



Universidade Presbiteriana Mackenzie
Tradição e Pioneirismo na Educação

Palestra:

Redes Neurais na Modelagem de Sistemas

Luiz Calôba

COPPE & Poli /UFRJ

www.lps.ufrj.br/~caloba

Abril de 2012

I - Modelos Matemáticos de Sistemas Físicos - essenciais em engenharia, física, etc.

Sistema Real, Planta

$$(\mathbf{x}^p, \mathbf{y}^p) \quad p = 1, 2, \dots, P$$



Modelo, Simulador



Modelo Matemático

Sistema de equações tal que

saída modelo $\approx$ saída planta

$$\underline{\tilde{y}}^p \cong \underline{y}^p \quad \forall p$$

equações (e seus parâmetros k) minimizam

$$F(k) = E_{\forall p} \left| \underline{y}^p - \underline{\tilde{y}}^p \right|^2$$

Modelos Fenomenológicos e Numéricos (Neurais)

Modelo Fenomenológico



Sistema de equações pré-determinado pela fenomenologia

Precisão das equações ?


Parâmetros das equações: conhecidos ou

à determinar a partir de dados experimentais

Cognitivo

Precisão ?

Modelo Neural – Rede Neural



Sistema de equações:

$$y = \sum tgh(.) \quad \text{aproximador universal}$$

Parâmetros (sinapses) à ajustar


backpropagation

$$\Delta w = -\alpha \frac{\partial F}{\partial w} \quad F(w) = E_{\forall p} \left| \underline{y}^p - \tilde{\underline{y}}^p \right|^2$$

Preciso


Informação fenomenológica ?

Modelo Neural – Rede Neural




$$u_i = \sum_{j=0}^N w_{ij} x_j$$

$$s_i = \begin{cases} u_i \\ tgh u_i \end{cases}$$



$$\tilde{y} = \sum t_i tgh u_i$$

Rede Neural – O treinamento backpropagation




$$F(w) = E_{\forall p} \left| \underline{y}^p - \underline{\tilde{y}}^p \right|^2 \quad \Delta w = -\alpha \frac{\partial F}{\partial w} = \alpha \varepsilon \frac{\partial \tilde{y}}{\partial w}$$

II - Modelos Fenomenológicos tratados como uma Rede Neural



Exemplo 1:

Atenuação de sinal em enlace terra-satélite



Modelo UIT-R de Propagação de Sinal Terra - Satélite - Equações

$$Z_1 = f(\varphi) = h_R$$

$$h_R = 5 - .075(\varphi - 23)$$

$$h_R = 5$$

$$h_R = 5 + .1(\varphi + 21)$$

$$h_R = 0 \quad \text{for } \varphi < -71$$

$$Z_2 = f(Z_1, h_R, \theta) = L_S,$$

$$L_S = \frac{(h_R - h_S)}{\sin \theta} \quad \text{for } \theta \geq 5^\circ$$

$$L_S = \frac{2(h_R - h_S)}{\left(\sin^2 \theta + \frac{2(h_R - h_S)}{R_e} \right)^{1/2} + \sin \theta} \quad \text{else}$$

$$Z_3 = f(Z_2, \theta) = L_G = L_S \cos \theta$$

$$Z_4 = f(f, \tau, \theta, R_{0.01\%}) = \gamma_R = k(R_{0.01\%})^\alpha$$

$$Z_5 = f(Z_3, Z_4, f) =$$

$$r_{0.01} = \frac{1}{1 + 0.78 \sqrt{\frac{L_G \gamma_R}{f}} - 0.38(1 - e^{-2L_G})}$$

$$Z_9 = f(Z_4, Z_7, Z_8, f, \theta) =$$

$$v_{0.01} = \frac{1}{1 + \sqrt{\sin \theta} \left(31(1 - e^{-(\theta/(1+\chi))}) \sqrt{\frac{L_R \gamma_R}{f^2}} - 0.45 \right)}$$

$$Z_{10} = f(Z_7, Z_9) = L_E = L_R v_{0.01}$$

$$Z_{11} = f(Z_4, Z_{10}) = A_{0.01} = \gamma_R L_E$$

$$Z_{12} = f(\theta, \varphi, p) = \beta$$

$$\text{if } p \geq 1\% \text{ or } |\varphi| \geq 36^\circ, \beta = 0$$

$$\text{if } p < 1\% \text{ and } |\varphi| < 36^\circ \text{ and } \theta \geq 25^\circ,$$

$$\beta = -0.005 (|\varphi| - 36)$$


$$\text{else,}$$

$$\beta = -0.005 (|\varphi| - 36) + 1.8 - 4.25 \sin(\theta)$$


$$\tilde{A}_p = f(z_{11}, z_{12}, p, \theta) =$$

$$= A_{0.01} \left(\frac{p}{0.01} \right)^{-(0.655 + 0.033 \ln(p) - 0.045 \ln(A_{0.01}) - \beta(1-p) \sin(\theta))}$$


Modelo UIT-R de Propagação de Sinal Terra - Satélite - Diagrama de Blocos





Composto por
Blocos ou sub-modelos
(equações)



Bloco
ou sub-modelo





Neuronio



Ex 2: Circuito equivalente de um transformador

$$2 \ln |L_d(j\omega)| = 2 \ln L_{d0} + \sum_{j=1}^m \ln(1 + \omega^2 T_d^j{}^2) - \sum_{i=1}^n \ln(1 + \omega^2 T_{d0}^i{}^2)$$

$$\arg[L_d(j\omega)] = \sum_{j=1}^m \operatorname{tg}^{-1}(\omega T_d^j) - \sum_{i=1}^n \operatorname{tg}^{-1}(\omega T_{d0}^i)$$



II.1 -Ajuste dos parâmetros do modelo fenomenológico


via retropropagação do erro

$$F_p = \varepsilon_p^2 = (y - \tilde{y})^2$$

$$\tilde{y} = f_1(Z_5)$$

$$Z_5 = f_2(k)$$

$$\begin{aligned} \Delta k &= -\alpha \frac{\partial F_p}{\partial k} = -\alpha \frac{\partial F}{\partial \tilde{y}} \frac{\partial \tilde{y}}{\partial k} \\ &= 2\alpha \varepsilon \frac{\partial \tilde{y}}{\partial k} = 2\alpha \varepsilon \frac{\partial \tilde{y}}{\partial Z_5} \frac{\partial Z_5}{\partial k} \end{aligned}$$



o erro ε na saída do modelo é **retropropagado** até cada bloco (ou parâmetro) de interesse

$$\alpha \varepsilon \frac{\partial \tilde{y}}{\partial Z_5} \quad \text{ou} \quad \alpha \varepsilon \frac{\partial \tilde{y}}{\partial k}$$

as derivadas podem ser calculadas analítica ou numericamente

$$\frac{\partial \tilde{y}}{\partial k} \cong \frac{\Delta \tilde{y}}{\Delta k} \quad \frac{\partial \tilde{y}}{\partial Z_5} \cong \frac{\Delta \tilde{y}}{\Delta Z_5} \quad \frac{\partial Z_5}{\partial k} \cong \frac{\Delta Z_5}{\Delta k}$$



valores iniciais dos parâmetros podem ser críticos, para que a convergência se de para os parâmetros da planta.

o passo α deve ser ajustado para cada variável


Aplicação: Circuito equivalente de um transformador

$$2 \ln |L_d(j\omega)| = 2 \ln L_{d0} + \sum_{j=1}^m \ln(1 + \omega^2 T_d^j{}^2) - \sum_{i=1}^n \ln(1 + \omega^2 T_{d0}^i{}^2)$$

$$\arg[L_d(j\omega)] = \sum_{j=1}^m \operatorname{tg}^{-1}(\omega T_d^j) - \sum_{i=1}^n \operatorname{tg}^{-1}(\omega T_{d0}^i)$$




III - Modelos Híbridos Neural-Fenomenológicos




Informação do Processo através do Modelo Fenomenológico
+
Precisão numérica através da Rede Neural

Qual a função da RN, como atua ?



Corrigindo o erro do modelo fenomenológico

Como treinar a Rede Neural ?



1 - propagação do sinal para a frente: os dois blocos (modelo fenomenológico e rede neural) atuam


2 - erro na saída do sistema completo $\varepsilon = y - \tilde{y} = y - (\tilde{y}_f + o_{rn})$

3 - erro retropropagado para a saída da RN = erro na saída do sistema completo, ε

IV Sub-modelos Híbridos Neural-Fenomenológicos

Modelos Fenomenológicos tratados como uma Rede Neural




Modelo Fenomenológico $\Rightarrow$ Sistema de equações $\Rightarrow$ Diagrama de Blocos $\Rightarrow$ Rede Neural



Modelo é composto por
blocos ou sub-modelos



ou “neuronios”




No modelo fenomenológico


o erro varia de bloco para bloco.

Como identificar os blocos com os maiores erros ?

Bloco com Block with

sinapses “mágicas” para correção do erro






Critério para erro do bloco:

$$\sigma_i = \sigma \left[\delta_i(p) \right]$$


Bloco com uma
sinapse “mágica” para correção do erro



Bloco com uma
rede neural para correção do erro.

**Que variáveis usar
como entrada da RN ?**


– correlatas com o erro do bloco



O erro do bloco vem de:

Função de transferência do bloco incorreta

- o erro do bloco está correlacionado com algumas entradas do próprio bloco
- use estas entradas na RN corretiva




Falta informação na entrada do bloco

- o erro do bloco não está correlacionado com as entradas do bloco
- teste outras variáveis disponíveis quanto à correlação com o erro do bloco. Se a correlação existe, use estas variáveis na entrada da rede neural de correção do bloco

Entradas da RN corretiva do bloco

- entradas do próprio bloco
 - **correlatas com o erro do bloco**
- outras variáveis disponíveis quando do cálculo do bloco
 - **correlatas com o erro do bloco**




ERROS DOS SUBMODELOS

DESVIO PADRÃO DO ERRO RETROPROPAGADO (δ_i) PARA CADA SUB-MODELO

Bloco	1	2	3	4	5	6	7	8	9	10	11	12
σ_i^2	0,17	0,07	0,09	0,57	1,09	0,00	0,13	0,01	0,97	0,16	0,13	0,49


A tabela acima evidencia que **os sub-modelos 5 and 9 são os mais críticos**, seguidos dos blocos 4 e 12.

Estes resultados concordam com a informação fenomenológica disponível.



Treinamento das RN's

- 1 - como no caso do modelo híbrido, na propagação do sinal para a frente todos os blocos (sub-modelos fenomenológicos e redes neurais locais) atuam**
- 2 - o erro a ser minimizado é o erro na saída do sistema completo ε**
- 3 - como no caso de ajuste dos parâmetros do modelo fenomenológico, o erro ε é retropropagado para a saída de cada RN, e daí para cada sinapse da mesma. As derivadas podem ser calculadas analítica ou numericamente**



RESULTADOS

ERRO RELATIVO RMS (%) PARA TODOS OS PARES.

Fenomenológico. UIT-R	Neural	Híbrido UIT-R-Neural
32	20	22

Outras contribuições de RNs para o estudo dos modelos fenomenológicos:

Estudo da importância das entradas:

Relevância de entradas

Estabelecimento de modelos:

Poda: Simplificação de estruturas para obtenção das equações do modelo fenomenológico

Modelos híbridos neural-fenomenológicos

Contribuição para entendimento dos modelos fenomenológicos.

FIM.

OBRIGADO PELO INTERESSE.