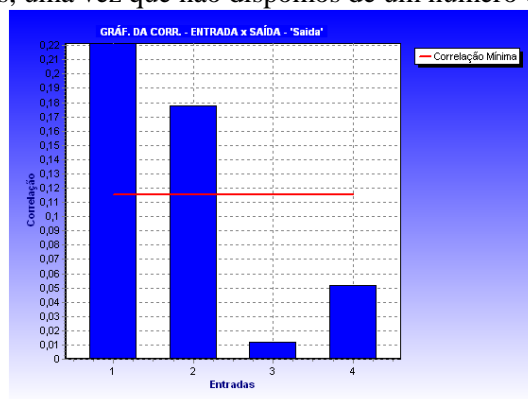


Figura 7. Janela mostrando o resultado do estudo de correlação com a saída. 1 – Distância, 2 – Intensidade, 3 – Polaridade, 4 – Altitude.

Diferentes configurações para a rede neural, no que se refere a número de camadas e neurônios por camada, foram averiguadas. Bons resultados foram obtidos ao se trabalhar com uma rede neural com apenas uma camada intermediária e um número mínimo de 6 neurônios nesta camada. A rede neural avaliada para obtenção destes resultados e treinada no aplicativo fornecido a Light é constituída por três camadas, com 6 neurônios na camada intermediária.

A figura 8 mostra o resultado do treinamento da rede neural. A curva em azul mostra a redução do erro de treinamento, enquanto a curva em vermelho a redução do erro do conjunto de teste. Os dados foram apresentados em um total de 75.000 épocas a rede neural, sendo que os valores armazenados para os pesos sinápticos da rede neural são aqueles obtidos no ponto onde se verificou sobre treinamento, mais especificamente na época 10.000. Neste ponto verificou-se um valor de erro mínimo do conjunto de teste igual a 0.4291.

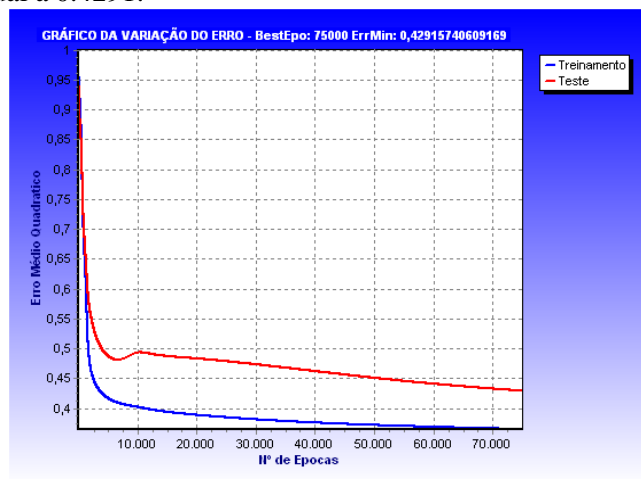


Figura 8. Janela mostrando o resultado do treinamento e teste da rede neural.

4.3. Avaliação da Rede Neural

Para a avaliação da rede neural consideramos uma situação de um desligamento do alimentador ILHSJ-LT RCO, ocorrida às 19 horas e 54 minutos em 10/08/2005.

A Tabela 1 mostra as descargas atmosféricas pré-selecionadas de acordo com III. Nesta tabela estão apresentados os valores da distância (d) da descarga atmosférica a linha de transmissão, a intensidade da descarga atmosférica (KA), a altitude da incidência (H) e polaridade da mesma. Também é apresentado o valor de saída fornecido pela rede neural.

O valor de saída da rede neural varia entre -1 e 1, sendo que quanto mais próximo a unidade, maior a precisão na identificação da descarga atmosférica. Descargas atmosféricas com valor positivo indicam descargas responsáveis pelo desligamento, enquanto um valor negativo indica a não responsabilidade no evento.

Pela Tabela 1 foram pré-selecionadas 31 descargas atmosféricas, de acordo com critério de distância (d) e horário de incidência, sendo estas submetidas à identificação pela rede neural considerada. Verifica-se que cinco descargas atmosféricas foram selecionadas como responsáveis pelo desligamento, caracterizando uma taxa de incerteza de 16% no resultado da avaliação. Este fato pode se justificar pela baixa disponibilidade de dados associados a desligamentos, tratados como padrões verdadeiros na etapa de treinamento da rede neural.

Pelo resultado da avaliação da rede neural descrito no campo Saída da Tabela 1, conclui-se que a descarga atmosférica com maior possibilidade de ser a responsável pelo desligamento é a descarga de número 1, cujo valor da Saída mais se aproxima da unidade positiva.

Tabela 1. Resultado da avaliação do conjunto de descargas atmosféricas pré-selecionadas pela rede neural.

Descarga	<i>d</i> (m)	KA	H (m)	Pol.	Saída
1	27,00	36,0	707,88	-1,00	0,8279
2	1.907,0	57,0	591,95	-1,00	-1,00
3	1.547,0	58,0	220,04	-1,00	-1,00
4	121,00	12,0	539,68	-1,00	-0,6636
5	4,00	10,0	77,488	-1,00	0,4478
6	487,00	44,0	248,85	-1,00	0,4469
7	26,00	42,0	705,90	-1,00	-0,3772
8	336,00	64,0	52,528	1,00	-1,00
9	481,00	67,0	381,63	-1,00	0,4728
10	92,00	55,0	1.017,6	-1,00	-0,9367
11	664,00	22,0	555,96	-1,00	0,2774
12	911,00	12,0	458,63	-1,00	-0,9294
13	682,00	42,0	693,38	-1,00	-0,2798
14	764,00	49,0	640,60	-1,00	-0,9684
15	615,00	58,0	964,05	-1,00	-1,00
16	806,00	52,0	475,27	-1,00	-0,138
17	600,00	97,0	212,84	-1,00	-0,9905
18	1.223,0	20,0	557,44	-1,00	-1,00
19	1.032,0	14,0	942,94	-1,00	-0,8307
20	1.125,0	26,0	655,83	-1,00	-1,00
21	1.167,0	44,0	309,04	-1,00	-1,00
22	1.012,0	58,0	807,45	-1,00	-1,00
23	1.269,0	54,0	683,91	-1,00	-1,00
24	1.366,0	85,0	215,78	1,00	-0,8943
25	1.676,0	18,0	705,10	1,00	-1,00
26	1.804,0	0,00	707,88	1,00	-1,00
27	1.883,0	28,0	923,33	1,00	-1,00
28	1.592,0	27,0	749,00	-1,00	-1,00
29	1.747,0	77,0	12,753	-1,00	-1,00
30	1.624,0	95,0	740,57	-1,00	-1,00
31	1.886,0	54,0	170,70	-1,00	-1,00

A taxa de acerto em 84% indica a viabilidade da ferramenta na identificação de descargas atmosféricas responsáveis por desligamentos, sendo que a melhoria no desempenho da rede neural e conseqüente elevação da taxa de acerto serão alcançadas com o emprego de um conjunto maior de dados na sua etapa de treinamento, principalmente de padrões verdadeiros, relativos a desligamentos.

5. CONCLUSÕES

Este artigo apresentou um sistema de avaliação do desempenho de linhas de transmissão utilizando redes neurais artificiais. Trata-se de uma metodologia alternativa à análise fenomenológica, muitas vezes simplificada de forma inadequada em função de sua elevada complexidade.

Ressaltando o aspecto inovador do sistema proposto, os resultados obtidos durante o projeto são extremamente promissores, já que indicam a validade do método. Este método também pode ser aplicado em redes de distribuição de eletricidade, uma vez que os dados de incidência de descargas atmosféricas disponibilizados pela RINDAT contemplam áreas urbanas.

Algumas limitações podem comprometer a metodologia desenvolvida, dentre as quais podemos destacar:

- O reduzido tamanho do banco de dados de desligamentos, que pode comprometer o processo de aprendizagem da RNA;

- A imprecisão nos dados dos horários dos desligamentos da linha. Uma maior precisão desta informação permitiria uma identificação mais precisa da descarga atmosférica;
- A inexistência de dados com possíveis elevadas correlações ao fenômeno em análise, tal como a resistência de aterramento das estruturas e a resistividade do solo.

A partir da identificação de um conjunto de descargas atmosféricas responsáveis por desligamentos, o projetista pode encontrar padrões associados à estrutura ou ao percurso da linha que venham influenciar na incidência de descargas atmosféricas. Assim, uma minimização do impacto da incidência de descargas atmosférica passa a ser atacado de forma mais efetiva através de medidas preventivas bem embasadas. Os resultados também contribuem para a validação de informações de desligamentos oriundas de diferentes fontes.

6. REFERÊNCIAS BIBLIOGRÁFICAS E/OU BIBLIOGRAFIA

- Beneti, C. A. A., Vasconcellos, C. A. SisRaios – Um Sistema Interativo de Análise e Visualização de Descargas Atmosféricas. In: Congresso Brasileiro de Meteorologia, Foz do Iguaçu, PR, 2002, p. 12.
- Bretas, A. S., Phadke, A. Artificial Neural Networks in Power System Restoration. *IEEE Transactions on Power Delivery*, v. 18, no. 4, 2003, p. 1181-1186.
- Carson, J. R. Wave Propagation in Overhead Wires with Ground Return. *Bell System Technical Journal*, vol. 5, 1926, p. 539-554.
- De Aquino, R. R. B., Carvalho Junior, M. A., De Souza, B. A. Redes Neurais Artificiais: Uma Aplicação ao Planejamento da Operação de Sistemas Hidrotérmicos de Geração. *Anais do IV Congresso Brasileiro de Redes Neurais*, São José dos Campos, SP, Brasil, 1999, p. 164-169.
- Haykin, S. Neural Networks: A comparative Foundation. New Jersey: Prentice Hall, 1999.
- Khotanzad, A., Muratukulam, D. J. An Artificial Neural Network Hourly Temperature Forecaster with Applications in Load Forecasting. *IEEE Trans. on Power Systems*, vol 11, no2, 1996, p. 870-876.
- Khotanzad, A., Afkhami-Rohani, R. ANNSTLF – A Neural-Network-Based Electric Load Forecasting System. *IEEE Trans. on Neural Networks*, vol 8, no 4, 1997, p. 835-846.
- Mansour, Y., Vaahedi, E., El-Sharkawi, M. A. Dynamic Security Contingency Screening and Ranking Using Neural Networks. *IEEE Trans. on Neural Networks*, vol 8, no 4, 1997, p. 942-950.
- Pereira, B. B. Introduction to Neural Networks in Statistics. State College\-Pensylvania: Center for Multivariate Analysis, 1999, p. 121.
- Santiago, N. H. Modelo para Propagação de Surtos em Linhas de Transmissão Incluindo os Efeitos Corona, Pelicular e de Retorno no Solo. Dissertação de Mestrado, Departamento de Engenharia Elétrica, COPPE/UFRJ, Rio de Janeiro, 1982.
- Segatto, Ê. C., Coury, D. V. Redes neurais artificiais recorrentes aplicadas na correção de sinais distorcidos pela saturação de transformadores de corrente. *Revista da Sociedade Brasileira de Automática: Controle & Automação*, vol.17, no.4, Campinas Oct./Dec, 2006.