

CÁLCULO DE ÍNDICES DE CONFIABILIDADE DE SISTEMAS DE POTÊNCIA UTILIZANDO REDES NEURAIS

J.C.S. Souza
CAA/UFF
Rio de Janeiro
julio@ic.uff.br

M. Th. Schilling
CAA/UFF
Rio de Janeiro
schilling@ic.uff.br

A. P. Alves da Silva
EFE I
Itajubá
alex@iee.efei.br

M. B. Do Coutto Filho
CAA/UFF
Rio de Janeiro
mbrown@caa.uff.br

Brasil

Abstract

This paper describes a new computational approach to assess power systems reliability using Artificial Neural Networks (ANN). The suggested procedure may be useful in a competitive environment, where the exchange of information among utilities may be subject to hindrances due to conflict of interests or competition.

1. INTRODUÇÃO

A solução de problemas que ocorrem durante a operação de sistemas de potência nem sempre é fácil de ser implementada. Dessa maneira, a monitoração e análise de índices de confiabilidade da operação de sistemas de potência é essencial para que se possa conhecer o risco associado a cada cenário operativo [1].

Atualmente, a grande maioria das aplicações de análise de confiabilidade de sistemas de potência estão associadas a estudos de planejamento. Isto pode ser explicado pelo fato de que os engenheiros envolvidos em estudos de planejamento geralmente dispõem de tempo suficiente para a análise de diversas alternativas, realização de diversas simulações e implementação dos ajustes necessários. Por outro lado, na análise de sistemas de potência no ambiente de operação o tempo disponível é drasticamente reduzido, podendo ser necessário inclusive a análise em tempo-real.

Refletindo a importância deste tema, a literatura técnica [1,2] registra propostas de uma grande variedade de índices, além da aplicação de técnicas de medição e previsão. Entretanto, observa-se que a aplicação de técnicas de inteligência computacional não foi ainda suficientemente explorada.

Dentre as técnicas de inteligência computacional pode-se citar as redes neurais (RNs), as quais são capazes de extrair conhecimento e aprender a resolver um problema específico através do processamento de um conjunto de dados históricos ou obtidos através de simulação. Estes dados são compostos por uma coleção de exemplares que contém associações entre um conjunto de características (variáveis) importantes para a solução do problema e a solução do problema propriamente dita. Diversos modelos de redes neurais foram propostos na literatura, diferindo basicamente no

que diz respeito a topologia adotada, modelo do neurônio e regra de aprendizagem [3-5,23].

Este trabalho apresenta uma abordagem que utiliza redes neurais para a avaliação da confiabilidade de sistemas de potência. A metodologia proposta pode ser útil para a análise da operação em ambiente competitivo, onde a troca de informações entre empresas pode ser restrita devido a conflitos de interesse e a capacidade de processamento através de técnicas convencionais pode não ser possível devido a restrições de tempo e/ou perda de dados.

2. ANÁLISE DE CONFIABILIDADE

Várias aplicações de inteligência computacional a sistemas de potência podem ser encontradas na literatura. Entretanto, aplicações específicas ao problema de análise de confiabilidade são muito raras [2,3,6-14].

Holen *et alii* [19] relata uma das primeiras aplicações, baseada na utilização de sistemas especialistas para a análise de confiabilidade de sistemas de potência.

Amjady *et alii* [20] propõe uma abordagem para a estimação de parâmetros de confiabilidade, tais como tempo médio para reparo, taxa de saída forçada e durações. Esta talvez seja uma das primeiras tentativas de utilizar uma rede neural (RN) para resolver diretamente problemas simples de análise de confiabilidade. Dash *et alii* [21] propõe uma abordagem para a estimação da qualidade de sistemas de potência, utilizando ADALINES.

Várias outras aplicações de RNs foram propostas, tais como análise de segurança em tempo-real, previsão de carga, processamento de alarmes, diagnóstico de defeitos, estimação de estado e controle [3]. Entretanto, aplicações ao problema de análise de confiabilidade permanecem raras. Porém, pode-se enumerar algumas razões que indicam que este panorama poderá mudar em breve.

Por um lado, a medida que a operação de sistemas de potência utiliza cada vez mais dispositivos eletrônicos de rápida resposta (*e.g.* FACTS) e se tornam cada vez mais estressados, aumenta a influência das não-linearidades inerentes a operação sobre o comportamento do sistema [15], reduzindo o grau de segurança da operação. Pode-se antever que os operadores necessitarão determinar a

robustez do cenário de operação corrente, face a ocorrência de distúrbios e mudanças de parâmetros. Por outro lado, a análise de risco no curto prazo é reconhecidamente uma função bastante complexa, estocástica e não-linear dos modelos de estado, distúrbios, incertezas, e seu cálculo via força bruta envolveria um número extremamente elevado de simulações Monte Carlo [14,16], cada uma consistindo de cálculos numéricos bastante complexos. Além disso, existe uma tendência bastante clara da redução do tempo disponível para a tomada de decisões, já que os operadores deverão avaliar praticamente em tempo-real a robustez do ponto de operação corrente com respeito a possíveis mudanças de parâmetros ou ocorrência de distúrbios [15-18].

Esta situação parece ser apropriada para a aplicação de técnicas de inteligência computacional, e em particular de RNs.

Além disso, outra forte motivação para a utilização de técnicas de inteligência computacional é a necessidade da análise de segurança probabilística. Apesar de até agora a análise de segurança ser basicamente realizada de forma determinística, percebe-se que a análise de segurança probabilística será necessária, de modo a estabelecer uma relação de compromisso entre custo e confiabilidade do ponto de operação, essencial para a sobrevivência na nova estrutura competitiva do mercado de energia e elétrica [14,16]. As RNs apresentam capacidade de extrapolação e são tolerantes a falhas, sendo capazes de lidar com as variações estocásticas do ponto de operação programado e também com dados incompletos, enquanto métodos clássicos necessitam de dados precisos e completos. A capacidade de interpolação não linear das RNs permite tratar casos inéditos, sendo esta uma característica bastante importante para a análise de confiabilidade probabilística. Como um último argumento, a rapidez de resposta de uma RN previamente treinada pode ser decisiva para a análise de confiabilidade no horizonte de curto prazo a tempo-real.

3. METODOLOGIA PROPOSTA

A Figura 1 apresenta as etapas básicas do processo de treinamento e construção *offline* da RN para análise de confiabilidade. Algumas destas etapas são comentadas a seguir.

Na análise da confiabilidade de sistemas de potência, um dos objetivos principais é capturar todos os fatores de influência relevantes, mantendo a dimensão e a complexidade do problema sob controle. A Tabela 1 resume alguns aspectos que podem influenciar a composição e a avaliação numérica do espaço de estado probabilístico.

As colunas da *Matriz de Dados de Entrada - MDE*, (veja o bloco 1 na Fig. 1) estão diretamente relacionadas com os aspectos apresentados na Tabela 1. Portanto, cada linha da *MDE* representa um cenário específico,

que corresponde a um certo grau de confiabilidade, descrito por um conjunto de índices de confiabilidade. Nas simulações realizadas neste trabalho, vários fatores apresentados na Tabela 1 são considerados, com exceção das programações de manutenção, da representação direta das fontes de energia primária, dos fatores ambientais e dos esquemas de proteção. Como o objetivo do trabalho é tratar o problema no horizonte de operação a curto prazo, a representação da variação de carga é possivelmente o fator mais importante a ser considerado. As incertezas são representadas através de taxas de falha e tempos médios para reparo de geradores, linhas de transmissão e transformadores.

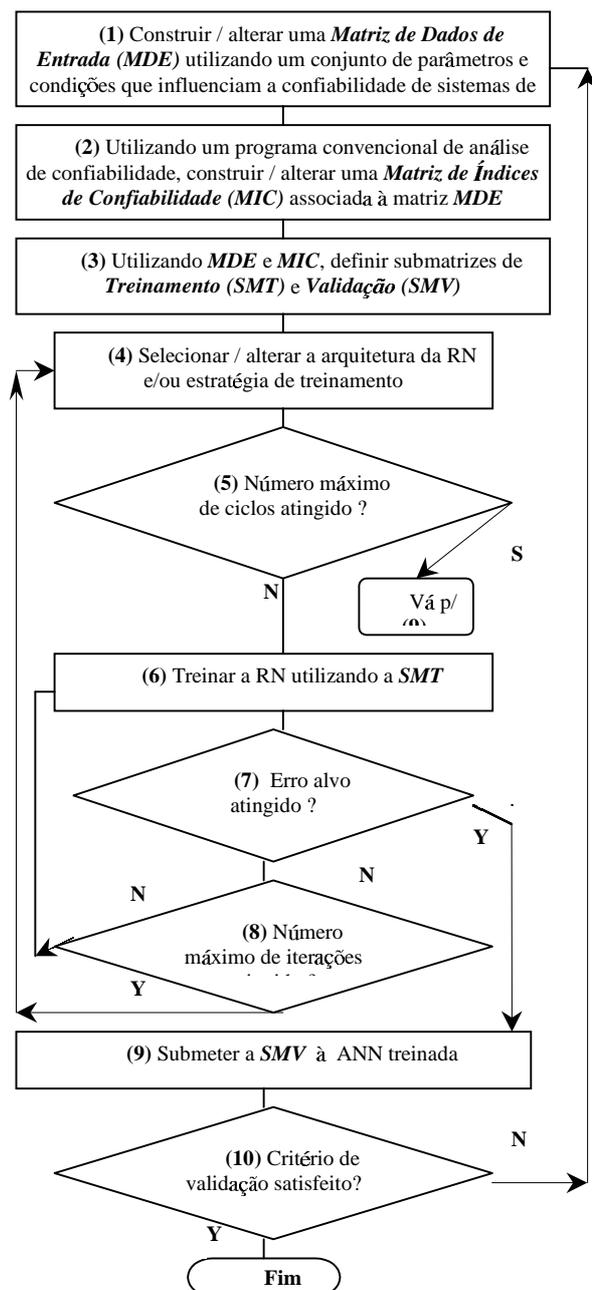


Figura 1 – Processo de Treinamento

Na análise de confiabilidade no curto prazo, alguns parâmetros (colunas de *MDE*) podem ser mantidas constantes e representam fenômenos associados à dinâmica lenta. É importante ressaltar que cada linha da matriz *MDE* deve ser submetida a um programa convencional de análise de confiabilidade, de modo a se obter um conjunto de índices de confiabilidade globais e/ou locais associados a cada cenário avaliado (veja o bloco 2 na Fig. 1). Neste trabalho, o programa convencional utilizado para a obtenção de índices de confiabilidade que compõem as saídas desejadas para o treinamento da RN, foi o *NH2* [2].

Tabela 1 – Fatores de influência para a simulação e modelagem do espaço de estado probabilístico

<ul style="list-style-type: none"> - Interferência Humana - <i>definição dos limites de operação normal e de emergência do sistema, políticas de despacho e ações corretivas, políticas de manutenção, ação numérica e ação</i> - Fontes de energia primária - Fatores ambientais - <i>hidrologia, temperatura, etc.</i> - Modelos dos equipamentos de geração - Topologia da rede - <i>linhas, transformadores, subestações, proteção,</i>
--

Os índices de confiabilidade calculados pelo programa convencional são armazenados na **Matriz de Índices de Confiabilidade - MIC**. A cada linha de *MIC* corresponde uma linha específica de *MDE*, já que uma linha que contém parâmetros que definem um cenário em *MDE* está associada a um conjunto de índices de confiabilidade armazenados em uma linha específica de *MIC*. Estas matrizes podem então ser combinadas para formar uma base de dados completa, que contém os parâmetros observados (colunas de *MDE* – entradas) e os índices de confiabilidade correspondentes (colunas de *MIC* – saídas). Desta base de dados pode-se extrair duas submatrizes independentes: a **Submatriz de Treinamento (SMT)** e a **Submatriz de Validação (SMV)** – bloco 3 da Fig. 1. Estas submatrizes são empregadas para o treinamento e validação do treinamento da RN.

O processo de treinamento da RN (bloco 4) inclui: *variação dos pesos iniciais, das taxas de aprendizado e de momento, do número de neurônios e camadas, ajuste do erro alvo e número máximo de iterações*. A melhor arquitetura é encontrada de forma heurística. Neste trabalho o modelo de RN adotado foi o Perceptron de Múltiplas Camadas (*MLP - Multilayer Perceptron*) treinado através do método da retropropagação de erros (*Backpropagation*) [5,23]. As simulações foram realizadas utilizando o toolbox de Redes Neurais do software Matlab.

No bloco 10, um critério para validação necessita ser definido. Por exemplo, o treinamento pode ser considerado satisfatório se pelo menos 90 % das saídas obtidas apresentam erros percentuais menores ou iguais a 10 % quando comparados com as saídas desejadas. Outras estratégias para validação podem também ser propostas, dependendo de cada caso.

4. TESTES E RESULTADOS

Testes foram realizados utilizando o sistema teste *RB* [22], ilustrado na Figura 2.

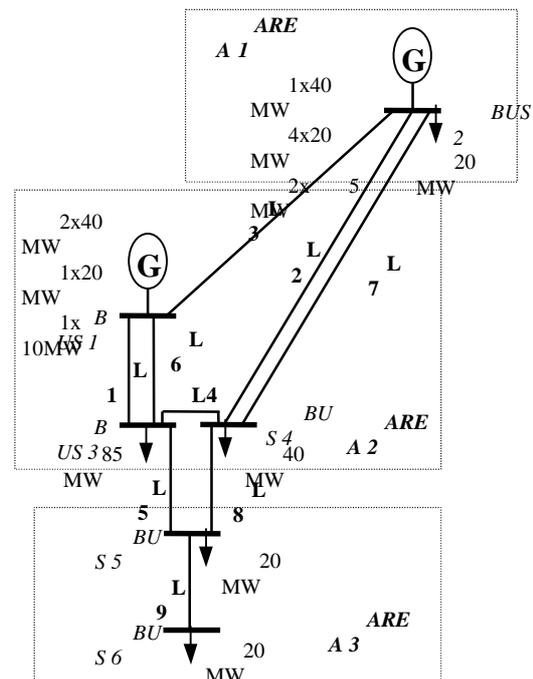


Figura 2 - Sistema teste RB [22]

Nos testes realizados, o objetivo foi prever os índices de confiabilidade (tanto globais quanto por barra) a partir de uma massa de dados contendo o comportamento da carga, topologia da rede, ponto de operação, taxas de falha de equipamentos e tempos médios para reparo, etc. A abordagem tradicional, através de técnicas convencionais de análise de confiabilidade [2], poderia ser aplicada caso o ambiente de estudo fosse de planejamento, quando o tempo requerido para resposta não é um fator crítico. Entretanto, no ambiente de tempo-real, a utilização de redes neurais se torna atraente e parece ser apropriada, desde que tenham sido adequadamente treinadas *offline* utilizando exemplares de treinamento obtidos através do emprego de técnicas convencionais de análise de confiabilidade. É importante enfatizar que o treinamento deve ser realizado *offline* e uma única vez. Após treinada, a RN deve ser capaz de realizar inferências em tempo-real.

Teste # 1:

Neste teste as entradas das RN são os valores totais de potência ativa e reativa em três diferentes áreas do sistema. Foram utilizadas três RNs, cada uma contendo uma única saída. A saída de cada RN é responsável por estimar um índice de confiabilidade global, ou seja: *probabilidade de perda de carga (LOLP)*, *expectativa de energia não suprida (EENS)*, e *frequência de perda de carga (LOLF)*. Uma base de dados contendo 1000 padrões foi construída utilizando o programa NH2. O conjunto de treinamento (*SMT*) e validação (*SMV*) foram extraídos dessa base de dados. Durante as simulações foi considerada uma variação de carga entre 50% a 105% do valor de pico de 185 MW. A Tabela 2 e as Figuras 3, 4 e 5 resumem os resultados da simulação.

Tabela 2 – Resultados para o teste # 1

	LOLP	EENS	LOLF
Número de padrões de treinamento	500	300	500
Número de entradas	6	6	6
Número de saídas	1	1	1
Número de camadas			
Número de neurônios			
Número de padrões "éditos" (validação)	500	700	500
Percentual de padrões por faixa de erro (%)			
0 - 5	10,0 0	40,2 8	28, 20
5 - 10	9,40	28,8 5	26, 00
10 - 15	3,20	16,4 2	21, 60
15 - 20	6,00	6,28	13, 60
20 - 30	14,2 0	5,71	10, 00
30 - 50	12,0 0	2,00	0,6 0
> 50	45,2 0	0,42	0

Nas Figuras 3, 4 e 5 a linha cheia representa os resultados obtidos com o programa NH2, enquanto a linha tracejada representa os resultados obtido pela RN. Da Tabela 2 e Figuras 3-5 pode-se observar que o índice EENS foi estimado com bastante precisão pela RN. Os resultados obtidos na estimativa da LOLP refletem uma dificuldade para estimar este índice, que é intrínseca aos sistemas que possuem alta confiabilidade. Isto confirma um resultado conhecido [2]. Como o NH2 utiliza simulação Monte Carlo para a obtenção dos índices de confiabilidade, o coeficiente de variação requerido para obter uma boa estimativa da LOLF demanda um número

muito grande de amostras. Isto também está refletido nas estimativas obtidas para a LOLF.

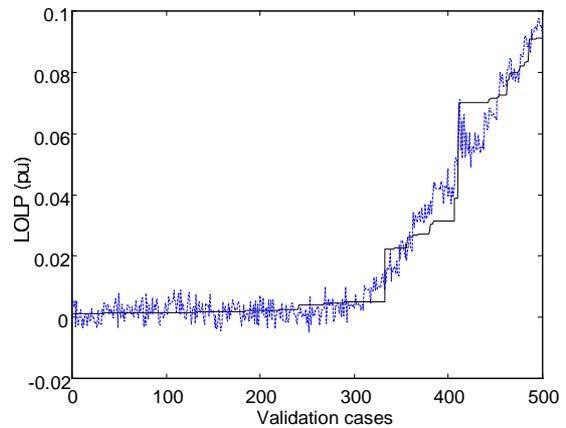


Figura 3 – Estimativa da LOLP

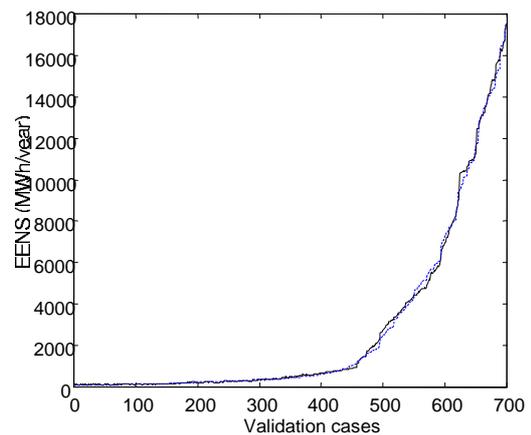


Figura 4 – Estimativa da EENS

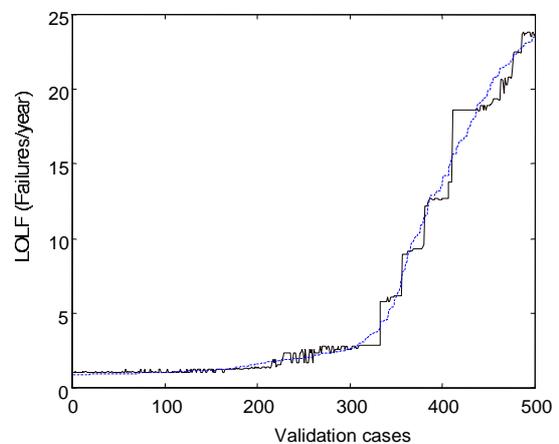


Figura 5 – Estimativa da LOLF

Teste # 2:

Neste teste são novamente utilizadas três RNs, cada uma contendo três variáveis de entrada (valores percentuais de carga em cada área) e uma única saída, responsável por estimar um índice de confiabilidade específico (LOLP, EENS e LOLF) associado à barra 6. Os conjuntos de treinamento e validação foram obtidos a partir da simulação de 1000 diferentes cenários de operação, onde a carga total variou entre 50% a 105% do valor de pico de 185 MW. A Tabela 3 e as Figura 6 e 7 ilustram os resultados obtidos. O número de exemplares utilizados não permitiu obter uma estimativa para o índice LOLF da barra 6.

Tabela 3 - Resultados para o teste # 2

	LOLP	EENS
Número de padrões de		
Número de entradas	3	3
Número de saídas	1	1
Número de camadas		
Número de neurônios		
Número de padrões "editados" (validação)	500	700
Percentual de padrões		
0 - 5	9,20	64,85
5 - 10	6,40	28,00
10 - 15	7,20	4,85
15 - 20	7,40	0,85
20 - 30	19,20	0,57
30 - 50	22,40	0,71
> 50	28,20	0,14

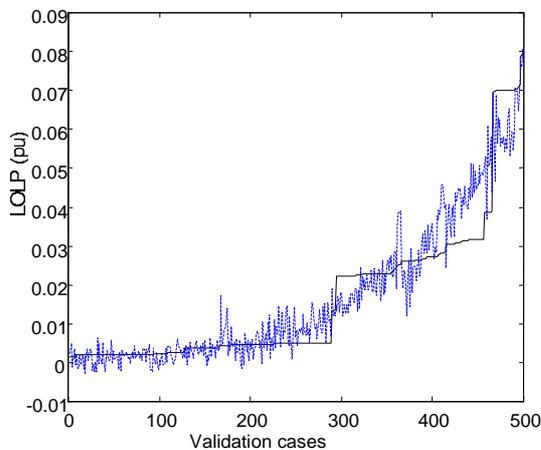


Figura 6 - LOLP estimada para a barra 6

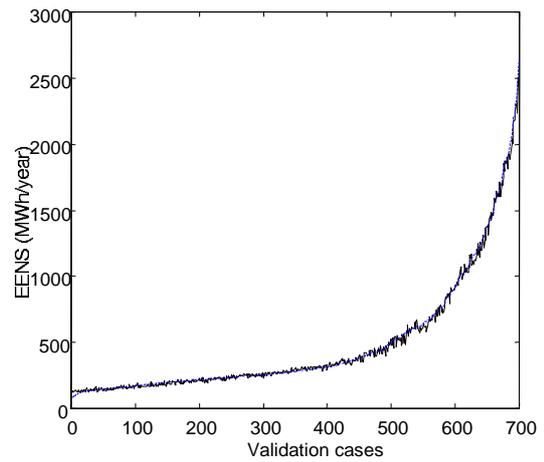


Figura 7 - EENS estimada para a barra 6

5. CONCLUSÕES

Este trabalho apresentou uma abordagem para a análise de confiabilidade de sistemas de potência utilizando redes neurais. Foi possível observar o potencial de aplicação de tal abordagem, a qual pode ser útil em um ambiente competitivo, onde a troca de informações entre empresas pode ser limitada. Foi discutido que a utilização de RNs fornecendo estimativas confiáveis em um tempo computacional desprezível se torna uma alternativa bastante atraente para a análise de risco da operação a curto prazo e em tempo-real. Nestes cenários, as RNs são capazes de responder bem na presença de restrições como indisponibilidade de dados e escassez de tempo para análise.

6. AGRADECIMENTOS

Os autores agradecem o *CNPq* e a *FINEP/RECOPE* (através do Projeto *SAGE 0626/96*) pelo apoio financeiro. Ao aluno Helder S. de Carvalho os autores agradecem pela colaboração nas simulações.

7. REFERÊNCIAS

[1] IEEE Task Force, "Reporting Bulk Power System Delivery Point Reliability", *IEEE Trans. on PWRS*, Vol 11, no 3, pp. 1262-1268, Aug 1996.

[2] R. N. Allan, R. Billinton, A. M. Breipohl, C. H. Grigg, "Bibliography on the Application of Probability Methods in Power System Reliability Evaluation 1992-1996", *IEEE PES Summer Meeting*, 1997.

[3] T. S. Dillon, D. Niebur (Editors), "*Neural Network Applications in Power Systems*", CRL Pub. Ltd., London, UK, (Chap. 2), 1996.

- [4] D. B Fogel, "*Evolutionary Computation, Toward a New Philosophy of Machine Intelligence*", IEEE Press, USA, 1995.
- [5] M. H. Hassoun, "*Fundamentals of Artificial Neural Networks*", The MIT Press, Cambridge, USA, 1995.
- [6] V. Sagar, S. Vankayala, N. D. Rao, "Artificial Neural Networks and their Applications to Power Systems - a Bibliographical Survey", *Electric Power Systems Research*, Vol 28, pp.67-79, 1993.
- [7] S. Talukdar, G. Rosenwald, "State-of-the-Art of Expert System Applications to Power System Problems", in *Knowledge-Based System Techniques with Applications to Power Systems*, IEEE Tutorial Course, 93 EHO 387-1-PWR, Oct 1993.
- [8] D. Niebur (Convener), "Neural Network Applications in Power Systems", *Int. J. of Eng. Intelligence Systems*, Vol 1, no 3, pp. 133-158, Dec 1993.
- [9] Y.-H. Song, A. Johns, R. Aggarwal, "*Computational Intelligence Applications to Power Systems*", Kluwer Academic Pub., Dordrecht, (Chaps 1, 8), 1996 .
- [10] D. Srinivasan, F. Wen, C.S. Chang, A.C. Liew, "A Survey of Applications of Evolutionary Computing to Power Systems", *IEEE Publication* 0-7803-3115-X/96, pp.35-41, 1996.
- [11] D. M. Falcão, "High Performance Computing in Power Systems Applications", *2nd. Int. Meeting on Vector and Parallel Processing (VECPAR'96)*, Porto, Portugal, Sep 25-27, 1996.
- [12] V. Miranda, D. Srinivasan, L. M. Proença, "Evolutionary Computation in Power Systems", *Int. J. Elec.Power & Energy Sys.*, Vol 20, no 2, pp.89-98, 1998.
- [13] D. M. Falcão *et alii*, "Intelligent Systems Applications to Power Systems in Brazil: Present Status and Perspectives", *VI Symp. of Specialists in Electric Operational and Expansion Planning (SEPOPE)*, SP-077, Salvador, Brazil, May 24-29, 1998.
- [14] L.A. Wehenkel, "*Automatic Learning Techniques in Power Systems*", Kluwer Pub., Dordrecht, Netherlands,(Chaps. 1, 2, 8, 11,12), 1998.
- [15] I. A. Hiskens , "Analysis Tools for Power Systems-Contending with Nonlinearities", *Proc. of the IEEE*, Vol 83, no 11, pp.1573-1587, Nov 1995.
- [16] R. J. Marceau, J. Endrényi (Conveners), "*Power System Security Assessment: A Position Paper*", *CIGRÉ Task Force 38.03.12*, Final Report, Paris, June 30, 1997.
- [17] E. Demko, "The 21th. Century Needs a Real-Time Reliability Meter (RTRM)", *IEEE Proc. Annual Reliability and Maintainability Symp*, pp.117-121, 1997.
- [18] M. B. L. Lively, "Real-Time Reliability-Based Electricity Pricing", *IEEE Proc. Annual Reliability and Maintainability Symp*, pp.279-284, 1998.
- [19] A. T. Holen, O.B. Fosso, T. Sannes, P. Støa, Å. Botnen, L. Holten, A. Mæland, "Expert Systems in Power System Reliability Assessment", *Proc. of the 14th. Int. Reliability, Availability, Maintainability Conf. for the Electric Power Industry (Inter-RAM)*, Toronto, Canada, pp. 413-420, May 26-29, 1987.
- [20] N. Amjady, M. Ehsan, "Evaluation of Power Systems Reliability by an Artificial Neural Network", Paper PE-182-PWRS-0-1, *IEEE PE S Winter Meeting*, 1998.
- [21] P.K. Dash, S. K. Panda, A.C. Liew, B. Mishra, R.K. Jena, "A New Approach to Monitoring Electric Power Quality", *Electric Power System Research*, Vol 46, pp.11-20, 1996.
- [22] R. Billinton *et alii* , "A Reliability Test System for Educational Purposes-Basic Data", *IEEE Trans. on PWRS*, Vol 4, no 3, pp.1238-1244, Aug 1989.
- [23] S. Haykin, "*Neural Networks: A Comprehensive Foundation*", Macmillan College Publishing Company, 1994.