

# Treatment of the Uncertainties Involved in the Electric Power Systems Fault Section Estimation with the Aid of Probabilistic Neural Networks

Ghendy Cardoso Junior<sup>1</sup>, Jacqueline Gisèle Rolim<sup>2</sup>, Hans Helmut Zürn<sup>2</sup>

<sup>1</sup> Universidade Federal do Pará, LABSPOT-UFSC

<sup>2</sup> Universidade Federal de Santa Catarina, LABSPOT-UFSC

E-mails: ghendy@labspot.ufsc.br, jackie@labspot.ufsc.br, hans@labspot.ufsc.br

## Abstract

*A probabilistic neural net is used as solution methodology during the task of identification of electric faulted sections. Such a net presents a great generalization capacity and it results in the answer with the maximum probability of being correct. It also estimates the likelihood that a new pattern is a member of any of our predefined classes. Models on the operation logic of the protection system used in lines, busbars and transformers are also proposed. A compact neural net, independent of the electric configuration, is associated to each one of these models.*

## 1. Introdução

Em sistemas elétricos de potência os equipamentos de proteção são responsáveis por detectar a ocorrência de uma falta e isolar somente a parte defeituosa do sistema (seletividade). É também muito importante que o restabelecimento do sistema ocorra o mais rapidamente possível, de modo a evitar danos aos consumidores, denegrindo a imagem da empresa fornecedora. Para tal, é essencial que a estimação dos eventos que produzem uma determinada seqüência de alarmes ocorra de forma rápida e precisa. Na operação em tempo real os despachantes precisam estimar a causa dos desligamentos a partir de um conjunto muito grande de informações, antes de iniciar a etapa de restauração. Outros problemas tais como: falha do sistema de proteção, falha nos canais de comunicação, aquisição de dados corrompidos, etc. podem complicar ainda mais esta tarefa.

A automatização da análise da operação de disjuntores e relés tem sido motivo de pesquisa desde 1969, sendo que a utilização de técnicas de Inteligência Artificial a este tipo de problema teve início nos anos 70 [1].

O desenvolvimento de um sistema inteligente para diagnóstico de faltas em sistemas de potência está longe do trivial, dado o volume de informações, e o relativo grau de incerteza nas informações disponíveis ao operador, além do estresse e a urgência da situação [2].

A rede neural do tipo perceptron de múltiplas camadas, com algoritmo de treinamento da

retropropagação de erros é a mais utilizada para tratar o problema de diagnóstico de faltas. Em [2] e [3] é utilizada tal arquitetura, sendo desenvolvido um modelo de rede neural para cada componente elétrico. Embora apresente bons resultados, o treinamento desta classe de redes pode ser bastante demorado, pois necessita de um grande conjunto de exemplares. A capacidade de generalização da rede deve ser explorada, de modo a evitar a memorização dos padrões contidos no treinamento, tornando a mesma incapaz de reconhecer outros exemplares.

Por outro lado, a rede neural probabilística (PNN) é dotada de características como: grande capacidade de generalização; aplicabilidade a problemas de classificação; facilidade de implementação, pois o treinamento ocorre de maneira instantânea e apresenta bons resultados com poucos exemplares de treinamento. Além destas vantagens, a PNN resulta em diferentes graus de resposta, desde a mais provável a menos provável, estimando o grau com que um novo padrão pertence às classes preestabelecidas.

Este artigo utiliza uma rede PNN para identificar a seção do sistema elétrico em falta. Este processo é realizado a nível de centro de controle, e faz uso do conhecimento sobre a lógica de operação do sistema de proteção de linhas, transformadores e barras.

## 2. Problemas envolvidos

Entre os principais problemas a serem considerados pelo sistema de diagnóstico de faltas, cita-se:

- Possibilidade de falha em relés e/ou disjuntores [4];
- Possibilidade de ocorrerem faltas múltiplas [4];
- Aquisição de dados corrompidos e perda de informações devido ao congestionamento nos canais de transmissão de dados, decorrentes de grandes desligamentos e [5];
- Imprecisão nos tempos de ocorrência dos eventos e [5].

## 3. Procedimentos para estimar o componente em falta

1. Identificar os componentes contidos nas áreas atingidas pelos desligamentos provocados por uma falta permanente;

- Aplicar a rede neural utilizada para modelar cada elemento pertencente ao item 1, e testar se a falta ocorreu ou não neste elemento;
- Caso haja atuação de alarmes sobre relés e disjuntores, mas na etapa 1 seja verificado que não houve desligamento de componentes do sistema, não será realizada a etapa 2, pois neste caso não houve falta permanente.

#### 4. Rede neural probabilística

A rede neural probabilística (PNN) é uma rede direta, multicamadas, semelhante à rede que utiliza algoritmo de retropropagação, bastante divulgada. A principal diferença entre estas, está na operação de seus neurônios, ou seja, na PNN é implementada uma estratégia de decisão Bayesiana durante a classificação dos vetores de entrada. Este comportamento é alcançado utilizando-se uma função de transferência de base radial (Gaussiana) na camada escondida, em conjunto com uma camada de soma que possui acoplada a sua saída uma função de transferência baseada em competição. A Fig. 1 mostra a estrutura de uma rede PNN [6].




Figura 1: Arquitetura da rede utilizada

Neste tipo de rede, o número de neurônios na camada escondida é igual ao número de exemplares utilizados para introduzir conhecimento na rede (treinamento). O número de neurônios na camada de soma corresponde ao número de classes (representam os grupos) nas quais os padrões de entrada podem ser classificados [7].

Quando um vetor de entrada é apresentado à rede, a primeira camada (escondida) calcula as distâncias (distância euclidiana) entre este vetor e os vetores utilizados durante o treinamento, que por sua vez serão submetidos à função de base radial, produzindo um vetor cujos elementos indicam a proximidade entre o vetor apresentado à rede e os vetores utilizados durante o treinamento. A segunda camada tem como função somar os resultados gerados pela função de base radial para cada classe, de modo a produzir, como saída, um vetor contendo os diversos graus de semelhança entre o vetor de entrada e cada uma das classes. Por último, a função de transferência baseada em competição, ligada na saída da segunda camada atribui à classe com a maior probabilidade de estar correta, o valor 1 (vencedor); e zero às demais classes.

## 5. Modelagem do problema

De modo a sobrepor as dificuldades apresentadas pelas redes neurais quanto à dimensão ( $n^o$  de nós da camada de entrada), e o problema relativo a mudanças na topologia da rede elétrica, motivou-se em desenvolver modelos compactos e independentes da configuração do sistema elétrico. A lógica de operação da proteção para barras, linhas e transformadores são as mesmas apresentadas em [8].

A simbologia utilizada na composição dos modelos é dada por:

L – linha de transmissão;

T – transformador;

B – barra;

S e R – lados emissor e receptor, respectivamente (pré definidos);

m – relé principal;

p – relé de retaguarda primário;

s – relé de retaguarda secundário;

CB – disjuntor.

### 5.1. Modelo utilizado na representação de linhas de transmissão

O modelo da Fig. 2 considera, como variáveis, os relés principais (LSm e LRm), proteção de retaguarda primária (LSp e LRp servem como proteção de retaguarda para LSm e LRm, respectivamente) e secundária (LSs e LRs servem como proteção de retaguarda para um elemento vizinho à linha). Também são considerados os disjuntores do lado emissor e receptor, ou seja “CBS” e “CBR”, respectivamente. Uma mensagem de falha de disjuntor “CBnext” para cada uma das extremidades da linha (“CbnextS” e “CBnextR”) é utilizada na modelagem da operação do relé de retaguarda secundário (não é para o disjuntor da linha que está sendo analisada, mas sim àquele pertencente ao elemento vizinho a esta).




Figura 2: Modelo representativo do sistema de proteção da uma linha

### 5.2. Modelo utilizado na representação de transformadores

O sistema de proteção do transformador é composto por relé principal (Tm), relé de retaguarda primário (TSp e TRp) e secundário (TSs e TRs). As proteções de retaguarda primária e secundária servem como retaguarda para a proteção principal e para o elemento vizinho ao transformador, respectivamente [8]. A Fig. 3 mostra as variáveis envolvidas no modelo, juntamente com as possíveis ocorrências de falta.




Figura 3: Modelo utilizado para representar o sistema de proteção do transformador

### 5.3. Modelo utilizado na representação de barras

As barras são protegidas por um relé diferencial, que em caso de falta envia comando de *trip* a todos os disjuntores ligados à barra (torna o modelo para a barra dependente do número de disjuntores em operação ou fora de operação).

Por serem o nó de interligação entre diversos componentes elétricos, as barras não apresentam um modelo específico, pois o arranjo de diversas configurações é possível mediante a realização de manobras sobre os disjuntores ligados às barras. O tratamento especial atribuído às barras será melhor compreendido em 6.3.

## 6. Formação do conjunto de treinamento

A formação do conjunto de treinamento consiste na codificação binária da lógica de operação do sistema de proteção de cada elemento. Utilizou-se o valor  $-1$ , para representar que o disjuntor ou relé não operou e  $+1$ , caso contrário.

Durante a formação do conjunto de treinamento não se considerou a possibilidade de erro e falta de mensagem adquiridas pelo sistema SCADA, pois espera-se que a rede seja capaz de generalizar. Falhas no sistema de transmissão de dados são codificadas por 0, isto é, um valor intermediário ao estado operativo e não operativo.

### 6.1. Formação do conjunto de treinamento para as linhas de transmissão

A seguir apresenta-se a lógica de operação do sistema de proteção da linha [8]:

- Lógica da proteção principal da linha:

**Classe 1** - SE ocorrer uma falta na linha, ENTÃO o relé LSm deverá operar, enviando comando de *trip* ao disjuntor CBS.

**Classe 1** - SE ocorrer uma falta na linha ENTÃO o relé LRm deverá operar, enviando comando de *trip* ao disjuntor CBR.

- Lógica da proteção de retaguarda primária:

**Classe 2** - SE ocorrer uma falta na linha E LSm não operar, ENTÃO LSp deverá operar para *trip* de CBS.

**Classe 2** - SE ocorrer uma falta na linha E LRm não operar, ENTÃO LRp deverá operar para *trip* de CBR.

- Lógica da proteção de retaguarda secundária:

**Classe 3** - SE ocorrer uma falta na barra do lado “R” da linha E CBR não operar,

OU

**Classe 4** - SE ocorrer uma falta no elemento vizinho do lado “R” da linha, E CBR E CbnextR não operarem,

ENTÃO LSs deverá operar para *trip* de CBS.

**Classe 3** - SE ocorrer uma falta na barra do lado “S” da linha E CBS não operar,

OU

**Classe 4** - SE ocorrer uma falta no elemento vizinho do lado “S” da linha, E CBS E CbnextS não operarem,

ENTÃO LRs deverá operar para *trip* de CBR.

A codificação do sistema de proteção da linha utiliza variáveis de entrada: LSm (1 se operou, e  $-1$  senão), LSp (1/-1), LSs (1/-1), CBS (1/-1), CbnextS (1 se falhou, e  $-1$  senão), LRm (1/-1), LRp (1/-1), LRs (1/-1), CBR (1/-1) e CbnextR (1 se falhou, e  $-1$  senão).

Como classificação utilizaram-se números variando de 1 a 5. Sendo que os números de 1 a 4 correspondem, respectivamente, às 4 classes de operação da proteção, apresentadas anteriormente. A classe 5 indica a insuficiência de mensagem para a análise. Esta classificação foi incorporada ao conjunto de treinamento da rede, pois sem esta, a mesma poderá produzir respostas pouco confiáveis, em casos extremos. Este seria, por exemplo, o caso em que o vetor de entrada apresentasse muitos valores errados e falta de mensagens (zeros), extremamente diferente dos casos para o qual a rede foi treinada.

Os exemplos utilizados para o treinamento, juntamente com suas classificações são apresentados na Tabela 1.

Tabela 1: Exemplos para treinamento e suas respectivas classificações

1	2	2	2	3	3	3	4	4	4	5	Classes
1	-1	-1	1	-1	-1	-1	-1	-1	-1	0	LSm
-1	1	1	-1	-1	-1	-1	-1	-1	-1	0	LSp
-1	-1	-1	-1	1	1	-1	-1	1	1	0	LSs
1	1	1	1	1	1	-1	-1	1	1	0	CBS
-1	-1	-1	-1	-1	-1	-1	1	-1	1	0	CbnextS
1	-1	1	-1	-1	-1	-1	-1	-1	-1	0	LRm
-1	1	-1	1	-1	-1	-1	-1	-1	-1	0	LRp
-1	-1	-1	-1	1	-1	1	1	-1	1	0	LRs
1	1	1	1	1	-1	1	1	-1	1	0	CBR
-1	-1	-1	-1	-1	-1	-1	-1	1	1	0	CbnextR

Como a segunda camada é composta por uma função de transferência baseada em competição, em caso de empate, será dado como resposta o menor número correspondente à classificação, ou seja, da esquerda para a direita (por exemplo, se houver um empate entre as classificações 2 e 3, será dada como vencedora a 2). Juntamente com a classificação vencedora, também é fornecido o grau de semelhança entre o vetor de entrada e os vetores do conjunto de treinamento relativos a cada classe.

Durante a elaboração do conjunto de treinamento, utilizou-se como critério, para casos de desempate entre qualquer classe, considerar como ordem de saída as respostas, falta (1 e 2), não está em falta (3 e 4) e por

último, não há informações suficientes para a análise (5). Deste modo previne-se, em caso de dúvida, a restauração de um componente em falta, aumentando-se ainda mais os danos provocados pela mesma. A opção por colocar a mensagem de insuficiência de dados, por último, se dá devido ao fato de que alguma resposta é melhor do que nenhuma.

A rede foi alimentada com 11 padrões de treinamento, cada qual refletindo o comportamento esperado dos dispositivos de proteção, sem considerar falta ou erro em mensagens de alarmes. Para validar e verificar a capacidade de generalização da rede, foram gerados, aleatoriamente, 289 casos. Cada caso foi previamente analisado e julgado, sendo depois apresentado à rede, a qual foi capaz de responder corretamente a 100% dos casos utilizados no treinamento e 97.92% dos casos gerados aleatoriamente.

## 6.2. Formação do conjunto de treinamento para os transformadores

A formação do conjunto de treinamento para a rede neural correspondente ao modelo do transformador, segue o mesmo raciocínio utilizado para o caso das linhas de transmissão. A principal diferença está nas variáveis utilizadas, ou seja, Tm (1 se operou, e -1 senão), TSp (1/-1), TSs (1/-1), CBS (1/-1), CbnextS (1 se falhou, e -1 senão), TRp (1/-1), TRs (1/-1), CBR (1/-1) e CbnextR (1 se falhou, e -1 senão).

Como classificação, utilizou-se:

**Classe 1** → Houve falta no transformador e Tm operou corretamente, dando *trip* em CBS e CBR;

**Classe 2** → Houve falta no transformador e CBS e/ou CBR não operaram durante o tempo de atuação de Tm, sendo que TSp e/ou TRp deram *trip* no(s) disjuntor(es) que não operou/operaram;

**Classe 3** → A barra no lado S e/ou R está em falta, e TSs e/ou TRs operou para *trip* em CBS e/ou CBR, respectivamente;

**Classe 4** → O elemento após a barra do lado S e/ou R está em falta e CbnextS e/ou CbnextR falhou, mas TSs e/ou TRs operou para *trip* em CBS e/ou CBR, respectivamente;

**Classe 5** → não há informações suficientes para a análise.

De maneira semelhante à rede utilizada para representar a lógica de operação da proteção de linhas, esta foi alimentada com 11 padrões de treinamento, cada qual refletindo o comportamento esperado dos dispositivos de proteção, sem considerar falta ou erro em mensagens de alarmes. Para validar e verificar a capacidade de generalização da rede, foram gerados, aleatoriamente, 283 casos. Cada caso foi previamente analisado e julgado, sendo depois apresentado à rede, a qual foi capaz de responder corretamente a 100% dos casos utilizados no treinamento e 96.82% dos casos gerados aleatoriamente.

## 6.3. Formação do conjunto de treinamento para as barras

As variáveis de entrada para a rede responsável pela análise das barras, são dadas por: Bm (1 se o relé principal operou, -1 senão), CB's (1 se todos os CB's ligados à barra operaram, -1 senão), CB'sF (1 se alguns CB's ligados à barra falharam, -1 senão) e nCBop (1 se nenhum CB operou, -1 senão).

As classificações variam de 1 a 4, onde:

**Classe 1** → em falta;

**Classe 2** → possibilidade de falta, confirme esta informação com a resposta da rede que analisar o elemento vizinho a barra;

**Classe 3** → não houve falta;

**Classe 4** → não há informações suficientes para a análise.

A classe 2 é necessária para levar em consideração a operação do esquema de proteção de retaguarda utilizada nas linhas e transformadores.

A rede foi alimentada com 6 padrões de treinamento, cada qual refletindo o comportamento esperado dos dispositivos de proteção, sem considerar falta ou erro em mensagens de alarmes. Para validar e verificar a capacidade de generalização da rede, foram gerados, aleatoriamente, 58 casos. Cada caso foi previamente analisado e julgado, sendo depois apresentado à rede, a qual foi capaz de responder corretamente a 100% dos casos utilizados no treinamento e 93.10% dos casos gerados aleatoriamente.

## 7. Exemplos testes

Alguns exemplos utilizados para testar os modelos propostos são apresentados na Tabela 2. Nesta são apresentados 10 casos de desligamentos, simulados no sistema teste da Fig. 4.




Figura 4: Sistema teste [9]

Os casos visam verificar se os modelos refletem o comportamento da proteção (sem ruído); e o comportamento da rede em casos mais complicados, incluindo erros e falta de mensagens (com ruído).

Tabela 2: Exemplos testes

C A	Relés que operaram		Disjuntores que operaram		Disjuntores que falharam		Falha na comunicação	Área Desligada
	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído	Com ruído	Sem ruído e com ruído
01	B1m, L2Rs e L4Rs	B1m, L2Sp e L4Rs	CB4, CB5, CB7, CB9, CB12 e CB27	Idem	CB6	CB6		B1, B2, L2 e L4
02	B1m, L1Sp e L1Rm	B1m, L1Sp e L1Rm	CB4, CB5, CB6, CB7, CB9 e CB11	CB7 e CB11			CB4, CB5, CB6, CB9, CB12, CB13, CB14, CB15, CB19 e L1Ss	B1 e L1
03	B1m, B2m, L1Sm, L1Rp, L2Sp e L2Rm	B1m, B2m, L1Rp, L2Sp	CB4, CB5, CB6, CB7, CB8, CB9, CB10, CB11 e CB12	CB4, CB5, CB6, CB7, CB8, CB9, e CB10			L1Sm e CB11	B1, B2, L1 e L2
04	T3p, L7Sp e L7Rp	T3p, T3m, L7Sp, L7Rm	CB14, CB16, CB29 e CB39	CB29 e CB39		CB33	L7Rp, CB12, CB13, CB15, CB19 e CB16	T3 e L7
05	T5s e T6s	B1m, T5s e T6s	CB21, CB22 e CB23	CB22, CB23 e CB21		CB22		A3
06	T7m, T8p, B7m, B8m, L5Sm, L5Rp, L6Ss, L7Sp, L7Rm e L8Ss	T7m, T8p, B7m, B8m, L5Sm, L5Rp, L6Ss, L7Sp, L7Rm e L8Ss	CB19, CB20, CB29, CB30, CB32, CB33, CB34, CB35, CB36, CB37 e CB39				CB31 e CB40	B7, B8, L5, L6, L7, L8, T7 e T8
07	L1Sm, L1Rp, L2Sp, L2Rp, L7Sp, L7Rm, L8Sm e L8Rm	L1Sp, L1Rp, L1Rs, L2Rp, L7Sp, L7Ss, L8Sm e L8Rm	CB7, CB8, CB11, CB12, CB29, CB30, CB39 e CB40	CB7, CB11, CB12, CB29, CB30 e CB39		CB14	L2Sm, L7Rs, CB8, CB31, CB33, CB34 e CB35	L1, L2, L7 e L8
08	L2Rm	L2Sm e L2Rm	CB8 e CB12	Nenhum			CB6, CB10 e CB12	L2
09	B1m	B1m	CB4, CB5, CB7, CB9, CB12 e CB27	CB4, CB5, CB7, CB9 e CB27	CB6	CB6	CB10, CB12, CB13, CB14, CB15, CB19, CB24, CB25, CB26, CB29	B1, B2, L2 e L4
10	L2Rs e L4Rs	Nenhum	CB4, CB5, CB7, CB9, CB12 e CB27	CB4, CB5, CB7, CB9, CB12 e CB27	CB6	CB6	L2Sm, L2Sp, L2Ss, L4Sm, L4Sp e L4Ss	B1, B2, L2 e L4

Na Tabela 3 são apresentados os resultados obtidos para os casos utilizados em [9], que refletem basicamente a lógica de operação do sistema de proteção.

O resultado final apresentado pela rede corresponde à última coluna (vencedora). O significado de cada classe vencedora é descrito em 6.1, 6.2 e 6.3, caso a designação represente uma linha, transformador ou barra,

respectivamente. Pode-se visualizar, também, o grau de proximidade entre o vetor representativo do caso e os exemplos armazenados na rede. Esta característica é bastante atraente, pois caso seja constatado que uma determinada resposta não esteja correta, pode-se recorrer a outra explicação, seguindo-se a ordem decrescente dos valores apresentados.

Tabela 3: Resultados obtidos com os exemplos testes sem ruído

Casos	Desig.	Graus de semelhança entre o vetor representativo do caso por classe					Classe Vencedora
		Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	
01	B1	1.000000e+000	3.872592e-121	2.999394e-241	3.872592e-121		1
	B2	1.499697e-241	3.872592e-121	1.000000e+000	3.872592e-121		3
	L2	0.000000e+000	0.000000e+000	3.872592e-121	1.000000e+000	9.332636e-302	4
	L4	0.000000e+000	0.000000e+000	3.872592e-121	1.000000e+000	9.332636e-302	4
02	B1	1.000000e+000	0.000000e+000	1.499697e-241	3.872592e-121		1
	L1	1.499697e-241	1.000000e+000	0.000000e+000	0.000000e+000	9.332636e-302	2
03	B1	1.000000e+000	0.000000e+000	1.499697e-241	3.872592e-121		1
	B2	1.000000e+000	0.000000e+000	1.499697e-241	3.872592e-121		1
04	L1	1.499697e-241	1.000000e+000	0.000000e+000	0.000000e+000	9.332636e-302	2
	L2	1.499697e-241	1.000000e+000	0.000000e+000	0.000000e+000	9.332636e-302	2
05	L7	0.000000e+000	1.000000e+000	0.000000e+000	0.000000e+000	9.332636e-302	2
	T3	0.000000e+000	1.000000e+000	0.000000e+000	0.000000e+000	1.183052e-271	2
06	A3	3.872592e-121	1.499697e-241	3.872592e-121	3.872592e-121		1
07	B7	7.745184e-121	1.499697e-241	3.872592e-121	3.872592e-121		1
	B8	1.000000e+000	0.000000e+000	1.499697e-241	3.872592e-121		1
	L5	1.499697e-241	1.000000e+000	0.000000e+000	0.000000e+000	9.332636e-302	2
	L6	0.000000e+000	0.000000e+000	1.000000e+000	3.872592e-121	9.332636e-302	3
	L7	1.499697e-241	1.000000e+000	0.000000e+000	0.000000e+000	9.332636e-302	2
	L8	0.000000e+000	0.000000e+000	1.000000e+000	3.872592e-121	9.332636e-302	3
	T7	1.000000e+000	7.745184e-121	0.000000e+000	0.000000e+000	1.183052e-271	1
	T8	0.000000e+000	1.000000e+000	0.000000e+000	0.000000e+000	1.183052e-271	2
08	L1	1.499697e-241	1.000000e+000	0.000000e+000	0.000000e+000	9.332636e-302	2
	L2	0.000000e+000	1.000000e+000	0.000000e+000	0.000000e+000	9.332636e-302	2
	L7	1.499697e-241	1.000000e+000	0.000000e+000	0.000000e+000	9.332636e-302	2
	L8	1.000000e+000	2.999394e-241	0.000000e+000	0.000000e+000	9.332636e-302	1
09	L2	3.872592e-121	3.872592e-121	0.000000e+000	0.000000e+000	9.332636e-302	1
	B1	1.000000e+000	3.872592e-121	2.999394e-241	3.872592e-121		1
	B2	1.499697e-241	3.872592e-121	1.000000e+000	3.872592e-121		3
	L2	0.000000e+000	0.000000e+000	1.499697e-241	3.872592e-121	9.332636e-302	4
10	L4	0.000000e+000	0.000000e+000	1.499697e-241	3.872592e-121	9.332636e-302	4
	B1	3.872592e-121	1.000000e+000	7.745184e-121	3.872592e-121		2
	B2	1.499697e-241	3.872592e-121	1.000000e+000	3.872592e-121		3
	L2	0.000000e+000	0.000000e+000	3.872592e-121	1.000000e+000	9.332636e-302	4
	L4	0.000000e+000	0.000000e+000	3.872592e-121	1.000000e+000	9.332636e-302	4

Nos mesmos dez casos da Tabela 3, introduziram-se ruídos, tais como, erros de mensagens, atuações indevidas de relés e disjuntores, e falha nos canais de transmissão de dados.

Analisando-se os resultados da Tabela 4, nota-se que as redes neurais tiveram sucesso em suas classificações, embora haja uma depreciação no grau de semelhança entre os novos padrões apresentados à rede e aqueles referentes a Tabela 3, o que já era esperado.

Tabela 4: Resultados dos exemplos testes com a inclusão de ruídos

Casos	Desig.	Graus de semelhança entre o vetor representativo do caso por classe					Classe Vencedora
		Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	
01	B1	1.000000e+000	3.872592e-121	2.999394e-241	3.872592e-121		1
	B2	1.499697e-241	3.872592e-121	1.000000e+000	3.872592e-121		3
	L2	0.000000e+000	0.000000e+000	0.000000e+000	1.499697e-241	9.332636e-302	4
	L4	0.000000e+000	0.000000e+000	3.872592e-121	1.000000e+000	9.332636e-302	4
02	B1	1.244603e-060	2.409920e-181	2.409920e-181	6.223015e-061		1
	L1	0.000000e+000	4.909093e-091	0.000000e+000	0.000000e+000	1.901092e-211	2
03	B1	1.000000e+000	0.000000e+000	1.499697e-241	3.872592e-121		1
	B2	1.000000e+000	0.000000e+000	1.499697e-241	3.872592e-121		1
	L1	9.332636e-302	6.223015e-061	9.332636e-302	0.000000e+000	1.499697e-241	2
	L2	0.000000e+000	2.999394e-241	1.499697e-241	0.000000e+000	9.332636e-302	2
04	L7	0.000000e+000	3.054936e-151	0.000000e+000	0.000000e+000	1.183052e-271	2
	T3	9.332636e-302	2.409920e-181	0.000000e+000	0.000000e+000	1.901092e-211	2
05	A3	7.745184e-121	1.499697e-241	0.000000e+000	3.872592e-121		1
06	B7	1.244603e-060	2.409920e-181	2.409920e-181	6.223015e-061		1
	B8	1.000000e+000	0.000000e+000	1.499697e-241	3.872592e-121		1
07	L5	1.499697e-241	1.000000e+000	0.000000e+000	0.000000e+000	9.332636e-302	2
	L6	0.000000e+000	0.000000e+000	7.888609e-031	7.888609e-031	1.183052e-271	3
	L7	1.499697e-241	1.000000e+000	0.000000e+000	0.000000e+000	9.332636e-302	2
	L8	0.000000e+000	0.000000e+000	7.888609e-031	7.888609e-031	1.183052e-271	3
	T7	7.888609e-031	6.109873e-151	0.000000e+000	0.000000e+000	1.499697e-241	1
	T8	0.000000e+000	7.888609e-031	0.000000e+000	0.000000e+000	1.499697e-241	2
	L1	0.000000e+000	3.872592e-121	0.000000e+000	0.000000e+000	9.332636e-302	2
	L2	0.000000e+000	2.409920e-181	0.000000e+000	0.000000e+000	1.499697e-241	2
08	L7	0.000000e+000	3.054936e-151	1.183052e-271	0.000000e+000	1.183052e-271	2
	L8	3.054936e-151	0.000000e+000	0.000000e+000	0.000000e+000	1.183052e-271	1
09	L2	2.409920e-181	0.000000e+000	0.000000e+000	0.000000e+000	1.499697e-241	1
09	B1	1.000000e+000	3.872592e-121	2.999394e-241	3.872592e-121		1
	B2	3.054936e-151	3.054936e-151	7.888609e-031	4.909093e-091		3
	L2	0.000000e+000	0.000000e+000	9.332636e-302	2.409920e-181	1.499697e-241	4
	L4	0.000000e+000	0.000000e+000	9.332636e-302	2.409920e-181	1.499697e-241	4
10	B1	3.872592e-121	1.000000e+000	7.745184e-121	3.872592e-121		2
	B2	1.499697e-241	3.872592e-121	1.000000e+000	3.872592e-121		3
	L2	0.000000e+000	0.000000e+000	1.901092e-211	4.909093e-091	1.901092e-211	4
	L4	0.000000e+000	0.000000e+000	1.901092e-211	4.909093e-091	1.901092e-211	4

## 8. Conclusões

Os resultados obtidos com a rede neural probabilística foram considerados extremamente satisfatórios, uma vez que:

- utiliza a teoria de decisão Bayesiana para classificar vetores, que juntamente com uma função de transferência competitiva, resulta em uma classificação final acompanhada dos respectivos graus de semelhança entre o vetor apresentado e os exemplos representativos de cada classe utilizados durante o treinamento;
- apresenta uma grande capacidade de generalização;
- treinamento da rede não ocorre de maneira iterativa, mas sim instantânea, ou seja, não depende de convergência.

Por outro lado, a maior desvantagem apresentada pela PNN é que todo o conjunto de treinamento deve ser armazenado e o tempo computacional necessário para classificar um padrão de entrada é proporcional à dimensão do conjunto de treinamento.

Os modelos propostos para fins de representar o esquema de proteção dos componentes elétricos são bastante flexíveis e caso haja necessidade, pode-se incorporar outras variáveis, além daquelas utilizadas.

## Referências

- [1] KEZUNOVIC', M. and FROMEN, C. W. An expert System for transmission substation event analysis. *IEEE Transaction on Power Delivery*, Vol. 8, No. 4, October 1993.
- [2] RODRÍGUEZ, C.; REMENTERÍA, S. *et al.* Fault analysis with modular neural networks. *Electric Power & Energy Systems*, Vol.18, No. 2, pp. 99-110, 1996.
- [3] BIONDI NETO, L.; CHIGANER, L. *et al.* Sistema híbrido de apoio à decisão para detecção e diagnóstico de falhas em redes elétricas. XIV SNPTEE, GRUPO V, Belém – PA, 1997.
- [4] HONG, T. Y.; WEN, W. C.; CHING, L. H. A new neural network approach to on-line fault section estimation using information of protective relays and circuit breakers. *IEEE Transaction on Power Delivery*, Vol. 9, no. 1, January 1994.
- [5] VALE, Z. A. and RAMOS, C. Temporal Reasoning in AI Applications for Power System Control Centres. *IFAC Control of Power Plants and Power Systems*, SIPOWER'95 Cancún, México 1995.
- [6] SKAPURA, D. M. *Building neural networks*. Addison-Wesley, New York, 1996.
- [7] FAUSETT, L. V. *Fundamentals of neural networks architectures, algorithms, and applications*. Prentice Hall International, Inc., New Jersey, 1994.
- [8] WEN, F. S. and HAN, Z. Fault section estimation in power systems using a genetic algorithm. *Electric Power Systems Research* 34 (1995), 165-172.
- [9] WEN, F. S. and CHANG, C. S. A tabu search approach to fault section estimation in power systems. *Electric Power Systems Research* 40 (1997) 63-73.