

Redes Neurais Artificiais : Uma Aplicação ao Planejamento da Operação de Sistemas Hidrotérmicos de Geração

Ronaldo R. B. de Aquino¹, Manoel Afonso de Carvalho Jr.², Benemar Alencar de Souza³

¹ UFPE/ Doutorando UFPB - UFPE/CTG/DEESP -Av Acadêmico Hélio Ramos s/n, Cidade Universitária Recife-PE Brasil CEP : 50740-530 Fone/Fax : 55 -81 -2718256

² UFPE - UFPE/CTG/DEESP -Av Acadêmico Hélio Ramos s/n, Cidade Universitária Recife-PE Brasil CEP : 50740-530 Fone/Fax : 55 -81 -2718256

³ UFPB-UFPB/CCT/COPELE- Av Aprigio Veloso ,882-Bodocongó -Campina Grande -PB Brasil CEP: 58109-970 Fone/Fax: 55-83- 3101015

E-mails: rrba@npd.ufpe.br, macj@npd.ufpe.br,benemar@dee.ufpb.br

Abstract

This paper shows an application of the Artificial Neural Networks (ANN) in the operation planning of a hydrothermal generation system. The ANN algorithm used is the multilayered perceptron (MLP) trained with error back-propagation learning correction rule. Here the ANN is trained to give as output the hydro generations when is presented to the natural inflows and/or turbined outflow. This ANN is modeled to represent the practical aspects of the analysed problem. An optimal hydrothermal operation model is used to provide the training examples.

A principal informação de entrada desses programas computacionais são as vazões afluentes e o seu objetivo é o estabelecimento de uma política de geração para o atendimento ao mercado de energia elétrica. Este atendimento será baseado nas gerações hidroelétricas, gerações térmicas, importações de energia e quando não for possível atender ao mercado apresentando o valor do deficit de energia.

As redes neurais artificiais (RNA) tipo MLP tem sido largamente utilizadas como ferramenta de solução em diversos problemas da engenharia elétrica como vê-se nas referências [6], [7], [8], [9] contudo, ainda não ao planejamento de sistemas de geração hidrotérmicos.

Objetivo deste trabalho é utilizando-se uma (RNA) tipo MLP obter-se as gerações hidráulicas de um sistema de geração quando esta rede é alimentada por dados de vazões afluentes e/ou turbinadas. Os dados utilizados para o treinamento desta RNA serão obtidos de um modelo de otimização, descrito no item seguinte, através de diversas simulações variando-se apenas os dados de vazão afluente.

1. Introdução

A operação de sistemas hidrotérmicos de grande porte com base hidroelétrica, como o caso de estudo utilizado neste artigo, possui muitas restrições operativas que não são controladas pelo sistema. Algumas dessas restrições são: vazões mínimas para navegação ou motivos ecológicos, controle de cheias, operações de eclusas (como é o caso da usina hidroelétrica de Sobradinho no Rio São Francisco no Nordeste do Brasil).

Estas restrições atuam no sistema de geração tanto diminuindo sua flexibilidade operativa como sua capacidade de geração de energia. Entretanto estas restrições estão incorporadas a operação das usinas e não são alteradas, porém dois outros usos são analisados no planejamento da operação que são irrigação e transposição de bacias .

O planejamento de sistemas de geração desse porte requer uma modelagem do problema, de modo que permita a solução utilizando técnicas de otimização[4], [5], implementadas em programas computacionais.

2.Modelo Hidrotérmico de Geração

Este modelo é implementado em “software” que realiza a otimização da operação de sistemas de hidrotérmicos de geração eletricamente interligados. O objetivo deste modelo é o atendimento ao mercado de energia elétrica em base mensal. A representação das usinas hidroelétricas neste modelo é de forma individualizada, e considera-se como restrições de uso múltiplo da água a irrigação e a transposição de bacias. A modelagem utilizada representa o problema de operação hidrotérmica como um problema de programação linear a qual será descrita no próximo item.

2.1 Formulação Matemática do Subproblema Hidráulico

A equação de balanço hídrico eq.(1) é a parte principal do subproblema hidráulico a qual mostra a maneira como as usinas hidroelétricas devem ser operadas, de tal forma que cada bacia hidrográfica tem sua equação de balanço hídrico.

Matematicamente é expressa como ,

$$V(i,t) = V(i, t-1) + A(i,t) - (Q(i,t) + S(i,t)) - (I(i,t) + T(i,t) + E(i,t)) + \sum_{j \in M(i)} (Q(j,t) + S(j,t)) \quad (1)$$

onde:

$V(i,t)$ = volume do reservatório i no período t .

$A(i,t)$ = vazão afluyente natural ao reservatório i no período t .

$Q(i,t)$ = vazão turbinada do reservatório i no período t .

$S(i,t)$ = vazão vertida do reservatório i no período t .

$M(i)$ = conjunto usinas hidroelétricas a montante da usina i .

$I(i,t)$ = vazão retirada para irrigação do reservatório i no período t .

$T(i,t)$ = vazão retirada para transposição do reservatório i no período t .

$E(i,t)$ = vazão evaporada do reservatório i no período t .

Além da equação de balanço hídrico mostrada anteriormente também são considerados os limites de armazenagem dos reservatórios e os limites de vazões turbinadas, além dos volumes inicial e objetivo.

2.2 Formulação Matemática do Subproblema de Balanço de Energia

As equações de balanço de energia eqs.(2) e (3) estabelecem como a carga está sendo atendida. Utilizando-se geração hidráulica, geração térmica e energia importada de outro subsistema ou se a carga não for totalmente suprida ocorre o deficit. Observe que cada subsistema tem uma equação de balanço de energia, que tem em comum o fluxo de energia entre os subsistemas.

$$\text{Para o subsistema 1} \\ \sum_{i=1}^{NH_1} GH_1(i,t) + \sum_{j=1}^{NT_1} GT_1(j,t) + DEF_1(t) - EXP_{12}(t) + EXP_{21}(t) = L_1(t) \quad (2)$$

$$\text{Para o subsistema 2} \\ \sum_{i=1}^{NH_2} GH_2(i,t) + \sum_{j=1}^{NT_2} GT_2(j,t) + DEF_2(t) + EXP_{12}(t) - EXP_{21}(t) = L_2(t) \quad (3)$$

onde:

$GT_k(j,t)$, é a produção da $j^{ésima}$ usina térmica do subsistema k no período t .

$GH_k(j,t)$, é a produção da $j^{ésima}$ usina hidroelétrica do subsistema k no período t .

$EXP_{12}(t)$ é o fluxo de energia do subsistema 1 para o 2 durante o período t .

$EXP_{21}(t)$ é o fluxo de energia do subsistema 2 para o 1 durante o período t .

$DEF_k(t)$ é o deficit de energia do subsistema k durante o período t .

$L_k(t)$ é a carga do subsistema k durante o período t .

NH_k é o número de usinas hidroelétricas do subsistema k .

NT_k é o número de usinas térmicas do subsistema k .

Na equação de balanço energético mostrada anteriormente também são considerados os limites de geração térmica e os limites de fluxo de energia.

2.3 Geração Hidráulica

A geração hidráulica é calculada para cada usina hidroelétrica multiplicando-se a vazão turbinada $Q(i,t)$ pela produtividade da usina $r(i)$ durante o período t . Aqui a produtividade característica da usina hidroelétrica é um valor constante para cada usina hidroelétrica.

$$GH(i,t) = r(i) * Q(i,t) \quad (4)$$

2.4 Função Objetivo

A qual busca minimizar o custo de operação .

$$\min \sum_{t=1}^T (\sum_{j=1}^{NT_1} CT_1(j) \times GT_1(j,t) + \sum_{j=1}^{NT_2} CT_2(j) \times GT_2(j,t) + CDEF \times (DEF_1(t) + DEF_2(t))) \quad (5)$$

onde :

CT é o custo do combustível para a geração térmica .
 $CDEF$ é o custo do deficit de energia.

3. O Problema de Operação Hidrotérmica: em Rede Neural Artificial

3.1. Rede Neural Artificial: Descrição Suscinta

A rede neural representada como um grafo Fig.1 é caracterizada pela topologia da rede, pelos nós que são os neurônios e os arcos que medem a força de ligação entre os neurônios chamados de pesos, e pela regra de atualização. A regra de atualização ou aprendizagem controla os pesos e/ou estados (ativados ou não) dos elementos de processamento (neurônios).

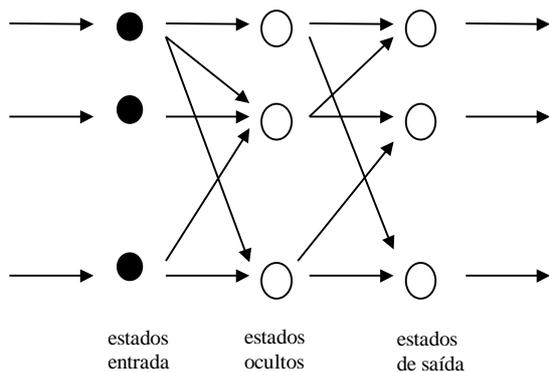


Figura 1. Grafo da RNA tipo MLP

3.2. Sinopse do Perceptron em Múltiplas Camadas (Multilayer Perceptron - MLP)

O Perceptron em Múltiplas Camadas (MLP) é mostrado na Fig. 1, consiste de n nós na camada de entrada, h nós na camada oculta e m nós na camada de saída conectados no sentido direto (feedforward) através de pesos multiplicadores w_{ij} . As entradas (x_i) são multiplicadas (ponderadas) pelos pesos das conexões (w_{ij}) e passadas para os neurônios (nós) da camada oculta. Nos neurônios da camada oculta a saída tem a função de transferência em forma de S, que é a função não linear chamada “sigmoide”, $f(z) = 1 / (1 + e^{-z})$. As entradas ponderadas pelos pesos é então recebida pela função “sigmoide” para produzir a saída. Para os nós da camada oculta o resultado é

$$H_j = 1 / (1 + \exp(- \sum_{i=1}^n w_{ij} \cdot x_i)) \quad (6)$$

onde H_j é a saída da j -ésimo nó da camada oculta, $j=1, \dots, h$, e x_i representa a i -ésima entrada conectada a este nó oculto pelo peso w_{ij} com $i=1, \dots, n$. O resultado do k -ésimo nó saída é dado por,

$$Y_k = 1 / (1 + \exp(- \sum_{j=1}^h w_{jk} \cdot H_j)) \quad (7)$$

onde Y_k é a saída do k -ésimo nó da camada de saída com $k = h+1, \dots, m$, e w_{jk} representa os pesos das conexões entre a camada oculta e a de saída.

O MLP deve ser treinado com dados históricos para encontrar valores apropriados de w_{ij} e o número de neurônios necessários para a camada oculta. O algoritmo de aprendizagem é de correção do erro propagado para trás (“error back-propagation - BP”). No algoritmo BP o aprendizado ocorre pelo ajustamento dos pesos. A saída produzida pela Rede Neural Artificial (RNA) em resposta as entradas são repetidamente comparadas com a resposta correta. A cada iteração os valores dos pesos são ajustados “lentamente” na direção da resposta correta pela propagação do erro da camada de saída, no sentido (saída - entrada), dentro da RNA de acordo com o algoritmo do gradiente negativo.

3.3 . Modelagem do Problema

O problema será inicialmente tratado através de um mapeamento entrada-saída associando dados e resultados obtidos com um modelo de otimização e utilizando-os como entradas e saídas de uma RNA. Estes dados serão utilizados inicialmente para o treinamento da rede e posteriormente verificando os resultados dessa rede para dados conhecidos (dentro do conjunto usado para treinamento) e desconhecidos.

Estabelecido no item 2 o problema de operação hidrotérmica foi resolvido, como um problema de programação linear, para 10(dez) hidrologias representativas do histórico de vazões para treinamento, mais 3 (três) hidrologias de testes para verificar-se a capacidade de generalização da rede. De cada problema resolvido é extraído um par vazão x geração hidráulica, ficando todos os outros dados de entrada mantidos constantes.

O caso exemplo aqui utilizado foi o resultado da simulação do sistema interligado Chesf / Eletronorte para um período de 12 meses. Neste caso simulou-se a operação das usinas hidroelétricas da Chesf em cascata no rio São Francisco; Sobradinho, Itaparica, Paulo Afonso, e Xingó e no rio Parnaíba Boa Esperança. Além da usina hidroelétrica de Tucuruí da Eletronorte no rio Tocantins.

Assim objetivou-se criar uma RNA que produza como resultado as gerações hidráulicas para uma ou varias UHE's quando uma determinada vazão é fornecida como dado de entrada para a RNA.

Posteriormente, para obtenção do balanço energético seria realizado por um outro algoritmo heurístico onde partindo-se dos dados do problema e das gerações hidráulicas seriam obtidas as gerações térmicas, intercâmbios e deficits para o atendimento do mercado de energia elétrica.

A proposta básica de modelagem pode ser resumida na Fig. 2.

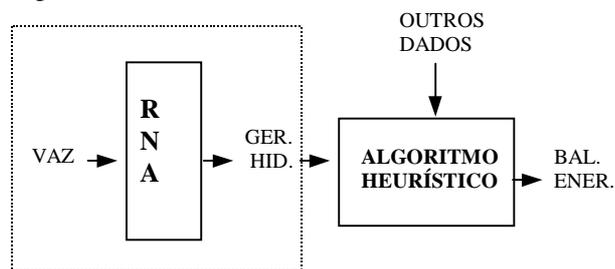


Figura 2 Proposta básica de modelagem

A parte da Fig. 2 envolvida pela linha tracejada será a partir de agora o nosso objeto de análise, ou seja como modelar a rede neural para o nosso problema, o que mostraremos a seguir.

Inicialmente buscou-se o resultado desejado através de uma modelagem que tivesse como vazões de entrada as aflúências aos reservatórios de Sobradinho e Tucuruí e como saída as gerações das UHE's

Sobradinho, Itaparica, Paulo Afonso, Xingó e Tucuruí numa única RNA como mostrado nas Figs. 3 e 4.

A UHE Boa Esperança não foi incluída na RNA dado que suas gerações não são bem representada como função de suas próprias vazões, mas como uma consequência das outras gerações, e como sua capacidade de geração é marginal quando comparada com o somatório das outras optou-se por retirá-la da RNA e colocá-la no algoritmo heurístico.

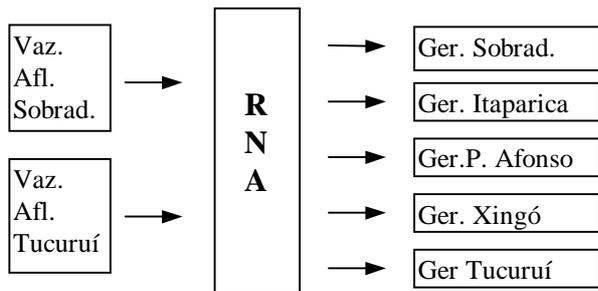


Figura 3. Primeira Tentativa de Modelagem.

Como trata-se de uma simulação em base mensal para cada ano hidrológico existem 12 afluências para Sobradinho e 12 para Tucuruí totalizando 24 neurônios de entrada. A saída da mesma é formada por 12 gerações para cada UHE o que totaliza 60 neurônios de saída. O que está mostrado na Fig. 4.

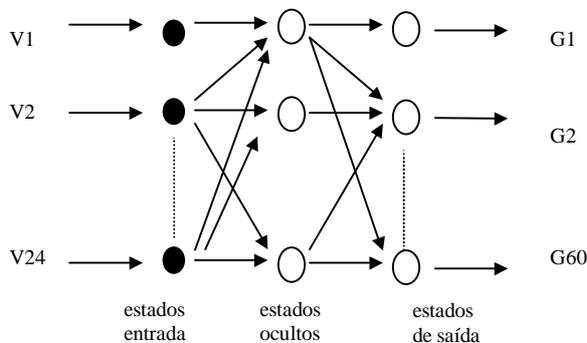


Figura 4. Grafo da Primeira Tentativa de Modelagem.

Para completar esta modelagem falta explicitar a quantidade de neurônios na camada oculta, que foi estipulado em 22.

Os resultados desta proposta mostraram que a rede treinada (com erro máximo permitido de 2%) reproduz bem os resultados objetivos para os quais foi treinada, porém não consegue generalizar bom resultados para afluências desconhecidas, o que nos levou a duas questões básicas;

- Porque não generalizou ? e
- Como fazer para generalizar?.

Diante destas questões buscou-se um maior aprofundamento teórico do MLP através do estudo do livro [1] capítulo 6, do qual destacamos três aspectos conceituais importantes:

1-No livro[1] o item 6.10 é específico sobre a Generalização na RNA tipo MLP, sendo lá dito que para uma rede generalizar é necessário ter-se um conjunto de treinamento disponível de tamanho N (amostras) tal que:

$$N > W/\epsilon \quad (8)$$

onde: W - é o total de pesos sinápticos na rede.

ϵ - é o erro médio quadrático desejado.

2- Outro aspecto importante discutido no Livro [1], Cap 6, pag.153 é quanto ao critério de parada ou convergência do processo de iterativo de treinamento. Sendo ali sugerido que critério de parada só será adequado quando a rede estiver generalizando “corretamente”.

3- Uma frase celebre sobre o projeto das RNA usando o algoritmo “back-propagation” diz que; “Este projeto é mais uma arte que uma ciência”, tendo em consideração os inúmeros fatores envolvidos no projeto os quais são oriundos da experiência pessoal do projetista no problema em questão.

Diante dos problemas da *1ª tentativa* e dos três aspectos resolveu-se que:

- Devido ao pequeno número de casos para treinamento o número de neurônios na camada oculta seria o mínimo possível para convergência e que esta camada seria única.
- Devido ao pequeno número de casos para treinamento, a RNA seria fracionada em várias sub-redes de tal forma que cada rede representasse um par vazãoXgeração para cada UHE, como mostrado na Fig. 5. Onde cada RNA é similar à da Fig. 3 sendo que agora são 12 estados (ou neurônios) de entrada e 12 estados de saída.

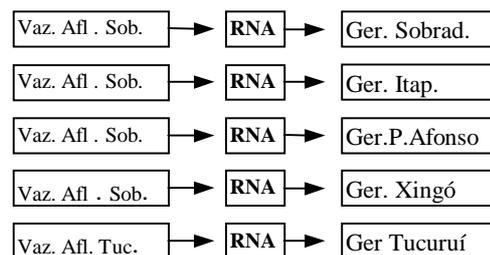


Figura 5 Segunda Tentativa de Modelagem.

Os resultados da *segunda tentativa* estão mostrados Tab.1 e Figs. 7 a 9 , onde vê-se que a RNA apesar de produzir os valores de treinamento a RNA não generaliza quando apresentada a valores desconhecidos, o que mostra que a redução do tamanho da RNA nesta tentativa apesar de grande, não foi suficiente para com a amostra de treinamento disponível promover a generalização, excetuando o caso da UHE Xingó.

Dado que não há interesse em se ter uma amostra de treinamento muito maior optou-se nessa *terceira tentativa* numa investigação explorando-se as características físicas do problema tais como; ligação das hidroelétricas em cascata, interligação eletroenergética entre Tucuruí e Sobradinho na modelagem da RNA e assim obter-se bons resultados de generalização.

Mantendo-se o básico da *segunda tentativa* de associar vazãoXgeração para cada UHE e seguindo premissas anteriores foi testada a seguinte modelagem para o problema apresentada na Fig.6.

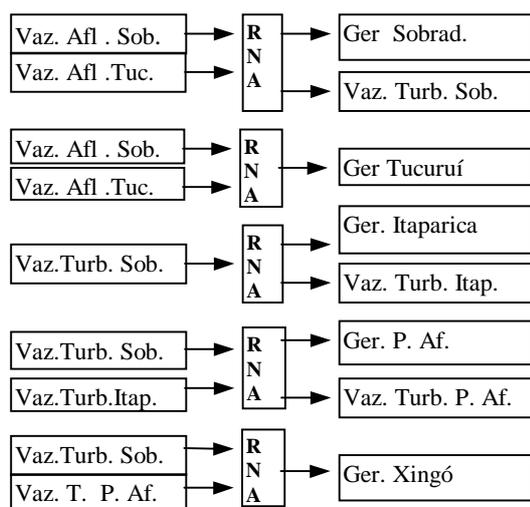


Figura 6. Terceira Tentativa ou Modelagem Final.

Analisando a modelagem anterior verifica-se que para a obtenção das gerações das UHE's de Sobradinho e Tucuruí individualmente utilizou-se as afluições de ambas o que leva em consideração a interligação eletroenergética dos sistemas Chesf e Eletronorte. Para as outras UHE's que formam a cascata do Rio São Francisco utiliza-se a vazão turbinada pela usina de montante juntamente com a de Sobradinho o que considera uma característica física importante do problema a ser modelado em RNA.

3.4. Pacote Computacional (“Software”)

Para realização do presente trabalho foi utilizado o “MATLAB, Neural Network Toolbox”, do qual foi utilizado o algoritmo “backpropagation” para o perceptron em múltiplas camadas sendo suas principais características descritas em [2].

4. Análise dos Resultados

Os resultados apresentados na Tab. 1, mostram que o erro absoluto diminui para todas as usinas hidroelétricas a medida que a modelagem vai evoluindo da 1ª para a 3ª tentativa. É interessante notar que para o caso da UHE Tucuruí da 1ª para a 2ª tentativa o erro aumenta já que na 2ª tentativa não considerou-se as afluições de Sobradinho o que é importante do ponto de vista do problema analisado e já na 3ª o erro caiu a 4%. Observe que apesar do erro de treinamento ser feito a 2% não é possível garantir que este erro se repita no caso no caso teste, contudo ficam próximos a 2%.

Já em termos mensais observamos nas Figs. 7 a 9 as usinas de Sobradinho, Xingó e Tucuruí mesmo na 3ª tentativa apresentaram valores razoáveis com disparidades entre os valores obtidos e desejados, isto se deve ao fato de termos o ajuste do erro médio quadrático (característica própria do algoritmo “backpropagation”) e como temos muitos neurônios na camada de saída eventualmente ocorre valores mais dispersos da média.

5. Conclusões

Os resultados obtidos neste trabalho demonstram que a capacidade das RNA, tipo MLP em realizar com sucesso a associação de padrões e generalizar para padrões desconhecidos, inclusive com poucos dados de treinamento, desde que representativos do espaço amostral e tendo a rede sido apropriadamente modelada.

Outros estudos poderão ser realizados para o aprimoramento dos resultados em base mensal obtidos neste trabalho, buscando-se uma atualização dos pesos que seja realizada de forma individual [1] e não pela média.

Referências

- [1] Simon Haykin, Neural Networks : A Comprehensive Foundation. MacMillan College Publishing Co. New York, 1994
- [2] “MATLAB, Neural Network Toolbox”, 1994
- [3] Ronaldo R. B. Aquino., Redes Neurais Artificiais : Uma Aplicação no Planejamento da Operação de Sistemas Hidrotérmicos de Geração .Projeto de Pesquisa 2, UFPB/COPELE, SET/1998
- [4] Ronaldo R. B. Aquino., Manoel A Carvalho Jr., Modelo de Otimização da Operação Hidrotérmica do Sistema Interligado Chesf/Eletronorte .XIV CILAMCE pp 533-542, 1993.
- [5] Ronaldo R. B. Aquino., Manoel A Carvalho Jr., Benemar Alencar de Souza, The Water Resources Multiple Use Impact in the Operation Planning of Hydrothermal Generation Systems ,VI SEPOPE, 1998.

[6] A.Khotanzad, D.J. Muratukulam ,An Artificial Neural Network Hourly Temperature Forecaster with Applications in Load Forecasting, IEEE Trans. on Power Systems ,Vol 11, No2 ,May 1996, pp 870-876.

[7] A.Khotanzad, R. Afkhami-Rohani, ANNSTLF -A Neural-Network-Based Electric Load Forecasting System, IEEE Trans. on Neural Networks ,Vol 8, No 4 ,July 1997 , pp 835-846.

[8] Y. Mansour, E.Vaahedi, M.A. El-Sharkawi ,Dynamic Security Contingency Screening and Ranking Using Neural Networks, IEEE Trans. on Neural Networks ,Vol 8, No 4 ,July 1997 , pp 942-950.

[9] M . Djukanovic, D.J. Sobajic, Y.-H. Pao, Neural-net based determination of generator-shedding requirements in electric power systems, IEE Proceedings-C, Vol. 139, No. 5, pp 427-436.

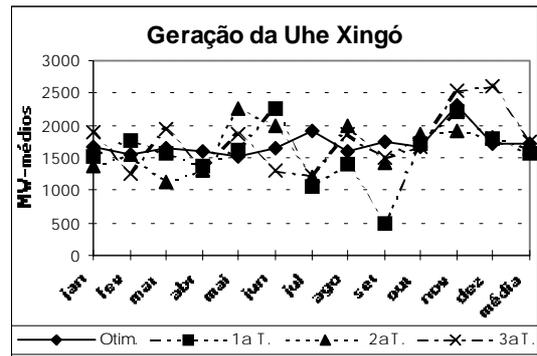


Figura 9

Tabela 1
Erros Médios das Gerações
em relação ao caso Otimizado

	Sob.	Itap.	Comp.	Xingó	Tucuruí
1a Tent.	-0,14	-0,08	-0,55	-0,09	-0,18
2a Tent.	-0,1	0,07	0,16	-0,04	-0,39
3a Tent.	-0,05	-0,02	0,01	0,02	-0,04

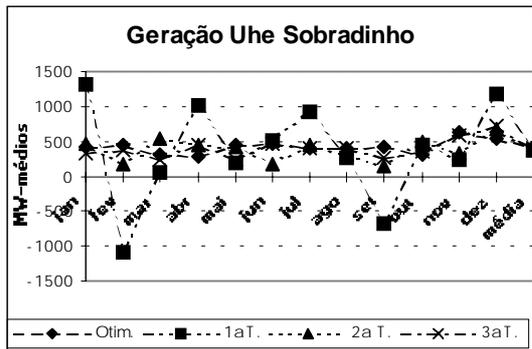


Figura 7

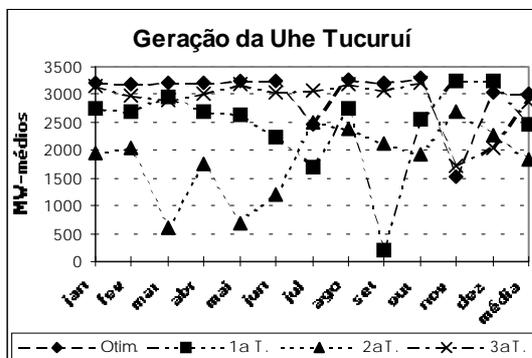


Figura 8