



Semana Universitária
22 a 26 de outubro de 2012
Universidade de Brasília

Ciência, Inovação Tecnológica e Sociedade:
o projeto da UnB 5 décadas depois



Redes Neurais em Séries Temporais:

Algumas Aplicações em Engenharia de Tráfego


Luiz P. Calôba.

COPPE & Poli/UFRJ

caloba@ufrj.br, www.lps.ufrj.br/~caloba


1 - Redes Neurais Artificiais

Emulam a maneira como o cérebro animal processa a informação



Sistema


entrada x



saída y

São aproximadores (mapeadores)

$$\underline{\tilde{y}} = \varphi(\underline{x})$$



São Aproximadores Universais !

Como “programar” a rede neural para responder ?

$$\underline{\tilde{y}} = \varphi(\underline{x})$$

Não são programadas ! treinam, aprendem por experiência


Não necessitamos conhecer o algoritmo

Sistema Real, Planta

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



Simulador



São excelentes ferramentas para modelar sistemas não lineares


2 - Séries Temporais

uma variável contínua no tempo ou

uma seqüência de dados ordenada no tempo

$s(t)$


$s(i)$



Previsão ?

Modelagem, previsão


Previsor



Componentes da Série

Componentes determinísticos lineares + Componentes não lineares + ruído

$S(t) =$ Artefatos espúrios + Tendência + Sazonalidade + Ciclos senoidais +
Componentes não lineares + Ruído não correlato



Decompondo a Série

Componentes determinísticos lineares + **Componentes não lineares** + **ruído**


$S(t) =$ **Artefatos espúrios** +
 Tendência +
 Sazonalidade +
 Ciclos senoidais +
 Componentes não lineares +
 Ruído não correlato




Redes Neurais
predizem este
termo !

A RN deve modelar apenas a série residual estacionária !

Série original



Série residual à ser modelada pela rede neural



3 – Engenharia de Tráfego

Modelos para o fluxo do tráfego

do ponto de vista das redes neurais e processamento de sinais

**Trânsito: Normas (Processamento Linear) +
 Reações Pessoais (Redes Neurais ?)**

Dois estudos preliminares

Estudo 1 – José Antonio Schultz

Efeito de um Semáforo em uma Via Rodoviária


Uma Abordagem com Redes Neurais Artificiais

Auto estrada Lagoa-Barra

Chegada à Gávea (Praça Sibelius)







045 - PREFEITURA
Pca. Sibélius

09:56:00
22-03-05

Fluxo do Trânsito nos três pontos

Semáforo: aberto: 90 s

fechado: 50 s




Intervalo de tempo: Divisor comum dos tempos do semáforo: 10 s

Peso dos veículos ~ comprimento: Caro: 1

Caminhão pequeno: 2


Ônibus: 3

Fluxo do Trânsito nos três pontos




efeito “passa baixas”

Séries sem tendência, normalizadas





Periodograma das séries




Sazonalidade principal

(140s – efeito do semáforo principal)

e séries sem a sazonalidade principal





Periodograma das séries após a extração da sazonalidade principal




Sazonalidades secundárias

(90s – efeito do semáforo secundário)

e séries sem a sazonalidade secundária



Periodograma das séries após a extração da sazonalidade secundária





Sazonalidades terciárias


(Ponto 1 – 120 s – causa ?)

(Ponto 2 – 80 s – causa ?)

e séries sem as sazonalidades terciárias



Periodograma das séries após a extração das sazonalidades terciárias




Autocorrelação das séries – entradas das RNs

Confiança 95%


$$N = 140$$

$$r \geq \frac{2}{\sqrt{N}} = 0.17$$




atrazos significativos: -1, -2

Rede Neural para a série residual




Resultados – ponto 1

sem RN




com RN




	Erro Médio Absoluto
Rede Neural Artificial	3,125%
Método Clássico	6,324%

Resultados – ponto 2

sem RN




com RN




	Erro Médio Absoluto
Rede Neural Artificial	2,426%
Método Clássico	3,723%

Resultados – ponto 3

sem RN






com RN






	Erro Médio Absoluto
Rede Neural Artificial	1,714%
Método Clássico	2,198%

Análogo elétrico



Análogo elétrico – filtro passa baixas



Estudo 2 – Victor Dweck

Simulação do Fluxo de Veículos em uma

Intersecção Rodoviária Saturada e Não-Semaforizada

Uma Abordagem com Redes Neurais Artificiais

“Gap acceptance, merge like a zip”



Intersecção saturada ?

sem “gaps”

**comportamento humano
(rede neural ?)**




Intersecção Rua Farani vs. Pinheiro Machado



Saturada, Não-Semaforizada

Intersecção Rua Farani vs. Pinheiro Machado



Notar:

Semáforo

Sinalização “ceda a vez”

5 faixas >>> 2 faixas

Dados


Intervalo: 15 s, 0 – 20 carros
(mal arbitrado !)

Carros: 1

Caminhões pequenos: 2


Ônibus: 3

Efeito semáforo




$$\Delta T = 15 \text{ s} \quad (0 - 20 \text{ cars})$$

Vehicle Flow Time Series




Approximated Seasonality





$$9 \times 15s = 135s \quad \# \quad 140s$$

Análise de Fourier,

Extração das componentes principais (uma alternativa para a sazonalidade)




$$9.38 \times 15 = 140.7$$



Correlação entre as séries residuais

$$O \times O$$



$$I_1 \times O$$




$$I_2 \times O$$



$$O(-1)$$

$$O(-3)$$

$$O(-4)$$



$$I_1(0)$$

$$I_2(0)$$


$$I_1(-2)$$

$$I_2(-2)$$

$$I_1(-3)$$

$$I_2(-3)$$


Resultados:




$I_1(0)$ $I_2(0)$
 $I_1(-2)$ $I_2(-2)$
 $I_1(-3)$ $I_2(-3)$

feedforward
model


$I_1(-2)$ $I_2(-2)$ $\vdots$ No NN
 $I_1(-3)$ $I_2(-3)$



$e = 4.5\%$



$e = 7.4\%$



$e = 8.8\%$

Referências:

Redes Neurais

- Ivan Silva, I.; Spatti, D. e Flauzini, R. - "Redes Neurais Artificiais para engenharia e ciências aplicadas", Artliber, 2010, cap 1-6.
- Haykin, S., “Neural Networks, A Comprehensive Foundation”, Prentice Hall, 1999.
Ver também: Haykin, S., “Redes Neurais, Teoria e Prática”, Bookman, 2001.

Séries Temporais

- Chatfield, C., “The Analysis of Time Series, An Introduction”, 6th edition, Chapman and Hall, 2004.
- Morettin, P. A.; Toloi, C. M. C., “Previsão de Séries Temporais”, Atual Editora, São Paulo, 1987.
- Calôba, L.P. , “Introdução ao Uso de Redes Neurais na Modelagem de Sistemas Dinâmicos e Séries Temporais”, Livro de Minicursos do XIV Congresso Brasileiro de Automática, Natal, 2002, pp 1-52.

Fim.

Obrigado pelo interesse.

www.lps.ufrj.br/~caloba