



Universidade Presbiteriana Mackenzie
Tradição e Pioneirismo na Educação

Palestra:

Redes Neurais na Modelagem de Sistemas Dinâmicos (e Séries Temporais)

Luiz Calôba

COPPE & Poli /UFRJ

www.lps.ufrj.br/~caloba

Abril de 2012

Redes Neurais na Modelagem de Sistemas Dinâmicos (e Séries Temporais)

Sistema SISO



Sistemas dinâmicos

$$y(t) = f[x(t), x(t-1), x(t-2), \dots, x(t-N)]$$

ou


$$y(t) = \varphi[x(t), \vec{e}(t)]$$

Modelos Não Recursivos

Modelo MA (moving average)

Filtro FIR

$$y(t) = \sum_{i=0}^T b_i x(t-i)$$



Time Delay Neural Network

Modelo NMA

$$y(t) = \varphi[x(t), x(t-1), \dots, x(t-N)]$$

Modelos Recursivos


Modelo AR (auto regressivo)

Filtro IIR

$$y(t) = b_0 x(t) + \sum_{i=1}^N a_i y(t-i)$$

Modelo NAR

$$y(t) = \varphi[x(t), y(t-1), \dots, y(t-N)]$$




Modelos Recursivos

Modelo ARMA

$$\tilde{y}(t) = \sum_{i=0}^M b_i x(t-i) + \sum_{i=1}^N a_i \tilde{y}(t-i)$$

Modelo **N**ARMA

$$y(t) = \phi[x(t), x(t-1), \dots, x(t-M), y(t-1), \dots, y(t-N)]$$



Dimensão dos Modelos

Planta:



linearizada nos pontos de operação

“singularidades”,
“frequências naturais”,
“constantes de tempo”

Dimensionando o MA (NMA)

$$N \cdot \Delta T \geq 4 \text{ Max } (\tau_i)$$


$$N \cdot \Delta T \geq \frac{2}{\pi f_{\min}}$$

$f_{\min} = 1 / (2\pi \text{Max}(\tau_i))$ é a mais baixa frequência natural do sistema, em Hz.

$$f_s = \frac{1}{\Delta T} \geq 2 f_{\max}$$

$f_{\max}$ = maior frequência operada pelo sistema


$$N \geq \frac{4}{\pi} \frac{f_{\max}}{f_{\min}}$$



Dimensionando o ARMA (NARMA)

N – ordem prevista (2,3)


$$M \leq N$$



NARMA muito menor que o MA mas pode instabilizar !


Como treinar a RN ?

Rede em Operação
(em modo paralelo)



Rede em Treinamento

Não é dinâmico, a rede
é treinada em separado !!




Treinamento da RN

Não é dinâmico, a rede é treinada em separado !!


Par entrada-saída $(\underline{e}(t), \underline{s}(t))$ correspondente ao instante t :

$$\underline{e}(t) = \begin{bmatrix} x(t) \\ x(t-1) \\ \dots \\ x(t-M) \\ y(t-N) \\ \dots \\ y(t-1) \end{bmatrix}$$

$$\underline{s}(t) = y(t)$$





Exemplo:



N=2


M=2



Construção dos pares entrada-saída para o treinamento:

t, n	x(n)	y(n)
...	...	...
52	x(52)	y(52)
53	x(53)	y(53)
54	x(54)	y(54)
55	x(55)	y(55)
56	x(56)	y(56)
57	x(57)	y(57)
...	...	...

t = n = 56



$$\left[\begin{array}{l} x(54) \\ x(55) \\ e(56) = x(56) \\ y(54) \\ y(55) \end{array} \right]$$

$$s(56) = y(56)]$$

Cuidados usuais a tomar com RNs

- 1 - Escolha das Variáveis de entrada
- 2 – Escalamento das Variáveis
- 3 - Pares entrada – saída
- 4 - Dimensionando a rede
- 5 – Inicializando a Rede
- 6 – Treinamento: Superfícies de Erro
- 7 – Overtraining (overfitting, sobre-treinamento)
- 8 – Critica durante o treinamento
- 9 - Validação Cruzada
- 10 – Critica pos treinamento
- 11 - Outros tipos de erro
- 12 – Outros Processos de Treinamento


Cuidados adicionais a tomar no caso de sistemas dinâmicos

1 - Escolha das Variáveis de entrada da rede neural

Quantas (quais) entradas / saídas atrasadas tomar ?

Entradas – existem atrasos puros ?

Saídas realimentadas - **ordem do sistema**




poucas: não representa
demasia: pode instabilizar

Tentativa e erro – ordem do sistema

Possível solução : **Poda de saídas realimentadas**
 na construção da RN automática / manual

2 – Escalamento das Variáveis

Rede **em operação** trabalha imersa em um escalador / desescalador



O escalador e o desescalador podem ser embutidos na primeira e última camada da rede treinada.

3 - Pares entrada – saída:

Mapeamento unívoco


$x_1 \gg y_1$ e $x_2 \gg y_2$

se $x_2 = x_1$ então $y_2 = y_1$

o modelo (inverso) é unívoco ?

Efeito de população local reduzida:

transição vs regime permanente



Efeito ? alto erro na região de baixa população

Correção ? replicar população

4 – Obtenção dos dados da planta

Pontos de operação para a modelagem:

Grande excursões (amplitudes) - explorar as não linearidades

Grande faixa de frequências – explorar todas as singularidades

entrada Ideal: ruído branco de grande amplitude

Pontos de operação reais:

Grandes excursões – busca do rendimento máximo


Operação suave – baixas frequências

E a caracterização das altas frequências ?

Aplicar um sinal piloto na entrada:


Altas frequências, baixa amplitude

$q(t)$ = onda quadrada de período aleatório




Enfatizar o erro em altas frequências na saída:

$$\varepsilon_M(t) = \varepsilon_{LF}(t) + k \varepsilon_{HF}(t)$$




Treinamento:



Operação da Rede


Operação em Paralelo

Independente da planta,
possível instabilidade




Operação em Série – Paralelo


Depende da planta,
estabilidade garantida
para que serve ? **Preditores** $y(t+k)$




Exemplo 1:



Operação em serie - paralelo



Operação em paralelo



Exemplo 2:


$$y(t) = \frac{y(t-1) y(t-2) y(t-3) x(t-2) [y(t-3) - 1] + x(t-1)}{1 + y(t-3)^2 + y(t-2)^3}$$

Entrada para treinamento e teste

$$x(t) = \sin(.1t) + .02 \text{ sq_rnd } (t)$$

Entrada para validação

$$x(k) = \begin{cases} \sin(\pi k / 25) & , k < 250 \\ +1 & , 250 \leq k < 375 \\ -1 & , 375 \leq k < 500 \\ 0,3\sin(\pi k / 25) + 0,1\sin(\pi k / 32) + 0,6\sin(\pi k / 10) & , 500 \leq k < 900 \end{cases}$$





Rede Neural: 7 neurônios na camada intermediária

Ordem do modelo (poda):


	Inicial	Final	Correta
N	5	3	3
M	4	2	2

Resultados



Uso em Series Temporais (modelo AR)

$S(t) =$ Tendencia +
 Sazonalidade +
 Ciclos senoidais +
 Outros artefatos determinísticos +
 Componentes não lineares +
 Ruído não correlato




Redes Neurais
predizem este
termo !

Trabalhar sobre a serie residual !


Series Temporais

Exemplo:




Resultados (período de teste):


Convencional



Holt-Winters



RNs



	Decomp.	Holt Winter	RN
1º Ano	4.71%	4.81%	3.68%
20 Meses	6.11%	5.25%	4.35%

FIM.

OBRIGADO PELO INTERESSE.