

REDES NEURAIS ARTIFICIAIS APLICADAS NA ESTIMAÇÃO DA QUANTIDADE DE CARGAS A SEREM REJEITADAS EM SITUAÇÕES DE SUB-FREQUÊNCIA

ATHILA QUARESMA SANTOS* RENATO MACHADO MONARO* LUCIANO CARLI M. DE ANDRADE*
DENIS VINICIUS COURY* MÁRIO OLESKOVICZ*

**Escola de Engenharia de São Carlos (EESC) – Universidade de São Paulo (USP)*
Departamento de Engenharia Elétrica (SEL)
Av. Trabalhador Sancarlene, 400, São Carlos, São Paulo, Brasil

Email: athila.santos@usp.br, monaro@usp.br, lucarli@sc.usp.br, coury@sc.usp.br,
olesk@sc.usp.br

Abstract— This paper uses an Artificial Neural Network (ANN) to estimate the minimum amount of load shedding in Electrical Power Systems (EPSs) in order to recover load-generation balance. The ANN training and testing data were extracted from an EPS simulated through Real Time Digital Simulator (RTDS). The best ANN topology, selected via cross-validation technique, was able to estimate the load shedding quantity with 4.85% of average error.

Keywords— Artificial Neural Network, Multi-Layer Perceptron, Load Shedding, Real Time Digital Simulator.

Resumo— Este trabalho tem como objetivo empregar uma Rede Neural Artificial (RNA) para a realização do cálculo da quantidade ótima de carga a ser rejeitada em Sistemas Elétricos de Potência (SEP) a fim de se restabelecer o equilíbrio geração-demanda. Os dados utilizados nas fases de treinamento e validação da RNA foram extraídos a partir de um SEP modelado através do simulador digital em tempo real RTDS. A melhor topologia da RNA, selecionada pela técnica da validação cruzada, demonstrou sua eficiência com erro médio de 4,85%.

Palavras-chave— Rede Neural Artificial, Perceptron Multicamadas, Rejeição de Carga, *Real Time Digital Simulator*.

1 Introdução

No decorrer dos últimos anos, grandes blecautes ocorreram ao redor do mundo como consta na literatura (Andersson et al., 2005; Corsi and Sabelli, 2004; Chen et al., 2007). Sobrecargas de linhas, instabilidade de tensão, operação e projetos mal dimensionados de proteção e esquemas não funcionais de rejeição de carga são os principais motivos que levaram ao cenário final de colapso do sistema trazendo direta ou indiretamente consequências danosas para a economia e segurança da região afetada (Seyedi and Sanayeh-Pasand, 2009; Yamashita et al., 2009).

Portanto, um controle apropriado capaz de impedir condições catastróficas como situações de sobrecarga é vital para a operação de um Sistema Elétrico de Potência (SEP). Um dos principais esquemas de proteção de sub-frequência é o processo de rejeição de cargas recomendado desde o blecaute de 1965 no nordeste dos Estados Unidos (Taylor, 1992) por prover meios de baixo custo na prevenção de desligamentos e interrupções indesejadas.

Como a frequência é um importante indicador de sintonia entre carga e geração, qualquer desvio em seu valor devido ao excesso de cargas ou incidentes não previstos, como faltas, defeitos em equipamentos, perda de geração ou perda de linhas, etc. pode levar a um estado de emergência (Tyagi et al., 2013; Rad and Abedi, 2008). Os

efeitos de uma queda na frequência podem resultar em falhas em cascata, causando perdas de sincronia e finalmente no colapso geral do sistema.

Assumindo-se que há reserva girante, reguladores de velocidade, podem responder rapidamente para manter a frequência próximo de seu valor nominal, caso contrário, a estratégia de rejeição de cargas deve ser adotada (Mitchell et al., 2000; Tyagi et al., 2013; Rad and Abedi, 2008; Thalassinakis et al., 2006). O esquema mais adequado é aquele que rejeite o menor número possível de cargas, em menor tempo, considerando ainda as restrições do SEP (Hooshmand and Moazzami, 2012).

Uma análise dinâmica de uma rede elétrica após um distúrbio é uma tarefa muito exigente (Mitchell et al., 2000). Dessa forma, inúmeros estudos têm sido propostos para restaurar a frequência de sistemas submetidos a severos distúrbios. Técnicas de sistemas inteligentes têm demonstrado desempenhos superiores à técnicas convencionais (Concordia et al., 1995). Alguns trabalhos empregaram Redes Neurais Artificiais (RNA) (Mitchell et al., 2000; Thalassinakis et al., 2006; Hsu et al., 2008; Hooshmand and Moazzami, 2012), Sistemas *Fuzzy* (Sallam and Khafaga, 2002), Algoritmos Evolutivos (Amraee et al., 2007; Amraee et al., 2006), dentre outros (Shokooh et al., 2005; Parniani and Nasri, 2006).

Desta forma, este trabalho propõe a construção de uma RNA com habilidade de quantificar

o déficit de potência existente entre geração e demanda e, conseqüentemente, sinalizar a quantidade de carga a ser removida do sistema. Com isso, pretende-se aprimorar a tarefa de supervisão do SEP, garantindo uma melhor eficiência na tomada de decisão em esquemas de alívio.

A Seção 2 do trabalho apresenta a filosofia adotada no Brasil para rejeição de cargas. A metodologia empregada na determinação da melhor topologia das RNAs é apresentada na Seção 3. Os resultados obtidos são apresentados na seção 4, bem como uma breve conclusão na Seção 5.

2 Filosofia de Rejeição de Cargas

O processo de rejeição ou alívio de cargas elétricas tem por objetivo manter a margem de geração de energia a nível nominal evitando, em última instância, o colapso geral do sistema (Pimjaipong et al., 2005). Ele também previne a desconexão indesejada, devido às sobrecargas, de ramos importantes que tenham cargas de grande relevância social, econômica, política, potencial ou até mesmo que resultem em impactos negativos para a imagem da concessionária de energia. A rejeição de cargas precisa ser executada quando a demanda elétrica é maior que a oferta. Isso envolve o corte imediato do fornecimento de potência para alguns circuitos elétricos reduzindo assim o estresse do sistema. Esse corte deve ser feito de forma ótima considerando as devidas prioridades e pertinências entre as cargas. O objetivo é prevenir o decaimento de frequência e tensão mantendo-se o equilíbrio entre geração e demanda.

Os métodos clássicos para controle de frequência são baseados em parâmetros tais como:

- A frequência instantânea do sistema, geralmente configurada em níveis em relés de sub-frequência;
- A taxa de variação da frequência $\frac{df}{dt}$, que mede a taxa de variação do desequilíbrio; e
- A taxa de variação média da frequência $\frac{\Delta f}{\Delta t}$, que mede a tendência de variação.

Todos os parâmetros usualmente empregados apresentam vantagens e/ou desvantagens em seu uso e, desta forma, precisam ser analisadas mutuamente para obtenção de melhores resultados (Committee, 2007).

2.1 Modelo de rejeição de cargas adotado no Brasil: ERAC

Conforme aprovado pela Agência Nacional de Energia Elétrica (ANEEL), é de responsabilidade do Operador Nacional do Sistema Elétrico (ONS) efetuar o acompanhamento dos montantes de carga disponibilizados para corte pelo Esquema

Regional de Alívio de Cargas (ERAC), identificando as situações de não conformidade e as necessidades de adequação dos esquemas existentes (ONS, 2004). O ONS dividiu o Brasil em dois blocos com esquemas diferenciados. O primeiro bloco é composto pelas regiões Sul, Sudeste e Centro Oeste enquanto o segundo bloco agrega as regiões Norte e Nordeste. As Tabelas 1 e 2 especificam os estágios de corte e a porcentagem de carga a ser rejeitada em cada nível.

Tabela 1: Rejeição de Cargas (Regiões SE/CO/Sul)

Estágio	SE/CO		Sul	
	Ajuste (Hz)	Carga Rejeitada (%)	Ajuste (%)	Carga Rejeitada (%)
1 ^o	58,5	7	58,5	7,5
2 ^o	58,2	7	58,2	7,5
3 ^o	57,9	7	57,9	10
4 ^o	57,7	7	57,6	15
5 ^o	57,5	7	57,3	15

Fonte: (ONS, 2004)

Tabela 2: Rejeição de Cargas (Regiões N/NE)

Estágio	Região Nordeste			
	Ajuste (Hz)	Carga Rejeitada (%)	Ajuste (%)	Carga Rejeitada (%)
1 ^o	56,5	5,5	57,8	5,5
2 ^o	56	7,5	57,1	7,5
3 ^o	55,8	7,5	57,1	4,5
4 ^o	55,5	8	55,5	8
5 ^o	55,2	8	55,2	8

Fonte: (ONS, 2004)

A partir da observação das Tabelas 1 e 2, conclui-se que, para a correta aplicação do ERAC, um monitoramento contínuo da frequência do SEP deve ser realizado nas subestações de energia a fim de se evitar situações de colapso generalizado nas redes de transmissão e distribuição.

3 Metodologia Empregada

Pretende-se desenvolver um sistema, a partir do aprendizado de uma RNA, capaz de estimar a quantidade ótima de cargas a serem retiradas de um SEP devido à ocorrências de sub-frequência. Um bloco de cargas deve ser manipulado em apenas um passo, conferindo vantagens significativas com os processos atuais que geralmente se baseiam em múltiplos passos para obtenção do equilíbrio de frequência.

O SEP a ser simulado para obtenção dos dados de treinamento e teste da RNA é apresentado na Figura 1. Um gerador com potência de 100MVA é controlado por um regulador de tensão e velocidade responsáveis por determinar o ponto

de equilíbrio do sistema. A carga total é conectada via linha de transmissão dupla LT1–LT2, representando 80% da carga máxima nominal do gerador e distribuída em 5 alimentadores (Barra 3) representados na alta tensão, conforme estabelecido na Tabela 3. Os alimentadores de 1 a 4 representam, cada um, um ponto de controle discreto para remoção de um bloco de cargas. Já o alimentador 5 é um ponto auxiliar para configurações de sobrecarga. Para cada caso de estudo, a potência de consumo variável no alimentador 5 é setada para simular a entrada de grandes blocos de demanda e solicitação excedente da geração, conforme mostrado na Tabela 4. O fator de potência escolhido foi 0,92.

Para melhor representar a dependência da frequência de cada bloco de cargas, optou-se por modelar a demanda solicitada pelo modelo exponencial (Guimarães, 2009). As equações utilizadas pelo RTDS, bem como os valores dos parâmetros genéricos utilizados são exibidos nas Equações 1 e 2, que relacionam as grandezas para composição da potência ativa e reativa consumidas.

$$P = P_0 \left(\frac{V}{V_0} \right)^{K_{pv}} [1.0 + K_{pf} (f - f_0)] \quad (1)$$

$$Q = Q_0 \left(\frac{V}{V_0} \right)^{K_{qv}} [1.0 + K_{qf} (f - f_0)] \quad (2)$$

sendo: $K_{pv} = 0,1$ e $K_{qv} = 0,1$ os parâmetros de sensibilidade da tensão para potência ativa e reativa. $K_{pf} = 1,0$ e $K_{qf} = 1,0$ os parâmetros de sensibilidade da frequência para potência ativa e reativa. $V_0 = 230$ kV e V a tensão nominal e instantânea na Barra 3, respectivamente. $f_0 = 60$ Hz e f a frequência nominal e instantânea na Barra 3, respectivamente. E finalmente, a potência ativa e reativa inicial depende do carregamento na Barra 3, mas para a configuração inicial de 80% da capacidade total, tem-se $P_0 = 73,60$ MW e $Q_0 = 31,35$ MVar.

Tabela 3: Distribuição de cargas

Aliment.	Consumo (%)	Potência (MVA)	Potência (MW)	Potência (MVar)
1	8	8	7,36	3,14
2	16	16	14,72	6,27
3	24	24	22,08	9,41
4	32	32	29,44	12,54
5	–	–	–	–

A modelagem do sistema foi realizada via RTDS (*Real Time Digital Simulation*) que é um sistema digital de testes em tempo real especializado em reproduzir fenômenos transitórios eletromagnéticos de sistemas de potência. O *hardware* é baseado na arquitetura de processamento paralelo com vários Processadores Digitais de Sinais (PDS) de alta velocidade, o que possibilita a representação de grandes esquemas de potência sem

Tabela 4: Sobrecarga no alimentador 5

Sobrecarga (%)	Sobrecarga (MVA)	Sobrecarga (MW)	Sobrecarga (MVar)
5	5	4,6	1,96
10	10	9,2	3,92
15	15	13,8	5,88
20	20	18,4	7,84
25	25	23	9,80
30	30	27,6	11,76
35	35	32,2	13,72
40	40	36,8	15,68
45	45	41,4	17,64
50	50	46	19,60
55	55	50,6	21,56
60	60	55,2	23,52
65	65	59,8	25,47
70	70	64,4	27,43
75	75	69	29,39
80	80	73,6	31,35
85	85	78,2	33,31
90	90	82,8	35,27
95	95	87,4	37,23
100	100	92	39,19

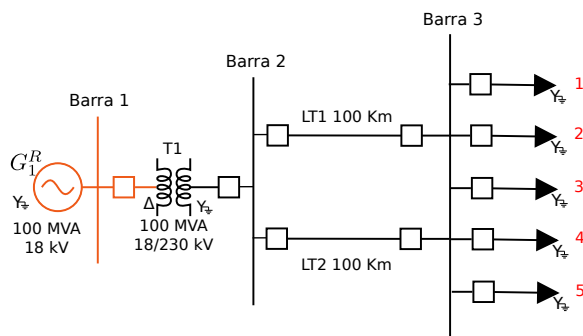


Figura 1: Sistema de simulação para obtenção de dados

o comprometimento do passo de simulação (Kuffel et al., 1995). O RTDS foi utilizado para geração de dados para alimentação das fases de treinamento e testes da RNA, representando o mais próximo possível o comportamento dinâmico do sistema.

Para o desenvolvimento de um nova heurística de remoção de cargas foi construída uma RNA que, utilizando os dados de frequência espaçados no tempo de um SEP, infere a quantidade de potência (carga) do sistema a ser removida para que a frequência volte ao seu valor nominal. A RNA se enquadra na arquitetura MLP (*MultiLayer Perceptron* - Perceptron Multicamadas) com algoritmo de treinamento *backpropagation* cujas entradas são janeladas ao longo do tempo operando em modo *off-line*. Para tanto, utilizou-se a biblioteca *open source* Fann, que implementa RNAs multicamadas na linguagem C (Nissen, 2003).

A escolha da melhor topologia para a RNA foi baseada no método da validação cruzada para obtenção do melhor ponto de generalização. A Figura 2 representa o modelo empregado em que os padrões de entrada e saída são formados a partir

dos dados normalizados obtidos da simulação. A massa de dados é então separada e 75% dos casos são utilizados para o conjunto de treinamento, enquanto os 25% restantes são reservados para o teste de generalização. Duas camadas intermediárias foram fixadas e a quantidade de seus neurônios é variada em cada ciclo buscando-se o menor EQM (Erro Quadrático Médio). Para a definição do número de neurônios nas camadas escondidas foram realizados 2500 testes variando-se de 1 a 50 os neurônios em cada camada intermediária, sendo escolhida a RNA com menor EQM para o conjunto de validação.

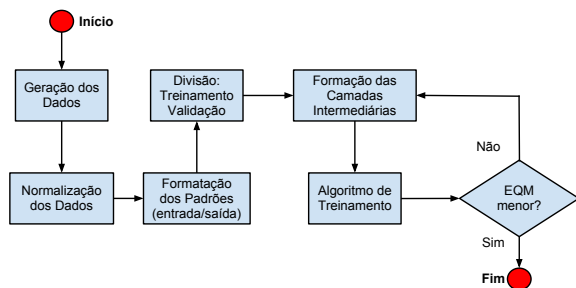


Figura 2: Fluxograma empregado no experimento

Inicialmente, a implementação recebe os valores de entrada da aplicação e normaliza-os entre -1 e 1 para trabalhar com os dados condizentes à RNA. Feito isso, é iniciado o treinamento utilizando o algoritmo *backpropagation*, que ajusta os pesos gerados aleatoriamente para serem utilizados na classificação dos dados de entrada. A função de ativação processa o conjunto de entradas recebidas e o transforma em estado de ativação, limitando o valor final da saída. A função de ativação utilizada para todas as camadas foi a tangente hiperbólica.

Os dados foram organizados em padrões com entrada de 5 elementos (representando o valores janelados de frequência consecutivos) e saída única (representando a quantidade de carga a ser rejeitada de acordo com o déficit de potência ativa do sistema). Os pesos foram gerados aleatoriamente e preenchidos nos atributos conforme definição das camadas da RNA. Cabe colocar que para o processo de aprendizagem pelo método *backpropagation*, esta aplicação exigiu uma taxa de aprendizagem de 0,001. O termo de *momentum*, que acelera a convergência da RNA, foi configurado em 0,5. O erro desejado foi de 10^{-4} , e o número máximo de épocas, caso a rede não viesse a convergir, foi de 100.000. Após a convergência na fase de treinamento, a matriz de pesos fixa foi armazenada para a sua consequente utilização na fase de testes.

4 Apresentação e Análise dos Resultados

A simulação dos casos de sobrecarga descritos na Tabela 4 foi efetuada sobre o sistema da Figura 1,

incrementando-se a potência consumida de 5 em 5% da capacidade inicial do gerador.

O comportamento da variação da frequência pode ser observado na Figura 3. Para melhor visualização, e sem perda de generalidade, apenas 9 curvas são apresentadas neste gráfico (de um total de 20 casos). É possível observar que o sistema consegue se recuperar dos distúrbios para sobrecargas de até 25%, mantendo a frequência próximo de seu valor nominal. Nesses casos, nenhuma ação corretiva deve ser acionada, provendo desta forma, seletividade ao sistema.

Já para casos os casos acima de 30% o mesmo não ocorre. O sistema não possui reserva girante suficiente para suprir a demanda em excesso e, como consequência, a frequência tende a se estabilizar em novos patamares, inferiores ao valor nominal. Para casos extremos de sobre-carga o sistema como um todo entra em colapso.




Figura 3: Curvas de sub-frequência

O conjunto de dados gerado pela simulação possuía passo de integração muito pequeno. Como na maioria das vezes as transições entre amostras não representavam variações significativas, optou-se por re-amostrar o sinal gerado. Para isso, como convenção, adotou-se o intervalo de tempo correspondente a variação de 0,1 Hz para a primeira curva de decaimento da frequência para o caso de sobrecarga de 50%. Com isso, o intervalo entre amostras, para todos os casos, foi de 32 ms.

Após a aplicação do método da validação cruzada, obteve-se a configuração mostrada na Figura 4, utilizando-se 5 entradas, 11 neurônios na primeira camada intermediária, 19 neurônios na segunda camada intermediária e 1 neurônio na camada de saída.

Por meio do histograma representado pela Figura 5 pode-se verificar que a quase totalidade dos erros percentuais relativos são muito próximos de zero com poucas exceções, concentrados em sua maioria para erros menores que 25%.

Ao longo do gráfico de barras da Figura 6 são apresentados os valores do erro relativo percentual para cada um dos pontos que formam os dados do conjunto de validação. A média do erro apresentada foi de 4,85%.

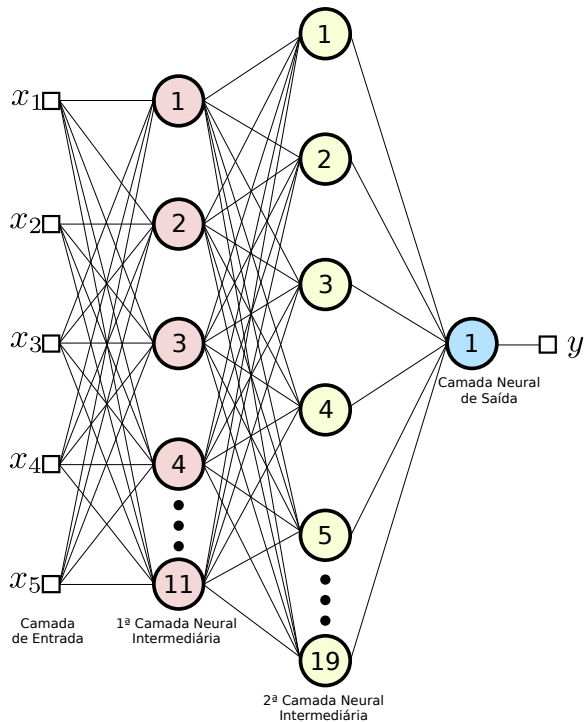


Figura 4: Melhor topologia da RNA

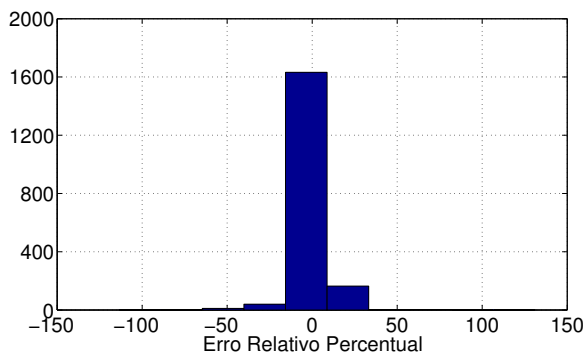


Figura 5: Histograma de erros

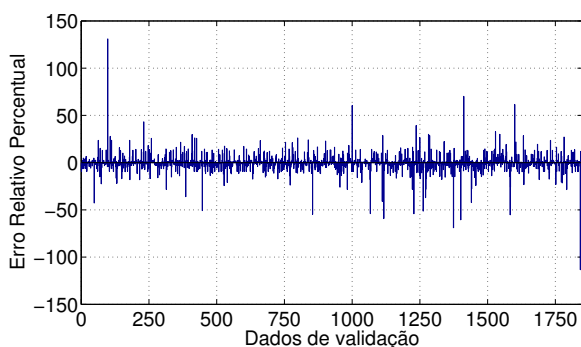


Figura 6: Barras de erro

5 Conclusões e Comentários finais

Os fenômenos de sobrecarga resultam em prejuízos consideráveis tanto para as concessionárias de energia quanto para seus clientes que englobam desde usuários residenciais até grandes corporações. Processos de rejeição de cargas devem ser

realizados a fim de preservar o equilíbrio geral do sistema, evitando-se em última instância, o seu colapso. Desta forma, é plausível a desconexão da quantidade mínima de blocos de carga para manter o nível de frequência em torno de seu valor nominal.

Com isso em mente, o trabalho desenvolvido propõe o uso de RNAs para o cálculo da quantidade ótima de carga a ser rejeitada com objetivo de auxiliar os processos de manutenção do equilíbrio em SEPs. A melhor topologia escolhida foi obtida por meio da ferramenta estatística de validação cruzada aplicada às medidas de frequência espaçadas no tempo e mensurados por meio de um circuito elétrico simples modelado via equipamento de simulação RTDS.

Os resultados obtidos demonstram a boa capacidade de aproximação da RNA frente às oscilações de frequências em casos de aumento de cargas. A rejeição é realizada em apenas 1 estágio oferecendo uma alternativa efetiva e rápida para o restabelecimento da frequência, ao contrário do estabelecido pelo ERAC que necessita de até 5 estágios para a sua restauração.

Agradecimentos

Os autores agradecem o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo financiamento prestado, bem como ao Laboratório de Sistemas de Energia Elétrica (LSEE) da Escola de Engenharia Elétrica de São Carlos (EESC/USP) pela infra-estrutura fornecida durante o desenvolvimento deste.

Referências

- Amraee, T., Mozafari, B. and Ranjbar, A. (2006). An improved model for optimal under voltage load shedding: particle swarm approach, *Power India Conference, 2006 IEEE*, pp. 6 pp.
- Amraee, T., Ranjbar, A., Mozafari, B. and Sadati, N. (2007). An enhanced under-voltage load-shedding scheme to provide voltage stability, *Electric Power Systems Research* **77**(8): 1038 – 1046.
- Andersson, G., Donalek, P., Farmer, R., Hatzargyriou, N., Kamwa, I., Kundur, P., Martins, N., Paserba, J., Pourbeik, P., Sanchez-Gasca, J., Schulz, R., Stankovic, A., Taylor, C. and Vittal, V. (2005). Causes of the 2003 major grid blackouts in north america and europe, and recommended means to improve system dynamic performance, *Power Systems, IEEE Transactions on* **20**(4): 1922 – 1928.

- Chen, X., Deng, C., Chen, Y. and Li, C. (2007). Blackout prevention: Anatomy of the blackout in europe, *Power Engineering Conference, 2007. IPEC 2007. International*, pp. 928–932.
- Committee, P. (2007). Ieee guide for the application of protective relays used for abnormal frequency load shedding and restoration, *IEEE Std C37.117-2007* pp. c1–43.
- Concordia, C., Fink, L. and Poullikkas, G. (1995). Load shedding on an isolated system, *Power Systems, IEEE Transactions on* **10**(3): 1467–1472.
- Corsi, S. and Sabelli, C. (2004). General blackout in italy sunday september 28, 2003, h. 03:28:00, *Power Engineering Society General Meeting, 2004. IEEE*, pp. 1691–1702 Vol.2.
- Guimarães, G. C. (2009). Curso de dinâmica de sistemas elétricos.
- Hooshmand, R. and Moazzami, M. (2012). Optimal design of adaptive under frequency load shedding using artificial neural networks in isolated power system, *International Journal of Electrical Power & Energy Systems* **42**(1): 220–228.
- Hsu, C.-T., Chuang, H.-J. and Chen, C.-S. (2008). Artificial neural network based adaptive load shedding for an industrial cogeneration facility, *Industry Applications Society Annual Meeting, 2008. IAS '08. IEEE*, pp. 1–8.
- Kuffel, R., Giesbrecht, J., Maguire, T., Wierckx, R. and McLaren, P. (1995). Rtds—a fully digital power system simulator operating in real time, *WESCANEX 95. Communications, Power, and Computing. Conference Proceedings. IEEE*, Vol. 2, pp. 300–305 vol.2.
- Mitchell, M., Peas Lopes, J., Fidalgo, J. N. and McCalley, J. (2000). Using a neural network to predict the dynamic frequency response of a power system to an under-frequency load shedding scenario, *Power Engineering Society Summer Meeting, 2000. IEEE*, Vol. 1, pp. 346–351 vol. 1.
- Nissen, S. (2003). Implementation of a fast artificial neural network library (fann), *Technical report*, Department of Computer Science University of Copenhagen (DIKU). <http://fann.sf.net>.
- ONS (2004). Acompanhamento do esquema regional de alívio de carga - erac, **104**(RE-3/101/2005): 21.
- Parniani, M. and Nasri, A. (2006). Scada based under frequency load shedding integrated with rate of frequency decline, *Power Engineering Society General Meeting, 2006. IEEE*, pp. 6 pp.
- Pimjaipong, W., Junrussameevilai, T. and Manerat, N. (2005). Blackout prevention plan; the stability, reliability and security enhancement in thailand power grid, *Transmission and Distribution Conference and Exhibition: Asia and Pacific, 2005 IEEE/PES*, pp. 1–6.
- Rad, B. and Abedi, M. (2008). An optimal load-shedding scheme during contingency situations using meta-heuristics algorithms with application of ahp method, *Optimization of Electrical and Electronic Equipment, 2008. OPTIM 2008. 11th International Conference on*, pp. 167–173.
- Sallam, A. and Khafaga, A. (2002). Fuzzy expert system using load shedding for voltage instability control, *Power Engineering 2002 Large Engineering Systems Conference on, LESCOPE 02*, pp. 125–132.
- Seyedi, H. and Sanaye-Pasand, M. (2009). New centralised adaptive load-shedding algorithms to mitigate power system blackouts, *Generation, Transmission Distribution, IET* **3**(1): 99–114.
- Shokooh, F., Dai, J., Shokooh, S., Taster, J., Castro, H., Khandelwal, T. and Donner, G. (2005). An intelligent load shedding (ils) system application in a large industrial facility, *Industry Applications Conference, 2005. Fourtieth IAS Annual Meeting. Conference Record of the 2005*, Vol. 1, pp. 417–425 Vol. 1.
- Taylor, C. (1992). Concepts of undervoltage load shedding for voltage stability, *Power Delivery, IEEE Transactions on* **7**(2): 480–488.
- Thalassinakis, E., Dialynas, E. and Agoris, D. (2006). Method combining anns and monte carlo simulation for the selection of the load shedding protection strategies in autonomous power systems, *Power Systems, IEEE Transactions on* **21**(4): 1574–1582.
- Tyagi, D., Kumar, A. and Chanana, S. (2013). Load shedding scheme for the two-area system with linear quadratic regulator, *Frontiers in Energy* **7**(1): 90–102.
- Yamashita, K., Li, J., Zhang, P. and Liu, C.-C. (2009). Analysis and control of major blackout events, *Power Systems Conference and Exposition, 2009. PSCE '09. IEEE/PES*, pp. 1–4.