

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS (RNA) NO CONTROLE DE DISPOSITIVOS FACTS STATCOM E CONTROLADORES SUPLEMENTARES POD E PSS INSTALADOS NO SISTEMA ELÉTRICO DE POTÊNCIA MULTIMÁQUINAS.

Pedro Henrique Franco Moraes
André Luiz Silva Pereira

IFG/Campus Jataí/Engenharia Elétrica – PIVIC, phfranco@gmail.com
IFG/Campus Jataí/Coordenação de Indústria, andspa@gmail.com

Resumo

O projeto de pesquisa proposto e a execução do trabalho foram baseados na tese do orientador desse plano de estudo, 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. Dentre as redes existentes, a que foi estudada, treinada e analisada foi a PMC (Perceptron Multicamadas). Os resultados da mesma são apresentados nesse trabalho.

Palavras-chave: Perturbações, Estabilidade, RNA's, ajustes e PMC.

I. 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).

O intuito desse trabalho é apresentar o conceito de redes neurais artificiais (RNA's) como ferramenta inteligente para os ajustes automáticos dos parâmetros do dispositivo POD-STATCOM, fazendo com que a introdução de amortecimento no SEP seja otimizada. O treinamento da rede foi feito utilizando um sistema teste em que foi instalado o FACTS STATCOM acoplado com o controlador POD. Com isso foram coletados os dados segundo os ajustes baseados na teoria de Controle Linear e os resultados da rede PMC (*Perceptron Multicamadas*) são mostrados e comentados.

II. 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).

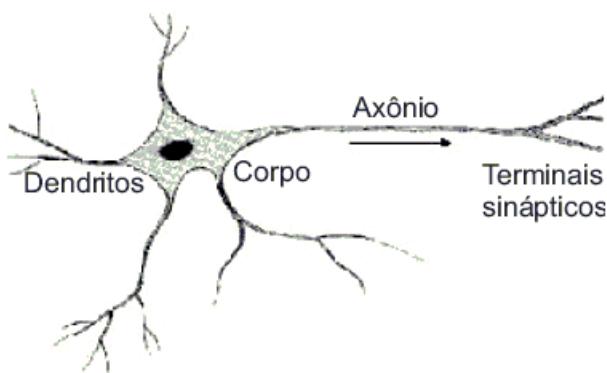


Figura 1: Neurônio Biológico.

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* (Figura 2).

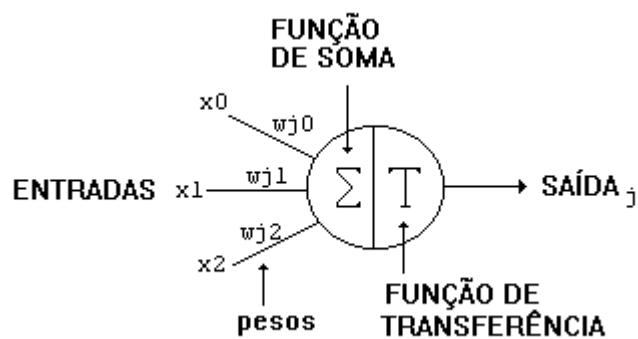


Figura 2: Neurônio Artificial.

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.

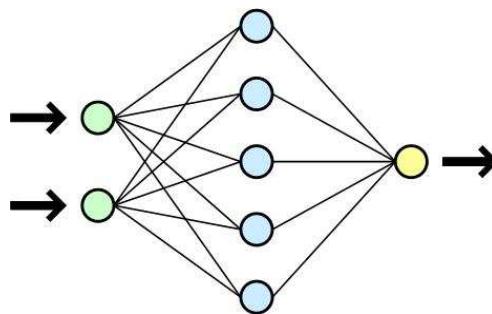


Figura 3: Estrutura básica de uma RNN.

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, redes recorrentes e redes reticuladas. As redes que são objetivo de estudo desse trabalho são as *feedforward* de camadas múltiplas, que 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.

De fato, o número de camadas escondidas e seus respectivos neurônios constituintes dependem, sobretudo, do tipo e da complexidade do problema a ser mapeado pela rede, assim como da quantidade e da qualidade dos dados disponíveis sobre o problema. (SILVA, 2010 p.48).

III. REDE PERCEPTRON MULTICAMADAS

A rede utilizada para a realização deste trabalho foi a rede *Perceptron Multicamadas*, ela é do tipo *feedforward* de camadas múltiplas e sua estrutura está mostrada abaixo (Figura 4). Sua maneira de processamento e envio de dados se dá seguindo a seguinte sequência: a informação chega pelos neurônios da camada de entrada, sendo que esses são interligados com todos os neurônios da camada escondida, mas a passagem para essa camada é feita pelos pesos sinápticos ponderando o sinal e após a função não linear de saída de cada neurônio ativa o sinal, enviando por fim para a camada de saída, sua função linear apresenta as saídas desejadas.

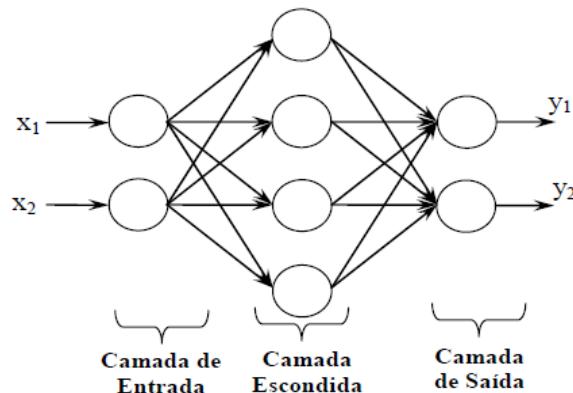


Figura 4: Estrutura de uma Rede Feedforward.

As variáveis da rede podem ser apresentadas seguindo as seguintes equações:

$$Uj(n) = \sum \omega_{ij}(n) * Y_i(n) - x_o \quad (1)$$

$$Y_j(n) = f(U_j(n)) \quad (2)$$

Onde U_j é o potencial de ativação do j -ésimo neurônio (Equação 1), seu valor é o somatório do produto dos peso sinápticos ω ; que conectam a saída do neurônio i a entrada do neurônio j ; pela saída Y_i menos o limiar x_o . Assim as saídas Y_j são adquiridas em função linear com o valor de cada potencial de ativação (Equação 2). O somatório do potencial de ativação é feito com o valor de j variando de um até m camadas.

IV. ALGORITMO *BACKPROPAGATION*

A rede PMC se utiliza de um modelo de treinamento denominado algoritmo *backpropagation*. Basicamente o mecanismo de treinamento de uma rede neural é feito com exemplos de comportamento, que nada mais são do que coletas de uma quantidade suficiente de valores de entrada e saída. Quanto maior for essa coleta de dados mais precisamente a rede irá trabalhar, e de acordo com o aprendizado seguindo o algoritmo, os pesos sinápticos são ajustados para melhor resposta possível a cada entrada. Esse processo se resume em aprendizado de padrões, a RNA PMC procura aperfeiçoar os padrões que são verificados pelos valores de entrada e saída utilizados e se ao fim a saída apresentada não for a desejada o algoritmo aqui discutido retorna para minimizar o erro (Equação 3).

$$Eq(n) = 0.5 \sum (dj(n) - yj(n))^2 \quad (3)$$

A equação acima é denominada de erro quadrático, o valor total desse erro é calculado pela metade do somatório da subtração ao quadrado das saídas desejadas dj do neurônio j pelas saídas momentâneas calculadas yj .

O critério de parada é estipulado em função do erro quadrático médio (Equação 4), e seu valor é obtido somando todos os erros quadráticos sobre todo n e então normalizando em função de ρ (número de padrões de treinamento).

$$Eqm = 1/\rho * \sum(Eq(n)) \quad (4)$$

A convergência do algoritmo é definida quando o erro quadrático médio de uma determinada repetição menos o erro da repetição anterior for menor ou igual ao valor do erro definido antes do início do treinamento (Equação 5). Cada uma dessas repetições são chamadas de épocas, e nada mais são do que a quantidade de retornos nos laços de repetições usados o algoritmo precisou fazer para minimizar o erro.

$$|Eqm(n+1) - Eqm(n)| < \epsilon \quad (5)$$

Para se corrigir os pesos sinápticos para a ponderação do sinal usa-se a equação abaixo (Equação 6).

$$\Delta \omega_{ji}(n) = \eta \sigma_j(n) y_i(n) \quad (6)$$

Onde σ_j é o gradiente local do neurônio j e η é a taxa de aprendizagem que também como o erro é previamente definida.

Para se encontrar o gradiente das camadas escondidas da rede, aplica-se a outra equação mostrada logo abaixo (Equação 7). Já o gradiente da camada de saída tem-se a equação posterior (Equação 8).

$$\sigma_j(n) = f'(u_j(n)) \sum \sigma_k(n) \omega_{kj}(n) \quad (7)$$

$$\sigma_j(n) = (d_j(n) - y_j(n)) f'(u_i(n)) \quad (8)$$

Com o intuito de acelerar a convergência do algoritmo e melhorar a estabilidade, é adicionado na equação dos ajustes dos pesos sinápticos (Equação 9) o termo *momentum* α , seu valor é limitado no intervalo de $0 < \alpha < 1$. Ele nada mais é do que um valor fracionário proporcional a alteração anterior (BEALE, 1990; WASSERMAN, 1989).

$$\Delta\omega_{ij}(n) = \alpha\Delta\omega_{ij}(n-1) + \eta\sigma_j(n)y_i(n) \quad (9)$$

V. 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 (Equação 10) 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.

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

$$[\Delta y] = [C_1 \quad C_2] \cdot \begin{bmatrix} \Delta x \\ \Delta z \end{bmatrix} \quad (10)$$

VI. 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 5) mostra a estrutura convencional do controlador.

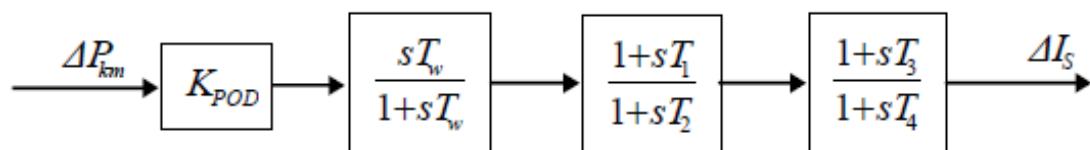


Figura 5: Controlador *Power Oscillation Damping* (POD)

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 $T\omega$) e um conjunto de blocos *lead-lag* definidos pelas constantes de tempo $T1 = T3$ e $T2 = T4$, que proporcionam avanço ou atraso de fase, de acordo com seu ajuste. A entrada dessa função é o fluxo de potência ativa (ΔPkm) entre a barra no qual o STATCOM acoplado ao controlador POD está instalado e outra barra vizinha.

VII. 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 tem um diagrama unifilar de um SEP com o compensador instalado (Figura 6):

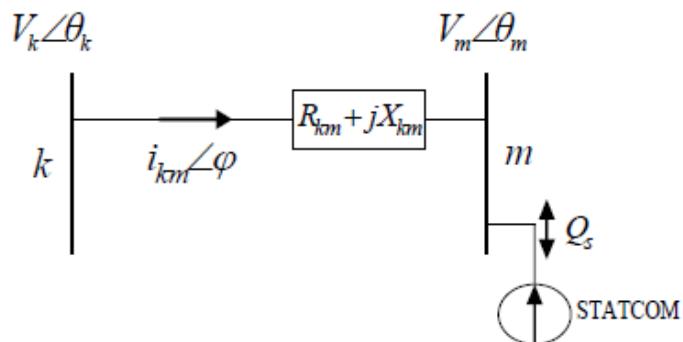


Figura 6: Diagrama Unifilar de um SEP com STATCOM instalado.

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 11) 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.

$$Q_s = V_m I_s \quad (11)$$

Considerando desvios em torno de um ponto de operação, podemos obter a equação linearizada (Equação 12) da equação anterior:

$$\Delta Q_s = V \Delta I_s + \Delta V I_s \quad (12)$$

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 13) que define o modelo dinâmico do compensador considerando pequenas perturbações, como sendo:

$$\Delta I_s = 1/T_{is}(POD - \Delta I_{sref} - \Delta I_s) \quad (13)$$

VIII. SIMULAÇÕES E RESULTADOS

Para o projeto de controladores, a vantagem de se utilizar RNA está baseada justamente na quantidade de pontos de operação necessários para seu treinamento, podendo fornecer dados (parâmetros) seguros para o bom desempenho do controlador em diferentes pontos de operação. Isso se deve ao fato de que os padrões que constituem os dados de treinamento das RNA's

trazem consigo distintos pontos de operação do SEP possibilitando, assim, um maior grau de segurança para que os controladores possam desempenhar sua função com uma maior eficiência. Em vista disso, uma RNA PMC é treinada para o ajuste de controladores POD acoplado ao dispositivo STATCOM em um sistema de potência teste.

IX. 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 7):

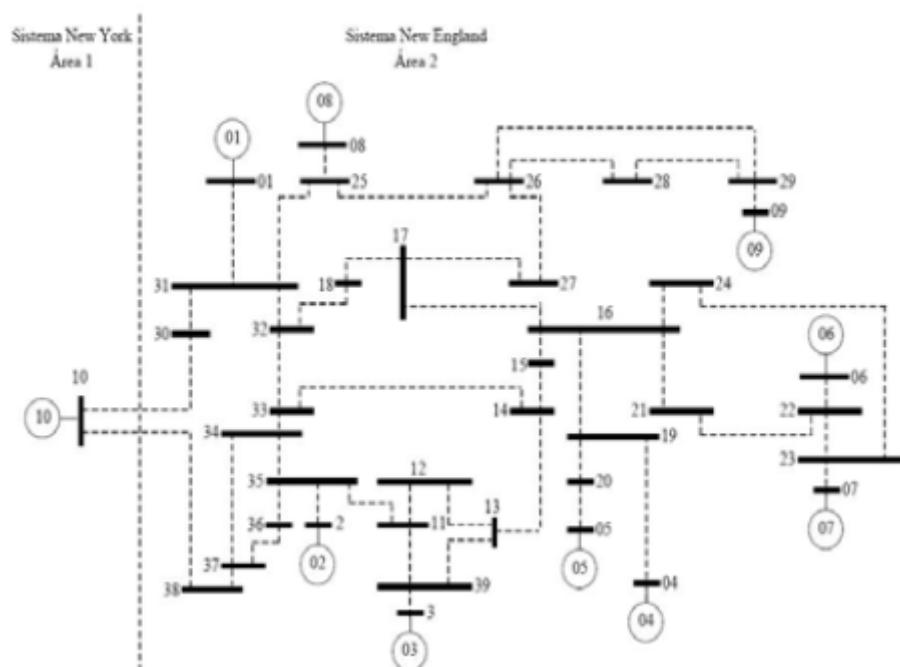


Figura 7: Sistema teste *New England*.

Analizando os autovalores da matriz de estados apresentada abaixo (Tabela 1), é possível ver que este sistema possui quatro modos eletromecânicos instáveis, sendo três do tipo local (modos 1, 2 e 3) e um interárea (modo 4), reconhecidos por suas frequências típicas.

Devido a esses problemas, foi decidida a instalação de dispositivos ESP's para resolver o problema de amortecimento local, e para o quarto modo a inserção do FACTS STATCOM com um POD acoplado ao mesmo.

Tabela 1: Autovalores dominantes do sistema *New England*.

Modo	Autovalor	ζ	ω_n
1	$0,056976 \pm 6,8627i$	-0,00830	6,862
2	$0,169320 \pm 5,9123i$	-0,02862	5,914
3	$0,092953 \pm 6,3185i$	-0,01471	6,319
4	$0,000753 \pm 3,5359i$	-0,00021	3,535

Para identificar qual a melhor localização desses controladores no sistema elétrico de potência foi feia a análise dos resíduos (CHANG, 2007).

Abaixo são apresentados os módulos (Tabela 2):

Tabela 2: Módulos dos Resíduos Associados aos Modos Eletromecânicos para Instalação dos Controladores POD-STATCOM e ESP.

Barra/Contr.	Modo 1	Modo 2	Modo 3	Modo 4
1/ESP	0,00100060	6,4392e-005	9,6326e-005	0,00014840
2/ESP	0,00039353	0,00025938	0,002232500	0,00041620
3/ESP	0,00031756	0,00027237	0,00233270	0,00049922
4/ESP	1,2063e-005	0,00033481	5,1399e-005	0,00050025
5/ESP	0,00028287	0,03579200	0,01481700	0,00506850
6/ESP	0,00036656	1,6218e-005	0,00070947	0,00056370
7/ESP	0,00264730	0,00020705	0,00517830	0,00367950
8/ESP	0,00078497	0,00021048	0,00015891	0,00024420
9/ESP	0,01652800	0,02141600	0,04093300	0,00383470
10/ESP	3,4652e-020	2,7247e-020	6,5478e-020	6,1915e-019
30/POD	0,01745100	0,00236840	0,0143380	0,024235

É possível observar na tabela acima que para o ESP instalado na barra 9 se terá uma maior influência sobre o modo instável 3, já para o ESP instalado na barra 5 sua influência mais significativa é sobre o modo 2. Pode-se observar também que para o conjunto POD-STATCOM instalado na barra 30 se vê uma maior influência desse dispositivo sobre os modos 1 e 4, além de ter uma influência também significativa sobre os outros modos instáveis. Assim decidiu-se pela instalação do POD-STATCOM na barra 30 e um ESP instalado na máquina 9. Feito esse procedimento efetuou-se a coleta de dados para treinamento da RNA.

X. SIMULAÇÕES DA REDE *PERCEPTRON* MULTICAMADAS

Para os ajustes automáticos inteligentes dos parâmetros do controlador POD-STATCOM é proposta uma rede PMC com três camadas, sendo que a primeira camada ou camada de entrada possui seis neurônios, a camada escondida com dez neurônios e a camada de saída com três neurônios. As constantes usadas para o treinamento da RNA foram as seguintes: tolerância $\varepsilon = 1e-10$, taxa de aprendizagem $\eta = 0.6$, termo *momentum* $\alpha = 0.5$. Para a validação da rede foi utilizado um total de 85 padrões treinamento (entrada/saída), num total de 4973 épocas, para os pesos inicializados no intervalo de [-0,4; 0,4].

Os dados de entrada considerados para o treinamento da RNA foram os valores de potência ativa e reativa referentes ao gerador 2 (ΔPG_2 , ΔQG_2) e para os dados de saída foram consideradas as constantes de tempo e o respectivo ganho do controlador (T1, T2 e K). Para o sinal de entrada do POD-STATCOM Neural (PSN) foram consideradas as variações do fluxo de potência ativa (ΔPkm) entre as barras 31 e 30. Abaixo uma ilustração da inserção do PSN no sistema elétrico em um malha fechada com realimentação.

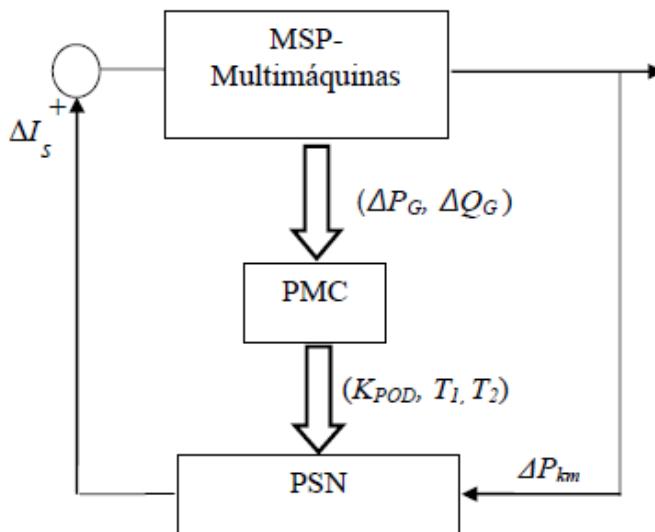


Figura 8: Diagrama de Blocos do MSP-Multimáquinas com a Inclusão do PSN.

Algumas informações sobre a rede que devem ser frisadas seguem a frente: os pesos da rede não são alterados após o término do processo de treinamento e suas entradas são os valores atuais de potências ativa e reativa fornecidos pelas máquinas síncronas, as respostas da RNA devem não somente ser as desejadas para entradas conhecidas como também apresentar saídas eficientes para entradas que estão dentro dos padrões de treinamento, a PMC poderá ajustar os parâmetros dos controladores em tempo real (online) possibilitando uma maior eficácia no que se refere ao amortecimento de oscilações eletromecânicas de baixa frequência, o dispositivo ESP terá seu ajuste feito através da maneira convencional, isto é, compensação de fase.

Como efeito de comparar e verificar a eficiência do PSN em relação ao modo convencional de ajustes, simulações foram feitas. Para este fim dois casos foram considerados: caso A: POD-STATCOM (ajuste convencional - PSC) + ESP (ajuste convencional); caso B: PSN (ajuste via rede neural) + ESP (ajuste convencional).

Os valores dos parâmetros dos controladores estão apresentados (Tabela 3) abaixo após essas simulações:

Tabela 3: Parâmetros dos Controladores - Casos “a” e “b” - CASO BASE- Ajuste Local.

Parâmetros	Caso a		Caso b	
	ESP-9	POD	ESP-9	POD
K	6,6879	8,0487	6,6879	8,3749
T ₁	0,2576	0,3817	0,2576	0,3849
T ₂	0,0972	0,2095	0,0972	0,2108

Com esses valores ainda não é possível comprovar a eficiência do PSN, pois os valores dos parâmetros do POD para os dois casos estão muito próximos.

Para avaliar uma nova situação da rede neural, foram feitas novas simulações nas quais foram aumentados simultaneamente os carregamentos das seguintes barras do sistema: barra 37 – aumento de 20%, barra 33 – aumento de 20%, barra 18 – aumento de 65% e para barra 26 um aumento de 60%. Claro que essas são variações que estão longe das pequenas perturbações reais, mas com isso pode-se verificar o quanto a RNA em questão se adapta a novas situações das

quais não foi treinada. A tabela abaixo (Tabela 4) trás os autovalores dominantes nessas variações para os mesmos casos A e B acima citados.

Tabela 4: Autovalores Dominantes: Parâmetros – Aumento do Carregamento

Caso a			Caso b		
Autovalores	ζ	ω_n	Autovalores	ζ	ω_n
$-10,630 \pm 22,48i$	0,427420	24,872	$-9,75500 \pm 24,985i$	0,363700	26,822
$-9,2504 \pm 4,385i$	0,903620	10,237	$-9,08090 \pm 4,5867i$	0,892600	10,173
$-0,3216 \pm 8,323i$	0,038619	8,3293	$-0,32388 \pm 8,3104i$	0,038944	8,3167
$-0,1760 \pm 8,295i$	0,021194	8,2977	$-0,18075 \pm 8,2951i$	0,021785	8,2971
$-0,2660 \pm 8,079i$	0,032918	8,0837	$-0,26545 \pm 8,0806i$	0,032833	8,0849
$-0,2290 \pm 7,287i$	0,031497	7,2911	$-0,27103 \pm 7,2680i$	0,037265	7,2730
$-0,1030 \pm 7,123i$	0,014520	7,1246	$-0,11375 \pm 7,1113i$	0,015994	7,1122
0,00720 ± 6,344i	-0,00113	6,3445	$-0,00281 \pm 6,3466i$	0,000443	6,3466
$-0,3968 \pm 6,109i$	0,064830	6,1217	$-0,41912 \pm 6,1281i$	0,068234	6,1424
$-0,2236 \pm 5,898i$	0,037884	5,9024	$-0,19950 \pm 5,8925i$	0,033838	5,8958
$-0,3563 \pm 3,316i$	0,106830	3,3354	$-0,29737 \pm 3,3083i$	0,089525	3,3217
$-3,8513 \pm 0,580i$	0,988840	3,8948	$-3,92860 \pm 0,7020i$	0,984410	3,9908

Verifica-se que para o caso A o sistema tornou-se instável, já no caso B não se observa esse problema, o que comprova uma maior robustez do PSN.

Também na tabela abaixo (Tabela 5) observa-se outros traços da maior eficiência do PSN sobre o meio de ajuste convencional. Um deles é o menor valor do ganho K no ajuste por redes neurais, isso mostra que há um menor esforço de controle. Outro ponto é que quando bem ajustada a rede pode fornecer melhores valores para os parâmetros do controlador considerando pontos de operação para qual a mesma não foi treinada.

XI. CONCLUSÕES

Esse trabalho trás como discussão dentre os inúmeros problemas de um sistema elétrico de potência (SEP) as oscilações de baixa frequência. Para se controlar e melhorar a estabilidade desses sistemas usam-se os chamados FACTS STATCOM, que são os compensadores síncronos de potência ativa e reativa. Acoplados a esses estabilizadores estão os controladores POD que fazem com que essa inserção de estabilidade ao sistema seja mais eficiente.

A proposta aqui apresentada é comparar o trabalho dos FACTS quando os seus controladores tem seus parâmetros ajustados pelo método convencional (compensação de fase) e quando são ajustados via rede neural. Com isso foi possível concluir qual desses dois métodos é mais vantajoso.

A rede neural usada nesse trabalho foi a *Perceptron Multicamadas* (PMC), ela foi treinada com os mesmos padrões de entrada e saída do POD-STATCOM convencional e ao fim foi utilizada no chamado sistema *New England*. Os dados dos dois modelos, POD-STATCOM convencional e POD-STATCOM neural, foram coletados e comparados.

Para a primeira simulação, os valores foram muito semelhantes, tanto para o PSC quanto para o PSN, impossibilitando a conclusão do melhor meio de ajuste. Mas quando os barramentos foram carregados e houve a segunda simulação, observa-se que para o PSC o sistema tende a ficar instável, já para o PSN não; e as comparações dos parâmetros do controlador também

demonstraram uma significativa melhora para o POD neural, o menor valor do ganho K para esse caso permitem concluir que existe um menor esforço de controle quando se utiliza os ajustes inteligentes.

O próximo projeto de pesquisa a ser executado será a utilização de uma rede neural artificial chamada de Função de Base Radial (FBR) nas mesmas situações em que a *Perceptron Multicamadas* foi usada, seu método de treinamento é diferenciado da rede PMC, possibilitando uma calibração mais rápida dos pesos sinápticos, ou seja, seu algoritmo possui uma convergência maior do que o da rede aqui apresentada. A finalidade da próxima pesquisa será a comparação das duas redes nos ajustes automáticos dos dispositivos estabilizadores.

XII. 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.
- BEALE, R. and JACKSON, T. **Neural computing: an introduction**. Bristol: Hilger, 1990.
- CHANG, Y. and XU, Z. **A novel svc supplementary controller based on wide area signals, Electric Power Systems Research**, 2007.
- 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 Altern 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.
- WASSERMAN, P. D. **Neural computing: theory and practice**. New York: Van Nostrand Reinhold, 230 p, 1989.