

# VI SBQEE

21 a 24 de agosto de 2005

Belém – Pará – Brasil



Código: BEL 13 7696

Tópico: Sistemas de Monitoramento e Tratamento de dados

## CLASSIFICAÇÃO DE PADRÕES DE AFUNDAMENTOS DE TENSÃO EM SISTEMAS DE MONITORAMENTO DA QUALIDADE DA ENERGIA ELÉTRICA

DÉLIO E. B. FERNANDES

MÁRIO FABIANO ALVES

PYRAMO P. C. JÚNIOR

PUC-MG

### RESUMO

Este artigo apresenta uma metodologia de classificação de afundamentos de tensão utilizando uma rede neural probabilística e um classificador de padrões de Bayes para validação. A partir de um conjunto de dados representativos de afundamentos de tensão é obtido um grupamento de dados utilizando um algoritmo de grupamento por distância Euclidiana e, então, os grupos encontrados são utilizados como padrões de treinamento em uma rede neural probabilística. Uma vez treinada, a rede é então utilizada para efetuar classificações em outros conjuntos de dados.

### PALAVRAS-CHAVE

Qualidade da energia elétrica, variações de tensão de curta duração, afundamentos de tensão, classificação de padrões, redes neurais artificiais, bancos de dados.

### 1.0 INTRODUÇÃO

Dentre os fenômenos eletromagnéticos que compreendem o escopo da análise da qualidade da energia elétrica, devemos destacar as variações de tensão de curta duração, mais especificamente os afundamentos de tensão. Grande parte dos problemas relacionados a QEE enfrentados por concessionárias e indústrias é associada aos afundamentos de tensão, [1]. A análise da qualidade da energia elétrica pode ser realizada a partir de simulação de modelos computacionais do sistema elétrico ou a partir de dados provenientes de seu monitoramento. Atualmente, os monitores de QEE utilizados são

equipamentos com capacidade para identificar informações de fenômenos eletromagnéticos diversos. No entanto, o monitoramento da QEE pode gerar quantidades muito grandes de dados, o que dificulta o processo de análise. Este grande volume de dados pode ter sua organização sistematizada e automatizada em estruturas de informação desenvolvidas para caracterização dos fenômenos eletromagnéticos, formando banco de dados de QEE. Um sistema computacional com estas características foi desenvolvido pelos autores. O Sistema de Gerenciamento da QEE, ou SGQEE, armazena, além de dados de monitoração, todos os atributos que os identificam, e possibilita acesso a estas informações sob diversos enfoques de análise, [2]. As informações introduzidas neste sistema são provenientes de um processo de caracterização que define atributos ao evento afundamento de tensão a partir da análise da sua forma de onda.

A análise de uma grande quantidade de informação requer a utilização de tratamento estatístico de dados para determinação de tendências e padrões de ocorrência. O tipo de fenômeno abordado, de natureza estocástica, mostra estabelecer uma tendência verificada através de medidas estatísticas após simulações correspondentes a muitos anos de operação do sistema elétrico, [3]. Isto equivale dizer que um local de monitoramento necessitaria ser monitorado por muitos anos para que o fenômeno afundamento de tensão apresentasse tendências de comportamento. A aceleração de tendências de ocorrência dos afundamentos de tensão por intermédio do reconhecimento de padrões é um objetivo futuro deste trabalho. O objetivo imediato

é o desenvolvimento de uma metodologia de classificação de padrões de afundamentos de tensão aplicável a uma barra qualquer do sistema.

A classificação de padrões consiste na alocação de eventos (afundamentos de tensão) a grupos, ou classes, pré-identificadas, com características similares, [4]. A classificação é efetuada utilizando como base toda a informação disponível sobre o fenômeno analisado, proveniente de sua caracterização. A utilização de um maior número de parâmetros de caracterização aumenta a capacidade discriminatória entre os eventos pelo aumento da dimensão dos dados de análise.

A partir de um classificador de padrões cada evento é avaliado e passa a pertencer a uma determinada classe de afundamento de tensão. A questão é: como definir a priori as classes a serem utilizadas para o procedimento de classificação? Há em um conjunto de eventos uma classificação natural que pode ser definida por um algoritmo discriminante, ou de grupamento, [4], implementado por metodologias com base na estatística clássica, ou pela utilização de redes neurais artificiais, [5]. O grupamento de dados pode, também, ser realizado a partir de uma análise especializada que determine características de eventos que se relacionem a um objeto de investigação de QEE. O algoritmo aqui utilizado agrupa os padrões de afundamentos de tensão segundo sua distância Euclidiana. Este grupamento possibilita compor conjuntos de padrões que representam grupos, tão mais definidos quanto maior o número de padrões que os compõe.

Os grupos são então utilizados em um procedimento de classificação utilizando uma rede neural artificial, validado por um classificador de Bayes. Esta abordagem, combinada a avaliação de um especialista na determinação dos grupos, permite a construção de uma base de conhecimento definida por padrões agrupados, que pode ser utilizada em outras análises, formando uma base de conhecimento crescente. Esta base de conhecimento, juntamente com a metodologia de classificação faz parte de um subsistema do SGQEE, o Sistema Especialista para a QEE – SEQEE, em desenvolvimento pelos autores.

## 2.0 CARACTERIZAÇÃO DO AFUNDAMENTO DE TENSÃO

A caracterização de afundamentos de tensão é executada pelo SGQEE a partir do processamento de sinais de oscilografias, armazenadas sob o formato COMTRADE, [6], registradas por um sistema de aquisição de dados. O resultado do processamento são os atributos de caracterização do afundamento de tensão. Tradicionalmente os atributos de caracterização de um afundamento de tensão são sua amplitude e duração. Há vários estudos que visam a definição de parâmetros de caracterização de afundamentos de tensão para sua melhor qualificação e quantificação, [7]. Atributos como o ponto da onda em que o evento se inicia e o desvio do ângulo de fase, entre outros, são analisados tanto no sentido de determinação da causa do evento, quanto para estimar o grau de sua capacidade de interferir no funcionamento normal das cargas sensíveis a sua ocorrência. Neste estudo foi utilizada como base a caracterização proposta em [2], que define, além da amplitude e duração, a média, mediana e o mínimo dos valores instantâneos do afundamento, a hora do dia de sua ocorrência entre outros parâmetros como perda de tensão e perda de energia, descritos em [8].

Os atributos são inseridos em um banco de dados de onde podem ser acessados pelo SGQEE, a partir de consultas discriminando características como local de monitoramento, período ou amplitude dos eventos. A tabela 1 apresenta a seleção de um conjunto de eventos de um determinado local de monitoramento por um determinado período de monitoramento.

## 3.0 CLASSIFICAÇÃO DE PADRÕES

O problema de classificação de padrões deve ser desenvolvido a partir de uma formulação matemática que modele uma fonte de geração de padrões pela qual seja possível avaliar o desempenho de sistemas classificadores [9], sejam eles definidos pela estatística multivariáveis ou por técnicas de inteligência artificial. O classificador de Bayes é utilizado como referência de classificação por ter uma descrição analítica bem definida. Um classificador que utiliza uma rede neural probabilística é comparado ao classificador de Bayes para sua validação. Ambos os classificadores têm características semelhantes, sendo que o classificador que utiliza a rede neural probabilística tem uma implementação computacional relativamente mais fácil quando se trata de classificação em dimensão mais elevada.

Tabela 1 - Tabela consulta de dados da caracterização de afundamentos de tensão em um canal de medição de um consumidor por um período de dois anos.

Canal	Data Inicio Evento	Nome Local	Amplitude	Duração VTCD	Mediana	Desvio Padrão	Perda Tensão
1	28/01/2003 18:53:01	BARRA 138KV	0,6062	0,0813	0,6529	0,0069	0,0286
1	14/04/2004 05:51:45	BARRA 138KV	0,5727	0,5007	0,6080	0,0019	0,1966
1	14/04/2004 23:57:02	BARRA 138KV	0,1042	0,0208	0,1670	0,0009	0,0173
1	14/04/2004 23:57:02	BARRA 138KV	0,1005	0,0215	0,1728	0,0011	0,0177
1	14/04/2004 23:57:02	BARRA 138KV	0,1007	0,0229	0,1961	0,0020	0,0183
1	14/04/2004 23:57:02	BARRA 138KV	0,1073	0,0243	0,2288	0,0036	0,0186
1	14/04/2004 23:57:02	BARRA 138KV	0,2736	0,2819	0,5195	0,0186	0,1360
1	14/04/2004 23:57:02	BARRA 138KV	0,1018	0,7090	0,4041	0,0455	0,4223
1	23/04/2004 07:37:52	BARRA 138KV	0,3096	0,1014	0,3922	0,0218	0,0624
1	04/05/2004 08:58:41	BARRA 138KV	0,2182	0,0938	0,4082	0,0210	0,0562
1	18/05/2004 03:30:13	BARRA 138KV	0,0858	0,0090	0,0914	0,0000	0,0082
1	18/05/2004 03:30:13	BARRA 138KV	0,1014	0,3792	0,3932	0,0299	0,2300
1	18/05/2004 03:30:13	BARRA 138KV	0,0003	1,9146	0,0041	0,0002	1,9055
1	26/05/2004 02:38:10	BARRA 138KV	0,3053	0,1028	0,3921	0,0226	0,0632
1	06/07/2004 04:40:34	BARRA 138KV	0,4130	0,1014	0,4834	0,0172	0,0530
1	06/07/2004 04:40:34	BARRA 138KV	0,6889	0,1792	0,7116	0,0016	0,0520
1	02/09/2004 19:27:57	BARRA 138KV	0,2741	0,3028	0,3738	0,0163	0,1903
1	04/09/2004 06:41:06	BARRA 138KV	0,1654	0,0979	0,3515	0,0337	0,0643
1	07/10/2004 22:09:07	BARRA 138KV	0,3575	0,1007	0,4309	0,0201	0,0580

### 3.1 O classificador de Bayes

O classificador de Bayes utiliza um algoritmo de decisão baseado na probabilidade condicional de cada atributo do evento tratado. A observação da dependência entre os atributos ou variáveis utilizados na classificação concede a este classificador a qualidade de um maior poder discriminatório, além da característica de aprendizado a partir da experiência. Cada padrão é definido por um vetor  $x$  sendo que na abordagem estatística  $x$  é um vetor aleatório de dimensão  $d$ . Os vetores de atributos pertencem a um espaço  $\Omega$  de atributos  $d$ -dimensional (normalmente  $\Omega = \mathfrak{R}_d$ ). Um vetor  $x$  pode provir ou ser associado a uma de  $c$  classes  $\omega_1, \omega_2, \dots, \omega_c$  com uma probabilidade  $P_i$ , chamada probabilidade à priori de cada classe. Sendo que:

$$\sum_{i=1}^c P_i = 1 \quad (1)$$

Define-se  $p(x | \omega_i)$  como a função de densidade de probabilidade multivariada de  $x$  quando se sabe que ele pertence a classe  $\omega_i$  ( $i = 1, 2, \dots, c$ ). A função de densidade de probabilidade global de  $x$  é:

$$p(x) = \sum_{i=1}^c P_i p(x | \omega_i) \quad (2)$$

Além das possíveis classificações para  $x$ , pode ser interessante rejeitar o padrão, classificando-o

como pertencente a uma classe  $\omega_0$  de rejeição.

Neste caso temos  $c+1$  decisões possíveis. Para modelar os processos de decisão temos que definir o conjunto de possíveis regras de decisão:

$$\omega(x) : \Omega \rightarrow \{\omega_0, \omega_1, \omega_2, \dots, \omega_c\} \quad (3)$$

Para definição do critério de classificação é preciso quantificar o custo de se cometer um erro de decisão. Indica-se o custo de se decidir por  $\omega_i$  quando a classe verdadeira é  $\omega_j$ , como:

$$C(\omega_i | \omega_j) = C_{ij} \quad (4)$$

onde:  $i = 0, 1, \dots, c; j = 1, \dots, c$ ;

Estes custos referem-se a cada par, onde o elemento  $i$  é o classificador e o elemento  $j$  é fonte geradora de padrões. A partir da matriz de custos  $C$  são estabelecidos os critérios de classificação do classificador de Bayes.

### 3.2 Rede neural probabilística

A rede neural probabilística, *PNN – Probabilistic Neural Network*, é uma extensão da rede RBF - *Radial Basis Function*. Quando uma entrada é apresentada, a primeira camada computa a distância do vetor de entrada aos vetores de treinamento, produzindo um vetor cujos elementos indicam a distância do vetor de entrada para os vetores de treinamento (classes). A segunda camada soma a contribuição da entrada para cada classe, produzindo em sua

saída um vetor de probabilidades. Finalmente, uma função de transferência competitiva encontra a classe com maior probabilidade de representar o vetor de entrada. Um classificador PNN tem o comportamento de um classificador de Bayes e sua relativa facilidade de implementação e treinamento a tornam ideal para um sistema automatizado de classificação.

As redes neurais artificiais do tipo RBF são estruturas de rede que, usando campos receptores locais, executam funções de mapeamento. Treinar este tipo de rede corresponde a encontrar uma superfície em um espaço multidimensional que provê aos dados de treinamento o melhor ajuste do ponto de vista estatístico. A figura 1 apresenta a estrutura de uma rede tipo RBF.

O nível de ativação da  $i$ ésima unidade é dado por:

$$\omega_i = R_i(x) = R_i(\|x - u_i\| / \sigma_i), \quad i = 1, 2, \dots, H \quad (5)$$

onde  $x$  é um vetor de entrada multidimensional,  $u_i$  é um vetor com a mesma dimensão que  $x$ ,  $H$  é o número de funções de base radial e  $R_i$  é a  $i$ ésima função de base radial com um único máximo. O vetor de entrada é comparado com cada um dos  $H$  vetores  $u_i$ , que representam os centros das funções de base radial. Um conjunto de pesos  $w_i$ , resultantes dessa computação, representa o grau de proximidade do vetor de entrada a cada um destes centros. Não existe nenhuma conexão de pesos entre a camada de entrada e a camada escondida. Tipicamente,  $R_i(x)$  é uma função Gaussiana (6).

$$R_i(x) = \exp\left(-\frac{\|x - u_i\|^2}{2\sigma_i^2}\right) \quad (6)$$

Dessa forma o nível de ativação da função de base radial  $R_i(x)$ , computado pela  $i$ ésima unidade da camada escondida, é máximo quando o vetor de entrada  $x$  está no centro da unidade  $u_i$ .




Figura 1 - Diagrama esquemático de uma RBFN com três unidades de campos receptivos.

A saída da rede pode ser computada tomando-se a soma ponderada do valor de saída associada a cada unidade, (7) ou tomando-se a média ponderada da saída associada a cada unidade.

$$d(x) = \sum_{i=1}^H c_i \omega_i = \sum_{i=1}^H c_i R_i(x) \quad (7)$$

#### 4.0 AVALIAÇÃO DOS CLASSIFICADORES

Com o objetivo de avaliar o classificador PNN utilizado no desenvolvimento deste trabalho foi adotado um processo de classificação a partir de dados aleatórios, provenientes de uma fonte geradora de dados. Esta fonte geradora é capaz de gerar conjuntos de dados aleatórios para diferentes classes, com média, desvio padrão e covariância definidos à priori.

Assim foram gerados dois conjuntos de dados: um conjunto de treinamento e outro de teste, cada um com um número  $n$  de classes bem definidas, similares entre os dois conjuntos. Como os classificadores abordados têm por característica o aprendizado supervisionado, é necessário proceder ao treinamento do classificador antes da classificação.

Utilizando ambos os classificadores (Bayes e PNN) foram realizadas várias sessões de classificação. A figura 2 apresenta a evolução no aprendizado dos dois classificadores com o aumento progressivo do número de padrões de treinamento utilizados e a subsequente classificação de todos os padrões de teste. O decréscimo no número de erros de classificação indica a definição de uma tendência de reconhecimento de padrões.

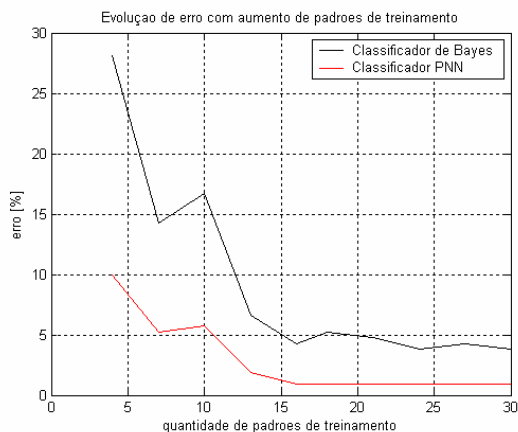


Figura 2 – Evolução no aprendizado do classificador PNN comparado à evolução do classificador de Bayes.

## 5.0 CLASSIFICAÇÃO DE AFUNDAMENTOS DE TENSÃO

Na aplicação da metodologia de classificação de padrões de afundamentos de tensão é utilizado um algoritmo de agrupamento por distância Euclidiana e o classificador PNN, em um conjunto de dados referentes a dois anos de monitoramento (período compreendido entre 2003 e 2004) em um local - barra de 138 kV do sistema elétrico de um consumidor com problemas de QEE. Todo o procedimento de classificação (multivariáveis) é realizado considerando-se os diversos atributos resultantes da caracterização dos afundamentos de tensão registrados: amplitude, duração, hora do dia, canal de medição, média, desvio padrão, mediana, perda de tensão e perda de energia.

O algoritmo de agrupamento determina a separação dos padrões em grupos. Os grupos encontrados são tomados como padrões de treinamento para a rede neural probabilística que, depois de treinada, armazena informações que determinam a probabilidade condicional de um novo padrão de afundamento de tensão pertencer a um dos grupos pré-definidos. Em seguida são selecionados eventos de afundamentos de tensão do mesmo local, em um período maior. Os eventos são submetidos à rede PNN e classificados. A classificação resultante apresenta como os demais padrões de afundamentos de tensão se enquadram no classificador previamente treinado.

A partir da classificação obtida é realizada uma análise classe por classe para verificação de suas características. Há uma série de possibilidades ao se efetuar o procedimento de classificação, alterando as variáveis de classificação, o número de classes e mesmo as populações de dados de treinamento e de classificação, bem como há

uma série de possibilidades para a avaliação dos afundamentos de tensão a partir da classificação de padrões. A figura 3 apresenta em um gráfico tridimensional três classes de afundamentos de tensão (as classes mais populosas) descritas segundo três das variáveis de classificação.

Uma forma mais utilizada de avaliação de dados multidimensionais por parte de um especialista é o diagrama de ligação de múltiplos gráficos bidimensionais de pontos de dispersão, como na figura 4, [4], que apresenta este diagrama para três variáveis selecionadas, as variáveis mais discriminantes. Em cada coluna uma variável é fixada no eixo x e em cada linha uma variável é fixada no eixo y. A partir deste diagrama é possível o reconhecimento visual das componentes principais, dos relacionamentos entre as variáveis e a discriminação das classes.

## 6.0 CONCLUSÕES

A partir de uma metodologia de classificação de padrões aplicada à análise de dados referentes aos afundamentos de tensão pode-se obter o reconhecimento de padrões de ocorrência deste fenômeno. Para a realização da classificação é preciso um conhecimento prévio das características das classes. Este conhecimento foi obtido pelo agrupamento de dados, aqui realizado pela distância Euclidiana entre os padrões, e representa o conhecimento especialista. Os grupos encontrados foram utilizados para treinamento do classificador de padrões. Com o treinamento da rede neural probabilística os grupos passam a ter uma representação estatística e os eventos de afundamentos de tensão, inclusive de outras bases de dados, podem ser por ela classificados. O potencial de classificação da rede neural probabilística foi comparado a um classificador de Bayes, demonstrando tendências de aproximação semelhantes.

A partir dos resultados parciais obtidos, acreditamos que a utilização de uma ferramenta como esta, associada a uma base de dados referentes à qualidade da energia elétrica, da qual seja possível recuperar informações sob a forma de consultas direcionadas, o SGQEE, num processo iterativo, pode fornecer uma metodologia eficiente na qualificação do desempenho do fornecimento de energia elétrica dentro de critérios de conformidade adotados. Esta metodologia é ponto de partida para desenvolvimento de um Sistema Especialista para análise da QEE - SEQEE, em desenvolvimento pelos autores.

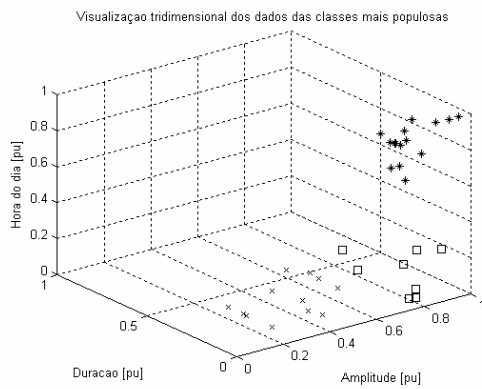


Figura 3 – Classificação dos padrões de afundamentos de tensão pela rede probabilística – PNN. Os símbolos representam as classes dos afundamentos.

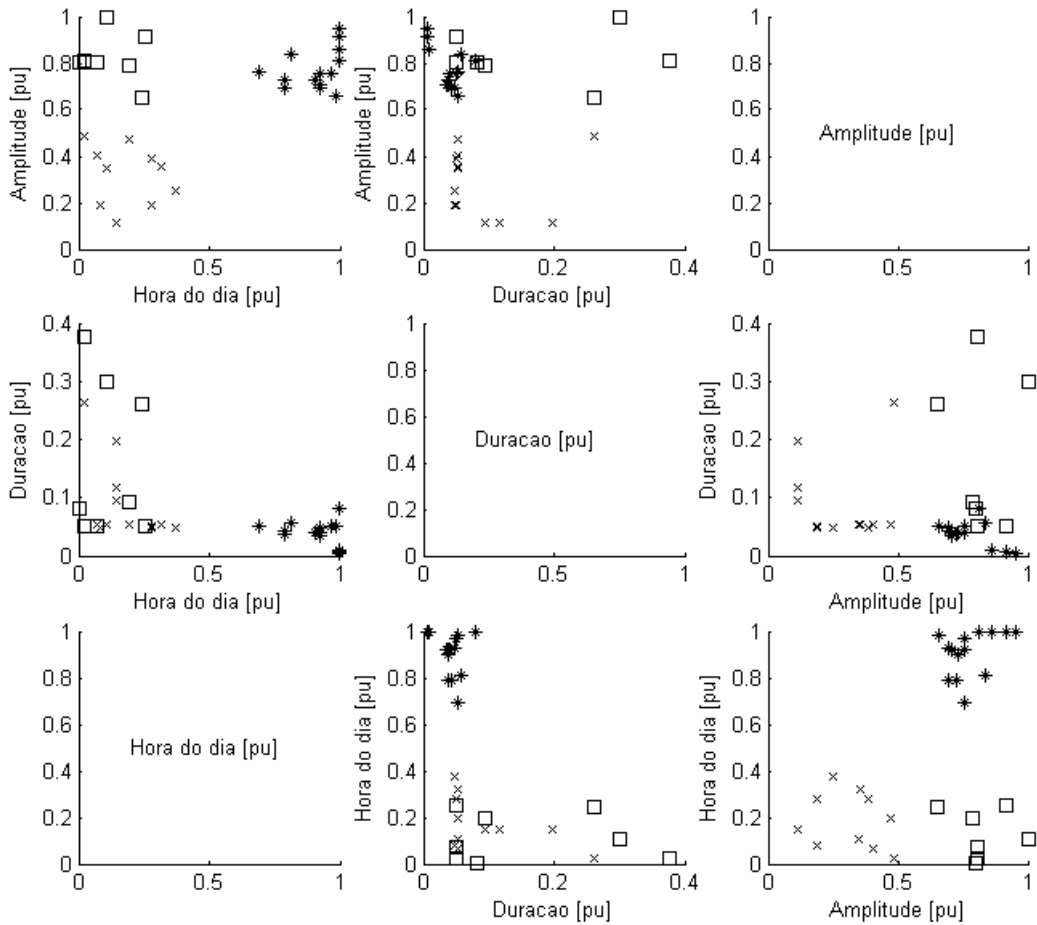


Figura 4 – Ligação de múltiplos gráficos bi-dimensionais de pontos de dispersão. Apresentação de três variáveis separadas nas três classes mais populosas.

## 7.0 AGRADECIMENTOS

À Companhia Energética de Minas Gerais – CEMIG pelo apoio financeiro através do projeto P&D007 – Gerenciamento da Qualidade da Energia Elétrica.

## 8.0 REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Dugan, R.C. McGranaghan, M.F., Beaty, H.W., "Electrical Power Systems Quality", McGraw- Hill, 1996, 265p.
  - [2] Alves, M.F., Fernandes, D.E.B., "Development of an Automated Power Quality Management System", 1999 IEEE/PES Transmission and Distribution Conference, New Orleans, apr., 1999.
  - [3] Alves, M.F., Fonseca, V.R.C., "Estimativa Estocástica de Afundamentos Tensão", XIII Congresso Brasileiro de Automática – CBA 2000, Florianópolis S.C., setembro de 2000.
  - [4] Johnson, R.A., Wichern, D.W. "Applied Multivariate Statistical Analysis", Prentice Hall, 3rd edition, New Jersey, USA, 1992, 642p.
  - [5] Haykin, Simon, "Neural Networks - A Comprehensive Foundation", Macmillan Publishing Company, USA, 1994, 696p.
  - [6] IEEE STANDARDS BOARD, "IEEE Std C37.111-1999 – IEEE Standard Common Format for Transient Data Exchange (COMTRADE) for Power Systems", USA, mar., 1999, 47p.
  - [7] IEEE STANDARDS BOARD, "IEEE Std 1159.2 Working Group 1996 – "Task Force on Characterization of a Power Quality Event Given An Adequately Sampled Set of Digital Data Points",
  - [8] ONS (Operador Nacional do Sistema Elétrico), GQEE – EFEI Grupo de Estudos em Qualidade da Energia Elétrica, "Estado da Arte de Indicadores para Afundamentos de Tensão", ONS-2.1-022/2001.
- Kohn, A. F., "Reconhecimento de Padrões – Uma Abordagem Estatística", Escola Politécnica - USP, São Paulo, 1998, 205p.

