



INSTITUTO FEDERAL
GOIÁS

MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE GOIÁS
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
DEPARTAMENTO DE PESQUISA E INOVAÇÃO

RELATÓRIO FINAL

TÍTULO DO PROJETO

**“APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS (RNA) NA
MELHORIA DA ESTABILIDADE DINÂMICA DO SISTEMA ELÉTRICO
DE POTÊNCIA (SEP) MULTIMÁQUINAS.”**

NOME DO BOLSISTA: Pedro Henrique Franco Moraes

NOME DO ORIENTADOR: André Luiz Silva Pereira

DATA DE INGRESSO COMO BOLSISTA (MÊS/ANO): 08/2011

NOME DO CURSO: Engenharia Elétrica

PERÍODO QUE ESTÁ CURSANDO: 9º

É BOLSISTA DE RENOVAÇÃO: () SIM (X) NÃO

Jataí, JULHO DE 2012

1 – Identificação do Projeto e Componentes

Título do Projeto: APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS (RNA) NA MELHORIA DA ESTABILIDADE DINÂMICA DO SISTEMA ELÉTRICO DE POTÊNCIA (SEP) MULTIMÁQUINAS.

Bolsista: Pedro Henrique Franco Moraes

Orientador: André Luiz Silva Pereira

Local de execução: Jataí

Vigência: Agosto/2011 a Julho/2012

2 – Introdução

A geração e transmissão de energia elétrica são hoje de fundamental importância para a maioria das atividades realizadas no meio industrial. Algo que vem sendo amplamente estudado e aplicado é a busca pela melhoria da qualidade dessa energia. Dentre os problemas que motivam esses estudos, estão as famosas oscilações eletromecânicas fracamente amortecidas, que prejudicam bastante a estabilidade de um SEP (Sistema Elétrico de Potência) e podem ser ocasionadas pelo carregamento normal do sistema, resultando em atividades anormais dos geradores da rede (ANDERSON, 2003; KUNDUR, 1994).

Como alternativa para a melhoria da estabilidade, são instalados nos barramentos do sistema ou nas linhas de transmissão os chamados FACTS (Sistemas Flexíveis de Transmissão AC), que dentre suas funções, é capaz de introduzir amortecimento no sistema com a ajuda do controlador POD (Power Oscillation Damping) (SONG, 1999; WATANABE et al., 1998).

Esse trabalho vem trazer um paralelo ao trabalho desenvolvido no programa de Iniciação Científica anterior, quando se utilizou a rede neural artificial (RNA) Perceptron Multicamadas (PMC) para ajustes otimizados de parâmetros de dispositivos instalados em um SEP. Agora a proposta é a utilização da RNA Função de Base Radial (FBR) para as mesmas funcionalidades, treinada basicamente com os mesmos valores da PMC. Ao fim foi verificado o funcionamento da mesma, com uma simples comparação da eficiência de ambas quando direcionadas para esse determinado problema.

2.1 – Redes Neurais Artificiais

Com a necessidade de se criar ferramentas que se comportem de maneira inteligente, reagindo não apenas a padrões comuns, mas também a situações não usuais, surgiram dentre outros o conceito de redes neurais artificiais. A estrutura de uma RNA é baseada primordialmente na disposição e funcionalidade do sistema neural humano, os neurônios biológicos (Figura 1) inspiraram na criação do modo de processamento de informações dessas redes. Ela nada mais é do que um modelo computacional que possui a capacidade de aquisição e manutenção do conhecimento (SILVA, 2010 p.22).

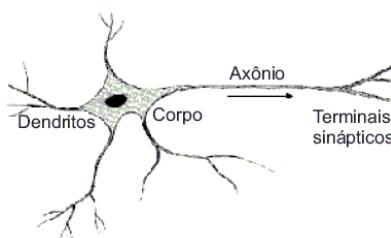
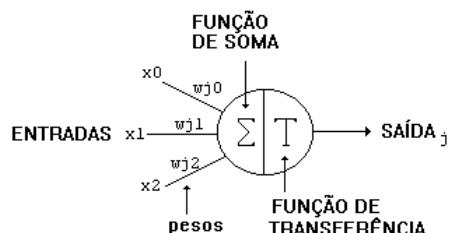
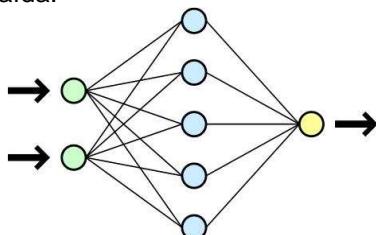


Figura 1 – Neurônio Biológico.

Para poder utilizar uma rede neural, é preciso determinar o problema a se solucionar ou o sistema a se automatizar, com isso é possível determinar e melhorar a topologia de rede para se aplicar ao problema em questão. Existem vários tipos de redes e cada uma com suas características próprias, voltadas para melhor resolver determinadas áreas de necessidades. Além do modelo de rede escolhido, cada uma possui sua forma de treinamento (algoritmo de treinamento), que é o modelo matemático utilizado para programação capaz de calibrar os chamados neurônios artificiais e definir os pesos (Figura 2).

**Figura 2 – Neurônio Artificial.**

Analogamente, pode-se comparar a estrutura de um neurônio biológico (Figura 1) com a disposição física básica de uma rede neural (Figura 3), onde os dendritos são os receptores dos sinais de entrada, o corpo celular é o local de processamento das informações, o axônio é a ligação da camada intermediária até as saídas ou terminações do axônio. Na RNA, os sinais de entrada estão apresentados como os dois primeiros círculos, o processamento são os cinco círculos do meio e o último disponibiliza o sinal de saída.

**Figura 3 – Estrutura básica de uma RNA.**

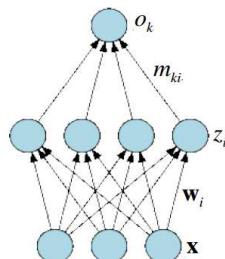
Outra característica das redes neurais é quanto a arquitetura das mesmas, elas podem ser divididas em:

- Feedforward (alimentação à frente) de camada simples,
- Feedforward de camadas múltiplas,
- RNA's recorrentes,
- RNA's reticuladas.

A RNA usada no trabalho em questão é do tipo feedforward de camadas múltiplas. Essas RNA's são muito usadas para a aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica, controle de processos, dentre outros. O número de camadas e a quantidade de neurônios em cada uma delas dependem basicamente da complexidade do problema e dos dados colhidos.

2.2 – Rede Função de Base Radial (RBF)

A rede utilizada para a realização deste trabalho foi a rede Função de Base Radial, ela é do tipo feedforward de camadas múltiplas e sua estrutura está representada abaixo (Figura 4), a parte inferior X é a entrada, os W_i são os pesos ou centros, o Z_i é a função de base radial (geralmente gaussiana), o M_{ki} são os pesos da saída e o O_k é o neurônio de saída. A diferença da FBR para a PMC é que a primeira possui apenas uma camada escondida enquanto a Perceptron pode ter inúmeras camadas escondidas com vários neurônios em cada.

**Figura 4 – Estrutura de uma Rede Função de Base Radial.**

O funcionamento da rede em questão se dá basicamente na seguinte sequência de acontecimentos: antes de entrar na camada X, os dados de treino são agrupados em centros de círculos de raio qualquer tomando por base suas proximidades de valores. O número de círculos será o número de pesos da rede após um laço de repetição, que tira a média em cada conjunto e compara com um valor anterior até ser menor que um erro pré-determinado. A função Gaussiana da camada intermediária depende da variância e da diferença dos valores de entrada e dos pesos corrigidos (Figura 5).

$$z_i(t) = \varphi(u_i(t)) = \exp\left[-\frac{u_i^2(t)}{2\sigma^2}\right]$$

Figura 5 – Equação da função Gaussiana.

Com esse tipo de função é possível aproximar qualquer tipo de função contínua, o mecanismo usado por ela é a combinação de várias funções probabilísticas gaussianas com centros em diferentes posições do espaço de entrada, como mostrado na figura abaixo (Figura 6).

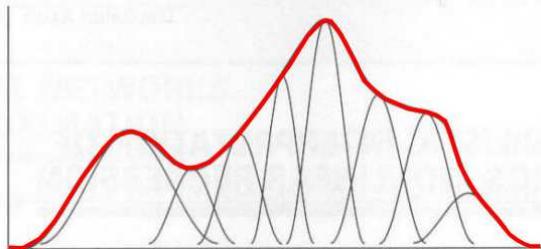


Figura 6 – Aproximação da função Gaussiana.

3 – Material e Métodos

O projeto de pesquisa proposto e a execução do trabalho foram baseados na tese do orientador desse plano de estudo e no trabalho de iniciação científica apresentado pelo orientando do mesmo, no ano anterior. O intuito é verificar o comportamento de redes neurais artificiais no controle e ajuste inteligente de dispositivos estabilizadores e controladores de um SEP (Sistema Elétrico de Potência), os dispositivos verificados na tese foram os seguintes: FACTS STATCOM, PSS e POD. A rede trabalha ajustando de forma automática os parâmetros para os dispositivos controladores, e esses ajustes são feitos devido às pequenas perturbações que ocorrem normalmente em um sistema de energia. No trabalho anterior, utilizou-se a rede Perceptron Multicamadas (PMC) e os resultados foram demonstrados. No presente desenvolvimento, propõe-se a utilização da rede Função de Base Radial (FBR) para a mesma utilidade. Para tal fim foi utilizado o software MatLab.

3.1 – Modelo de Sensibilidade de Potência (MSP) no ambiente multimáquinas

Esse modelo foi desenvolvido para estudo das oscilações de baixa frequência e se baseia no fato de que os balanços das potências ativa e reativa devem ser satisfeitos em qualquer barra do sistema durante qualquer processo dinâmico (DECKMANN, 1994).

A definição desse modelo é dada pelos sistemas abaixo (Figura 7) e essa modelagem utiliza como variáveis de estado (Δx) para cada gerador: a velocidade angular (ω), o ângulo do rotor (δ), a tensão interna de eixo em quadratura ($E'q$) e a tensão de campo (Efd). As entradas (Δu) são a potência mecânica de entrada (Pm) e a tensão de referência ($Vref$) do regulador automático de tensão de cada gerador. O módulo (V) e o ângulo (θ) da tensão terminal das barras do sistema são as variáveis algébricas (Δz) do modelo linearizado.

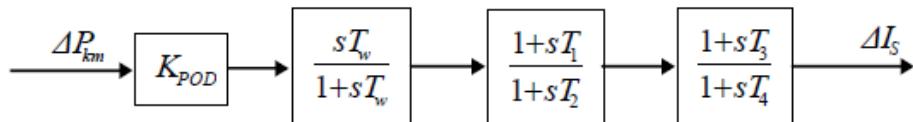
$$\begin{bmatrix} \dot{\Delta x} \\ 0 \end{bmatrix} = \begin{bmatrix} J_{11} & J_{12} \\ J_{21} & J_{22} \end{bmatrix} \cdot \begin{bmatrix} \Delta x \\ \Delta z \end{bmatrix} + \begin{bmatrix} B_1 \\ B_2 \end{bmatrix} \cdot \begin{bmatrix} \Delta u \end{bmatrix}$$

$$\begin{bmatrix} \Delta y \end{bmatrix} = \begin{bmatrix} C_1 & C_2 \end{bmatrix} \cdot \begin{bmatrix} \Delta x \\ \Delta z \end{bmatrix}$$

Figura 7 – Definição do MSP.

3.2 – Controlador Suplementar de Amortecimento

Uma de suas funções em um SEP é o controle do fornecimento de amortecimento às oscilações de baixa frequência. Por isso os controladores suplementares POD são geralmente acoplados com os chamados dispositivos FACTS (HINGORANI, 1999). A figura abaixo (Figura 8) mostra a estrutura convencional do controlador.

**Figura 8** – Controlador *Power Oscillation Damping* (POD).

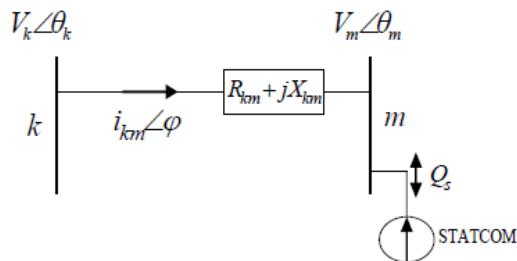
A estrutura da função de transferência do sistema de controle de um POD se constitui basicamente de um ganho K_{pod} , um bloco washout (que tem como função permitir somente a passagem de sinais relacionados a baixas frequências, determinado pela constante de tempo T_w) e um conjunto de blocos lead-lag definidos pelas constantes de tempo $T_1 = T_3$ e $T_2 = T_4$, que proporcionam avanço ou atraso de fase, de acordo com seu ajuste. A entrada dessa função é o fluxo de potência ativa (ΔP_{km}) entre a barra no qual o STATCOM acoplado ao controlador POD está instalado e outra barra vizinha.

3.3 – Compensador Síncrono Estático (STATCOM)

Esses compensadores basicamente geram ou absorvem potência reativa através do chaveamento sincronizado de capacitores ou reatores. Eles podem ser ajustados de acordo com os requisitos de compensação da rede de transmissão.

Observando essa geração de potência reativa, podemos comparar esses dispositivos com uma máquina síncrona, sendo que sua geração de reativo é variada por um controle de excitação. Assim como essas máquinas, o compensador também pode operar com a troca de potência ativa, dependendo apenas da fonte de energia acoplada (SONG, 1990).

Abaixo se têm um diagrama unifilar de um SEP com o compensador instalado (Figura 9):

**Figura 9** – Diagrama Unifilar de um SEP com STATCOM instalado.

Quando o compensador é usado apenas para geração/absorção de reativo, ele é visto como uma fonte de corrente em derivação. Nesse trabalho foi usado apenas essa topologia do dispositivo síncrono. A equação abaixo (Equação 1) trás a potência reativa Q_s trocada com a rede. O I_s é a corrente fornecida pelo STATCOM e o V_m é a tensão do barramento onde o mesmo está localizado.

$$Q_s = V_m I_s \quad (1)$$

Considerando desvios em torno de um ponto de operação, podemos obter a equação linearizada (Equação 2) da equação anterior:

$$\Delta Q_s = V \Delta I_s + \Delta V I_s \quad (2)$$

Desta forma, a inclusão do STATCOM é feita considerando o parâmetro de controle I_s , o qual será considerado uma variável de estado e também será responsável pelo fornecimento de amortecimento devido ao acoplamento do controlador POD. Abaixo está representada a expressão (Equação 3) que define o modelo dinâmico do compensador considerando pequenas perturbações, como sendo:

$$\Delta I_s = 1/T_i (POD - \Delta I_{sref} - \Delta I_s) \quad (3)$$

3.4 – Sistema Teste New England

O sistema teste utilizado (sistema New England) nesse trabalho é composto por 39 barras 46 linhas de transmissão e 10 geradores, e uma máquina (barra 10) modelada com um barramento infinito que representa o sistema New York (ARAUJO, 2001).

Abaixo é mostrado o diagrama unifilar desse sistema (Figura 10):

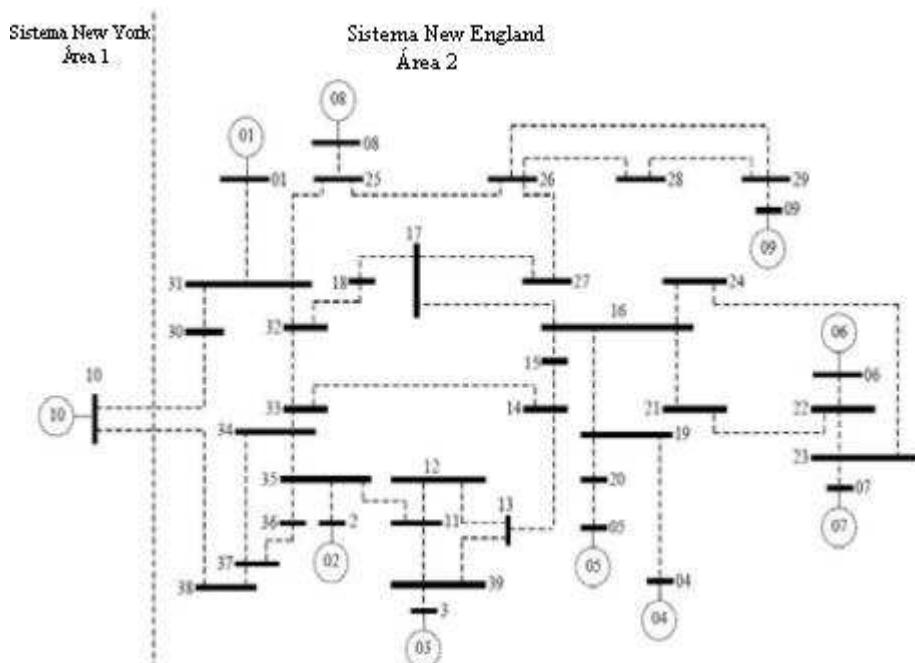


Figura 10 – Sistema teste New England.

4 – Simulações e resultados

Para os ajustes automáticos inteligentes dos parâmetros do controlador POD-STATCOM é proposta uma rede FBR com cinco neurônios na camada intermediária gaussiana. As constantes usadas para o treinamento da RNA foram as seguintes: tolerância $\epsilon = 1e-20$ e taxa de aprendizagem $\eta = 0.01$. Para a validação da rede foi utilizado um total de 71 padrões treinamento (entrada/saída), num total de 3679 épocas, para os pesos inicializados no intervalo de [0,0034; 0,1216]. Como padrões de entrada foram utilizadas as potências ativas e reativas da barra de geração 2 (ΔP_{G2} e ΔQ_{G2}) e para padrões de saída foram avaliados as constantes de tempo (T_{1POD} e T_{2POD}) bem como o ganho (K_{POD}) do controlador POD.

Para os resultados obtidos o que se observou foi que, de acordo com que as barras iam sendo carregadas, a rede apresentava valores de saída muito confiáveis até certo limite se comparadas aos valores reais de treinamento (Tabela 1a), isto é, para dentro do intervalo de treinamento e para certa porcentagem de valores fora desse intervalo (Tabela 1b). Consideravelmente fora desse intervalo as respostas da rede se fixavam em valores iguais, podendo

ser para valores de potência menores que o mínimo (Tabela 2a) ou para valores maiores que o máximo (Tabela 2b), o que é chamado de respostas viciadas.

Tabela 1a - Valores de entrada e saída reais (treinamento).

| Entradas | | Saídas | | |
|----------|---------|------------|------------|-----------|
| P_2 | Q_2 | T_{1POD} | T_{2POD} | K_{POD} |
| 0.70623 | 0.26724 | 0.37322 | 0.21442 | 0.85161 |
| 0.70944 | 0.26809 | 0.37287 | 0.21463 | 0.8536 |
| 0.71265 | 0.26894 | 0.37252 | 0.21485 | 0.8556 |
| 0.71586 | 0.26979 | 0.37218 | 0.21506 | 0.85759 |
| 0.71928 | 0.27071 | 0.37181 | 0.21529 | 0.85971 |

Tabela 1b - Valores de entrada e saída da rede dentro do intervalo de treino (pós-treinamento).

| Entradas | | Saídas | | |
|----------|---------|------------|------------|-----------|
| P_2 | Q_2 | T_{1POD} | T_{2POD} | K_{POD} |
| 0.70623 | 0.26724 | 0.37823 | 0.21173 | 0.82238 |
| 0.70944 | 0.26809 | 0.37774 | 0.21197 | 0.82559 |
| 0.71265 | 0.26894 | 0.37496 | 0.21351 | 0.84171 |
| 0.71586 | 0.26979 | 0.37051 | 0.21601 | 0.86715 |
| 0.71928 | 0.27071 | 0.37086 | 0.21581 | 0.86524 |

Tabela 2a - Valores de entrada e saída da rede dentro do intervalo de treino (pós-treinamento).

| Entradas | | Saídas | | |
|----------------|----------------|----------------|----------------|----------------|
| P_2 | Q_2 | T_{1POD} | T_{2POD} | K_{POD} |
| 0.63123 | 0.23240 | 0.37865 | 0.21141 | 0.82109 |
| 0.62877 | 0.22879 | // | // | // |
| 0.62045 | 0.22102 | // | // | // |
| 0.61654 | 0.21769 | // | // | // |
| 0.60589 | 0.20487 | // | // | // |

Tabela 2b - Valores de entrada e saída com carga maior que o valor máximo de potência.

| Entradas | | Saídas | | |
|---------------|----------------|----------------|----------------|----------------|
| P_2 | Q_2 | T_{1POD} | T_{2POD} | K_{POD} |
| 0.7506 | 0.28057 | 0.37865 | 0.21141 | 0.82109 |
| 0.7581 | 0.28337 | // | // | // |
| 0.76568 | 0.28620 | // | // | // |
| 0.77334 | 0.28906 | // | // | // |
| 0.78107 | 0.29195 | // | // | // |

Verifica-se que para rede FBR, quando submetida a valores de entrada no intervalo de treinamento ou com pequenas variações fora desse intervalo, a mesma fornece saídas muito próximas as saídas reais, isto já era esperado devido ao fato que a RNA foi treinada na faixa desses padrões. Já para os valores de entrada distantes dos valores de treinamento, a rede não consegue generalizar e entra num processo vicioso de valores iguais. Isso ocorre provavelmente pelo fato da curva gaussiana ser posicionada apenas dentro desses valores de treino, e para valores fora a mesma não possui respostas, por se tratar de um método probabilístico.

Isso pode ser observado na figura abaixo (Figura 11), onde a curva com concavidade para cima pode ser tomada como os valores reais. No centro, podemos observar os valores de treino que foram coletados e verificar que esses valores não dão uma boa dimensão da curva total fora do

intervalo coletado. A curva com concavidade para baixo pode ser tomada como a curva gaussiana ajustada da RNA FBR após seu treinamento. Se for observado, para todos os valores dentro do intervalo de treino, as respostas da rede são praticamente valores reais, mas fora do intervalo, a RNA apresenta valores cada vez mais distantes dos valores desejados.

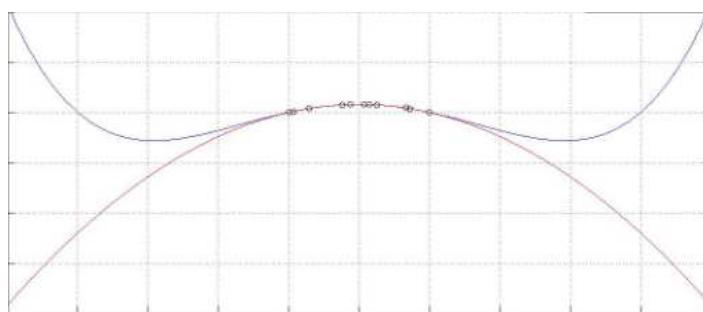


Figura 11 – Curva de valores reais VS Curva Gaussiana FBR (pós-treinamento).

5 - Conclusão

Como foi observado nesse trabalho, a rede FBR não apresentou resultados satisfatórios não sendo possível realizar uma análise mais ampla no que se refere à estabilidade dinâmica do SEP. Dentre os possíveis fatores que podemos destacar problemáticos podemos citar os padrões de treinamento utilizados (talvez não foram satisfatórios para tal análise) ou até mesmo o numero de neurônios utilizados nas camadas escondidas. Sendo necessário fazer uma análise mais ampla a respeito desses parâmetros para tentar obter resultados mais significativos.

6 – Perspectivas de continuidade ou desdobramento do trabalho

Esse presente trabalho foi continuação de um projeto de pesquisa do programa de iniciação científica do ano anterior. Para o primeiro trabalho, foram demonstrados bons resultados com a utilização da rede (Perceptron Multicamadas). Já neste trabalho não foi possível apresentar resultados similares ou melhores, devido ao fato de que os dados coletados para treinamento da nova rede (Função de Base Radial) não foram bons para o objetivo principal. Isso foi descoberto praticamente no final do programa graças à ajuda de um professor de outra instituição perito na área de RNA. Foi alertado que a função a qual estava sendo trabalhada não consegue apresentar valores consideravelmente fora do intervalo de treinamento, pois é uma curva que se ajusta devido ao seu treinamento.

Para melhor concluir o mesmo trabalho, dados novos deveriam ser coletados, mas por motivos particulares dos integrantes, o trabalho não terá segmento.

7 – Publicações e participações em eventos técnico-científicos

O trabalho será submetido ao 1º Simpósio de Pesquisa, Ensino e Extensão que ocorrerá no IFG - Campus Goiânia, do dia 29 de agosto a 1º de setembro.

8 – Apoio e Agradecimentos

Colaboraram: André Luiz Silva Pereira (Professor Orientador) e Igor Santos Peretta (Professor da Universidade Estadual de Campinas (UNICAMP)).

9 – Referências Bibliográficas

- ANDERSON, P. and FOUAD, A. A. **Power System Control and Stability**, 2.ed. Iowa: Iowa State University Press (IEEE Power System Engineering Series), 2003.
- ARAUJO, P. B. and ZANETTA, L. C. Pole Placement Method Using System Matrix Transfer Function and Sparsity. **International Journal of Electrical Power & Energy Systems**, v. 23, n. 3, p. 173–178, 2001.
- DECKMANN, S. M. and DA COSTA, V. F. **A Power Sensitivity Model for Electromechanical Oscillation Studies**. IEEE Trans. on Power Systems, New York, v. 9, n. 2, p. 965-971, 1994.
- HINGORANI, N. G. and GYUGYIL, L. **Understanding FACTS - Concepts and Technology of Flexible Alternating Current Transmission Systems**. New York: Wiley - IEEE Press, 452 p, 1999.
- KUNDUR, P. **Power System Stability and Control**. New York: MacGraw-Hill, 1176 p, 1994.
- SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**, 1.ed. São Paulo: Artliber, 2010.
- SONG, Y. H. and JOHNS, A. T. **Flexible AC transmission systems (FACTS)**. London, The Institution of Electrical Engineers, 592 p, 1999.
- WATANABE, E. H; BARBOSA, P. G; ALMEIDA, K. C. and TARANTO, G. N. **Tecnologia FACTS-tutorial**. SBA Controle & Automação, Campinas, v. 9, n. 1, p. 39–55, 1998.