

REPRESENTAÇÃO DE SISTEMAS EXTERNOS EM ESTUDOS DE OTIMIZAÇÃO *ON-LINE* UTILIZANDO REDES NEURAIS ARTIFICIAIS.

Thiago Locatelli Aguiar, Leonardo Nepomuceno. – Engenharia Elétrica – Engenharia Elétrica – Departamento de Engenharia Elétrica – Faculdade de Engenharia de Bauru – Campus de Bauru.

Os estudos de otimização reativa on-line são realizados em centros de controle de sistemas de energia, através de modelos de Fluxo de Potência Ótimo (FPO). O FPO é utilizado para calcular controles reativos (tensões em barra controláveis, taps de transformadores, bancos de capacitores/reactores, etc.) que, implementados, tendem a produzir um ajuste fino no reativo/tensão, promovendo a otimização das perdas do sistema.

As ferramentas de FPO implementadas apresentam algumas deficiências como citadas em Tinney (1988). Há uma séria limitação de modelagem que compromete a precisão dos controles calculados pelo FPO: a qualidade da representação dos sistemas externos. Os sistemas externos são localizados fora da área de operação do centro de controle e, operados por concessionárias vizinhas. As informações sobre os sistemas externos a um centro de controle não são acessíveis *on-line* (por questões de confiabilidade de dados). Assim, é imprescindível desenvolver um modelo que represente as respostas externas durante estudos de otimização na parte interna do sistema.

Este trabalho utiliza Redes Neurais Artificiais (RNAs) para representar sistemas externos em estudos de otimização. É utilizada uma RNA para mapear padrões de respostas externas em estudos de otimização reativa no sistema interno. A RNA será treinada com informações obtidas de estudos de otimização envolvendo o sistema interligado completo, fornecidas por um modelo FPO particionado (FPO^p) em termos dos subsistemas interno, fronteira e externo (NEPOMUCENO E SANTOS 1997), destacados na Figura 1.

Dada uma alteração no sistema interno, o sistema externo fornece uma resposta (em termos das potências ativas e reativas adicionais que são injetadas na fronteira).

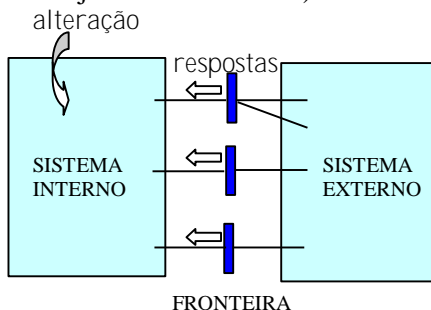


Figura 1. Diagrama esquemático dos subsistemas interno, fronteira e externo e representação de alteração-resposta no sistema interligado.

O modelo externo utiliza uma RNA para mapear padrões de alterações/respostas externas durante estudos de otimização reativa no sistema interno. Os padrões alterações/respostas externas, que constituem o conjunto de treinamento e de teste da RNA foram obtidos de estudos de otimização utilizando o FPO reativo.

O FPO busca a otimização das perdas do sistema interligado. Entretanto, um centro de controle deseja minimizar apenas as suas próprias perdas internas.. Assim, é necessário flexibilizar o modo que a função objetivo e as restrições possam ser introduzidas ou retiradas da formulação, dependendo do subsistema ao qual estejam associadas. Para isso, propõe-se o particionamento de variáveis e equações do FPO em termos dos subsistemas (interno, fronteira e externo) associados a elas (NEPOMUCENO 1997; TOGNETE 2005).

Utilizando-se o FPO^p , definem-se vários problemas de otimização. Assim, a abordagem proposta utiliza uma Rede Neural Artificial (RNA) para mapear as reações externas em estudos de otimização no sistema interno. É importante que o conjunto de treinamento da RNA reflita uma gama considerável de

situações ótimas nos sistema interno e externo, de modo que as reações externas sejam mapeadas com boa precisão.

Para a obtenção dos conjuntos de treinamento e de teste, foram feitos estudos de otimização envolvendo variações nos parâmetros do sistema: tensões controladas, níveis de geração ativa e reativa, carga ativa e reativa, taps de transformadores e bancos de capacitores. Estas alterações foram feitas de modo aleatório, mas obedecendo a faixas de variação específicas para cada variável, respeitando os seus limites operativos e físicos.

Os dados de entrada RNA consistem no estado otimizado calculado pelo FPO^p , constituído pela magnitude e ângulos das tensões em todas as barras do sistema, dados pelos vetores V e \tilde{E} . O estado estimado fornece as informações do sistema, utilizado como informação de entrada da RNA. Os dados de saída da RNA utilizados foram as reações externas de potência ativa e reativa (P_k^{ext}, Q_k^{ext}), dadas pela soma algébrica de todos os fluxos de potência que saem do sistema externo e entram na barra de fronteira k considerada.

Foi utilizada a RNA perceptron multicamadas com uma camada intermediária para representar as reações do sistema externo (HAYKIN, 1999). A Figura 2 mostra a topologia da RNA utilizada.

O algoritmo de treinamento utilizado foi o de Levenberg-Marquardt, que se mostrou eficiente para o mapeamento das reações externas. Nos testes realizados considerou-se uma situação típica de carga pesada. É conveniente que RNAs específicas sejam treinadas para as situações de carregamento básicas: cargas leve, média e pesada.

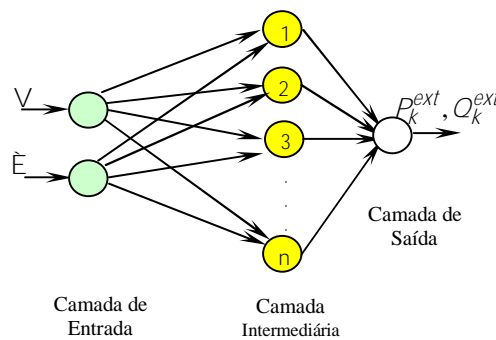


Figura 2. Topologia da RNA Proposta com representações de entrada e saída.

As reações externas calculadas pela RNA são injeções de potência ativa e reativa na região da fronteira. A inserção destas reações no subsistema interno/fronteira é feita alterando-se as injeções líquidas de potência ativa e reativa nas barras de fronteira de modo a refletir as reações externas.

O sistema estudado foi o IEEE 30 barras mostrado na Figura 3, onde se destaca a divisão adotada para os subsistemas. Conforme destacado na figura, há 4 barras de fronteira: 9, 10, 12 e 25. Nos resultados, é avaliada a precisão do modelo de representação do sistema externo, baseado na abordagem neural proposta.

De um conjunto total de 1001 estudos de FPO^p distintos obtidos fez-se um conjunto de treinamento de 800 estudos de FPO^p , e utilizando o algoritmo de Levenberg-Marquardt, foram treinadas 8 RNAs (em cada barra de fronteira deve-se mapear as reações de potência ativa e reativa). As figuras 4 e 5 mostram a evolução do erro quadrático médio durante as épocas de treinamento, para o mapeamento das reações das potências ativa e reativa na barra de fronteira 10. A evolução das demais RNAs foi bastante similar e os erros se mostraram bastante satisfatórios em todos os casos.

A validação das RNAs foi feita sobre o conjunto de 201 situações-teste não utilizadas no treinamento. Os erros relativos (mostrados para a barra 10) nas reações de potência ativa e reativa estão mostrados nas Figuras 6 e 7 respectivamente. Estes erros são calculados comparando-se o valor exato (obtido da solução de FPO^p) e o valor estimado (obtido pela RNA). Conforme esperado, os erros são maiores para o mapeamento da reação de potência reativa, que possui um caráter mais não linear, comparado à potência ativa.

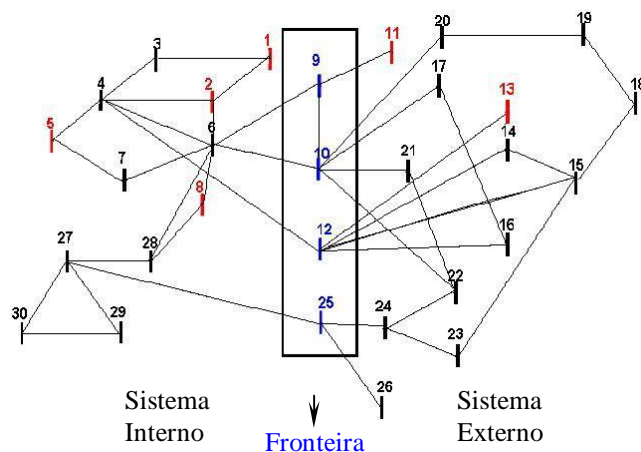


Figura 3. Divisão do sistema teste estudado. Sistema IEEE de 30 barras.

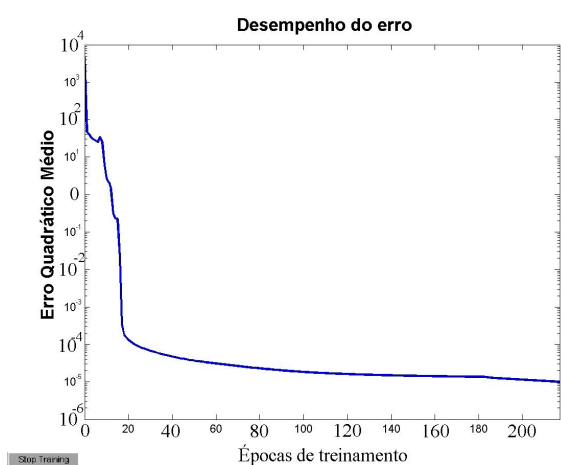


Figura 4. Evolução do Processo de Aprendizado da Reação de Potência Ativa na barra 10 (50 neurônios na camada intermediária).

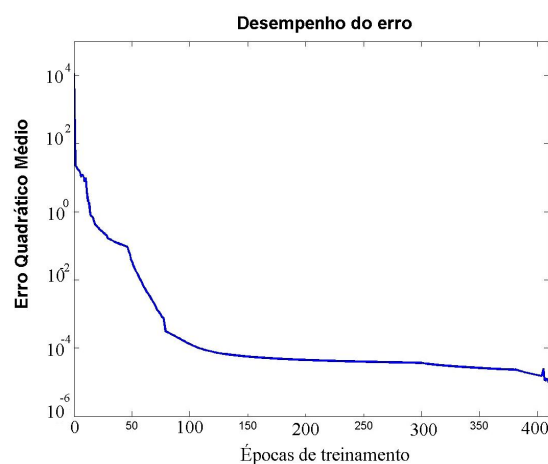


Figura 5. Evolução do Processo de Aprendizado da Reação de Potência Reativa na barra 10 (50 neurônios na camada intermediária).

Foram realizados também estudos para definir o número de neurônios da camada intermediária de cada uma das RNAs. O número de neurônios da camada intermediária foi variado entre 10 e 50 (de 5 em 5). Um exemplo é mostrado na Tabela 1 em que é analisada a potência reativa na barra de fronteira 10. Mostram-se na tabela os valores médios de erro relativo e os desvios padrões calculados para cada arquitetura considerada.

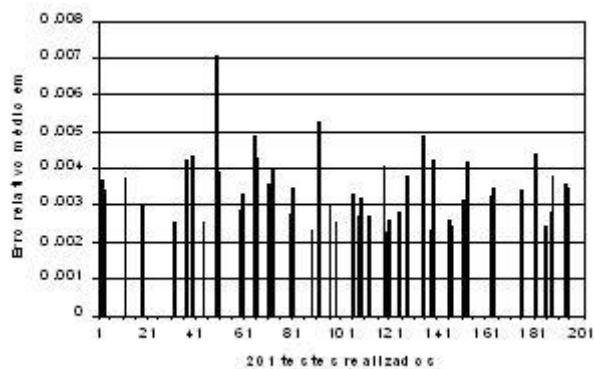


Figura 6. Erro Relativo de Estimção da Reação de Potência Ativa Externa na Barra de Fronteira 10.

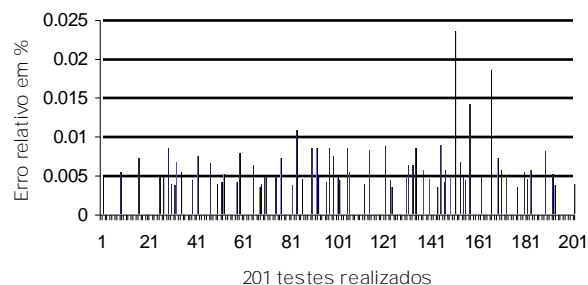


Figura 7. Erro Relativo de Estimção da Reação de Potência Reativa Externa na Barra de Fronteira 10.

Na Tabela 1, nota-se que a arquitetura que apresentou menor erro relativo, com desvio padrão também baixo, foi a arquitetura 2. Os resultados da tabela mostram que a RNA foi capaz de mapear o problema da reação externa de fluxo de potência ativa, conseguindo generalizar estas reações com grande eficiência.

Estendendo-se este estudo às demais barras de fronteiras definiu-se uma configuração mais adequada para cada barra. As configurações estão sintetizadas na Tabela 2, para as reações de potência ativa e reativa. Observando-se a tabela, percebe-se que a RNA obteve erros relativos bastante reduzidos, demonstrando ter sido capaz de aprender e generalizar com bastante eficiência o problema de representação de sistemas externos em estudos de otimização. Os erros de representação das reações externas apresentados pela abordagem neural proposta (destacados na Tabela 2) estão na mesma ordem de grandeza daqueles obtidos pelo modelo descrito em Tognete (2005). Estes resultados são promissores, já que as RNAs não apresentam as deficiências de outros modelos externos relatados na literatura, tais como: a necessidade de atualizações em bancos de dados de sistemas externos e o aumento na dimensão dos problemas de FPO.

Tabela 1. Escolha da Arquitetura da RNA para Estimar a Reação de Potência Reativa Externa na Barra de Fronteira 10.

Arquitetura	Número de Neurônios da Camada Intermediária	Dados de Teste	
		Erro Relativo Médio (%)	Desvio Padrão (%)
1	10	0.0023326	0.01395
2	15	0.0001508	0.000865
3	20	0.0004754	0.001509
4	25	0.0008545	0.001918
5	30	0.0010841	0.004699
6	35	0.0013686	0.002755
7	40	0.0029245	0.016044
8	45	0.0021242	0.01052
9	50	0.0022910	0.003621

Tabela 2. Arquitetura Definida para cada Barra de Fronteira.

Barra de Fronteira	Potência	Número de Neurônios da	Dados de Teste	
			Erro Relativo (%)	Desvio Padrão (%)
9	Ativa	25	0.0000889	0.000486
	Reativa	30	0.0004432	0.003680
10	Ativa	25	0.0022010	0.003898
	Reativa	15	0.0001508	0.000865
12	Ativa	30	0.0022293	0.008614
	Reativa	15	0.0013103	0.004745
25	Ativa	10	0.0000000	0.000000
	Reativa	10	0.0000000	0.000000

Este trabalho mostra que problemas como a necessidade de criação/manutenção de um banco de dados associado ao sistema externo podem ser contornados pela utilização de um modelo externo baseado em RNAs. O trabalho propõe a utilização de RNAs para mapear padrões de respostas externas durante estudos de otimização reativa no sistema interno. O modelo proposto, além de apresentar uma precisão excelente no cálculo dos controles, o modelo neural não aumenta significativamente a dimensão do FPO e também não necessita de atualizações *on-line* em bancos de dados relacionados aos sistemas externos. Apesar dos resultados obtidos muito promissores, estudos adicionais ainda são necessários para validar esta metodologia em sistemas de dimensões reais.

Referências Bibliográficas

- HAYKIN, S., Neural Networks - A Comprehensive Foundation, Prentice Hall, 1999.
- NEPOMUCENO, L. E SANTOS, A. JR., Minimização das Perdas Via FCO Newton com Representação das Partes Não Observáveis Através do Modelo Ward Estendido, XI CBA, São Paulo, 1996, pp 179-184.
- NEPOMUCENO, L. E SANTOS JR., A. Equivalent Optimization Model For Loss Minimization: A Suitable Analysis Approach, IEEE Trans. On Power Syst., 1997, vol. 12, no. 4, pp. 1403-1412, November.
- TINNEY W. F., BRIGHT, J. M., DEMAREE, K. D., HUGHES B. A., Some Deficiencies in Optimal Power Flow, IEEE Trans. Power Systems, 1988, vol. 3, no. 2, pp. 676-683, May.
- TOGNETE, A. L. NEPOMUCENO, L. E SANTOS JR., A. Framework for Analysis and Representation of External Systems for Online Reactive-Optimisation Studies, IEE Proc.-Gener. Transm. Distrib., 2005, vol. 152, no. 6, pp. 755-762, November.