

Uso de Redes Neurais em Modelagem de Sistemas

- Sistemas estáticos

I - Modelos Matemáticos de Sistemas Físicos

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


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

equações (e seus parâmetros \mathbf{k}) minimizam

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

Modelos Fenomenológicos / Numéricos (Neurais)

Sistema à emular



Conhecimento do Sistema

Fenomenológico – equações – modelo caixa branca

Funcional – relação entrada/saída – modelo caixa preta

Pares entrada-saída $(\underline{x}^p, \underline{y}^p)$ $p = 1, \dots, P$

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 Numérico (Neural)



Sistema de equações:

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

Parâmetros (sinapses) à ajustar

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


Preciso

Informação fenomenológica ?

Aprendizado

(ou treinamento, ou ajuste de parâmetros)

como um processo de otimização



Aprendizado =
minimização do erro na saída

Erro a minimizar:

$$\varepsilon^{2^k} = \|\underline{\mathbf{y}}^k - \tilde{\underline{\mathbf{y}}}^k\|^2 = \sum_{l=1}^m (\underline{\mathbf{y}}_l^k - \tilde{\underline{\mathbf{y}}}_l^k)^2$$

Erro médio quadrático:

$$F_0 = E(\varepsilon^{2^k}) = \frac{1}{P} \sum_{k=1}^P \varepsilon^{2^k}$$

$$F_0 = E(\varepsilon^{2^k}) = F_0(\underline{\mathbf{w}}) \geq 0$$

Treinamento, Aprendizado: Minimizar o erro na saída

Função objetivo à minimizar:

$$F_0 = E(\varepsilon^{2^k}) = F_0(\underline{\mathbf{w}}) \geq 0$$

Problema:

Como encontrar o vetor $\underline{\mathbf{w}}_0$ (ou $\underline{\mathbf{k}}$) que minimize $F_0(\underline{\mathbf{w}})$?


$$F_0(\underline{\mathbf{w}}_0) \leq F_0(\underline{\mathbf{w}}) \quad \forall \underline{\mathbf{w}} \neq \underline{\mathbf{w}}_0$$

II - Modelos Fenomenológicos tratados como uma Rede Neural - Ajuste de parâmetros



Exemplo 1:

Atenuação de sinal em enlace terra-satélite



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

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

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

$$h_R = 5$$

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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


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

$$\text{else, } \beta = -0.005 (|\varphi| - 36) + 1.8 - 4.25 \text{ sen } (\theta)$$


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

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


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

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

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



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

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

II.2 - Cuidados a tomar no treinamento (ajuste)

II.2.1 – Escalamento das variáveis de entrada, saída e internas

Normalmente não é possível, porque as não linearidades das equações do modelo fenomenológico atuam de forma diversa dependendo do escalamento.

II.2.2 – Cálculo das derivadas

Os blocos podem apresentar transferências complexas. As derivadas podem ser calculadas analítica ou numericamente

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

Cálculo numérico das derivadas

$$y(x_0 + \Delta x) = y(x_0) + \Delta y = y(x_0) + \Delta x \frac{\partial y}{\partial x} + \frac{1}{2} (\alpha \Delta x)^2 \frac{\partial^2 y}{\partial x^2}$$

$$\Delta y(\Delta x) \Big|_{x=x_0} = \Delta x \frac{\partial y}{\partial x} + \frac{1}{2} (\Delta x)^2 \frac{\partial^2 y}{\partial x^2} =$$

$$\Delta y(\Delta x) \Big|_{x=x_0} = \Delta_I + \Delta_{II} \quad \text{Inpar}(\Delta x) + \text{Par}(\Delta x)$$

$$\Delta I = \frac{1}{2} [y(x_0 + \Delta x) - y(x_0 - \Delta x)]$$

cancela a contribuição dos acréscimos de ordem par

$$\Delta II = \frac{1}{2} [y(x_0 + \Delta x) + y(x_0 - \Delta x) - 2y(x_0)]$$

cancela a contribuição dos acréscimos de ordem ímpar

II.2.3 - Valores iniciais

Valores iniciais devem ser próximos dos valores esperados. Devido às não linearidades valores iniciais dos parâmetros podem ser críticos, para que a convergência se de para os parâmetros da planta e não para mínimos locais.


II.2.4 – Passo de treinamento

Deve ser pequeno de forma a garantir que a aproximação de primeira ordem seja válida. A aproximação de 1ª ordem é válida se

$$|\Delta_{II}| \ll |\Delta_I| \quad \left| \frac{1}{2} (\alpha \Delta x)^2 \frac{\partial^2 y}{\partial x^2} \right| \ll \left| \alpha \Delta x \frac{\partial y}{\partial x} \right|$$

Δ_I e Δ_{II} podem ser calculados numericamente cf item II.2.2 acima. Os passos α podem ser diferente para cada variável, de forma a garantir a condição acima.

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 $\epsilon = y - \tilde{y} = y - (\tilde{y}_f + o_{rn})$

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


III.1 - Um caso particular:

Sistemas com Não Linearidades Fracas

Modelo linear (fenomenológico ?) + complemento não linear



Modelo linear + complemento não linear




1 - Fazer as sinapses vermelhas nulas. Treinar apenas as sinapses azuis. $t_1=1$

2- Congelar as sinapses azuis. Treinar as sinapses vermelhas (com as azuis atuando).

IV Sub-modelos Híbridos Neural-Fenomenológicos

Modelos Fenomenológicos tratados como uma Rede Neural




Modelo Fenomenológico → Sistema de equações → Diagrama de Blocos → 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:

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


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

VARIÂNCIA 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 críticos.**




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.

Modelo	Fenom. UIT-R	Híbrido UIT-R-Neural	Neural
Erro	32	22	20

E a propagação do erro de um bloco para os blocos à frente ?

$Z_1 + \varepsilon_1$
 $Z_3 + \varepsilon_3$

Bloco Z_5
 Modelo Fenomenológico
 $Z_5 = f_5(Z_1, Z_3)$

$Z_5 = f(Z_1, Z_3) + \varepsilon_1 \frac{\partial Z_5}{\partial Z_1} + \varepsilon_3 \frac{\partial Z_5}{\partial Z_3} + \varepsilon_5$

Como formalizar o equacionamento ? Em aberto.