

Redes Neurais em Séries Temporais

Referências:

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. (está no site da disciplina)


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.

Séries Temporais


uma variável contínua no tempo ou

uma sequência de dados ordenada no tempo



Tempo contínuo

$s(t)$ tal que $t \in (t_0, t_1)$ $s(t)$


**Tempo discreto**

$s(t)$ ou $s(i)$
tal que $t, i \in [1, 2, \dots, N]$

pares $[t, x(t)]$

Modelo para a série: sistema tal que

resposta no tempo: pares $[t, s(t)]$



não é eficaz.

O que usar ?

Modelo Determinístico Linear + Redes Neurais


$S(t) =$ **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 !



Previsão

$s_1 \quad s_2 \quad \dots \quad s_i \quad \xRightarrow{?} \quad \tilde{s}_{i+1} \quad \dots \quad \tilde{s}_{i+h}$



$\Rightarrow$ *Análise*


*Decomposição em
séries mais simples*



$$s(t) = s_a(t) + s_b(t) + \dots + s_z(t)$$

Tipo de decomposição

Aditiva

$$s(t) = s_a(t) + s_b(t) + s_c(t) + s_r(t)$$

$$s_r = s - s_a - s_b - s_c$$

Multiplicativa

$$s(t) = s_a(t) \cdot s_b(t) \cdot s_c(t) \cdot s_r(t)$$

$\log \Rightarrow$ aditiva

Mista

$$s(t) = s_a(t) [s_b(t) + s_c(t)] + s_r(t)$$


$\Rightarrow$ Decomposição aditiva

$$s_r(t) = s(t) - s_a(t) - s_b(t) - s_c(t)$$

Tipos de Componentes

como determinar ?

1ª análise - subjective - plotar a série !




Componentes da decomposição

Tendência



$t(t)$



Sazonalidade

período T

$$\frac{1}{T} \left[\text{período } \frac{T}{T} \right]$$



Ciclo periódico

$$a \cos \left[\omega t + \theta \right]$$

Termos não lineares

$n(t)$

ruído

$r(t)$

Quebras e outras irregularidades drásticas!

Série residual

$$s_r(t) = s(t) - \text{tend}(t) - s_z(t) - cs(t)$$

$$= nl(t) + r(t)$$

estacionária no tempo?

ou o mais próximo possível disso!

Séries estacionárias no tempo

$$m_j(t) = cte(t)$$

$$\left. \begin{array}{l} \mu(t) = cte(t) \\ \sigma^2(t) = cte(t) \end{array} \right\} \begin{array}{l} \text{fracamente} \\ \text{estacionária} \end{array}$$

$$m_3(t) = cte(t)$$

$\vdots$


Modelo para séries (fracamente) estacionárias no tempo

A informação de tempo é desnecessária !


série = resposta impulsiva de um

modelo não linear auto regressivo, NAR

**modelo estável,
sem componentes periódicas**



Operação do preditor



Operação série –paralelo, estável

Decomposição:

$$S = S_e + S_{ne}$$

$$\Rightarrow S_1 = S - S_{ne}$$

$$S = S_{ne} + f(i) S_e$$

$$\Rightarrow S_1 = S - S_{ne}$$

$$S_2 = \frac{1}{f(i)} S_1$$

Alguns exemplos de séries temporais:




Figure 1.1 Part of the Beveridge wheat price index series.




Figure 1.2 Average air temperature at Recife, Brazil, in successive months.




Figure 1.4 A process control chart.








Figure 1.3 Sales of a certain engineering company in successive months.



(a) Discontinuity present: numbers of new insurance policies issued by a particular life office (monthly in hundreds).



Série alvo: Vazão em São Félix.



Análise no Domínio do Tempo

Ferramenta: Correlação, Correlograma

$$\text{Séries} \quad x_1 \quad x_2 \quad x_3 \quad \dots \quad E(x) = 0$$

$$y_1 \quad y_2 \quad y_3 \quad \dots \quad E(y) = 0$$

$$r(x, y) = \frac{\sum_{i=1}^n x_i y_i}{\left[\sum_{i=1}^N x_i^2 \sum_{i=1}^N y_i^2 \right]^{1/2}}$$

$$= \frac{\frac{1}{N} \sum x_i y_i}{\sigma_x \sigma_y}$$

Auto correlação

$$r_k = \frac{\sum_{i=1}^{N-k} x_i x_{i+k}}{\sum_{i=1}^N x_i^2} \cdot \frac{N}{N-k} \quad k > 0$$


Correlação cruzada

$$r_k(x, y) = \frac{\sum_{i=1}^{N-k} x_i y_{i+k}}{\left[\sum_{i=1}^{N-k} x_i^2 \sum_{i=k+1}^N y_i^2 \right]^{1/2}}$$

Confiança

Sequências randômicas $\mu_r \approx 0$

$r \approx \text{normal}$ $\sigma_r = \frac{1}{\sqrt{N}}$



$$|r| > 2\sigma_r = 2/\sqrt{N}$$

Não correlação $|r| < \frac{2}{\sqrt{N}}$

2σ $\Rightarrow$ **95 %**




Figure 4.1 The correlogram of 100 'independent' normally distributed observations.

Exemplos:




Figure 2.1 A time series showing short-term correlation together with its correlogram.




Figure 2.3 A non-stationary time series together with its correlogram.

Temperatura no Recife




Figure 1.2 Average air temperature at Recife, Brazil, in successive months.




Figure 2.4 The correlogram of monthly observations on air temperature at Recife: (a) for the raw data; (b) for the seasonally adjusted data. The dotted lines in (b) are at $\pm 2/\sqrt{N}$. Values outside these lines are significantly different from zero.

Correlação parcial

$$x_i = \alpha_1 x_{i-1} + \dots + \alpha_p x_{i-p} + \text{res}$$

$$\mu = 0$$

$$p=1 \quad \alpha_1 = r_1$$

$$p=2 \quad \alpha_1 = r_1 (1 - r_2) / (1 - r_1^2)$$

$$\alpha_2 = (r_2 - r_1^2) / (1 - r_1^2)$$

$$p \quad R = \begin{bmatrix} 1 & r_1 & r_2 & \dots & r_{p-1} \\ r_1 & 1 & r_1 & \dots & r_{p-2} \\ & r_{p-1} & r_{p-2} & & 1 \end{bmatrix}$$

$$[R] \underline{\alpha} = r \quad \therefore \underline{\alpha} = \dots$$




Figure 2.1 A time series showing short-term correlation together with its correlogram.

Análise no Domínio da Frequência

Ferramenta: Série de Fourier, Espectrograma, Periodograma

$$s(t) \quad t = 1, \dots, N \quad \Delta t = 1$$

$$s(t) = a_0 + \sum_{i=1}^{\frac{N}{2}-1} \left[a_i \cos 2\pi \frac{i}{N} t + \right.$$

$$\left. b_i \sin 2\pi \frac{i}{N} t \right] + \frac{a_N}{2} \cos \pi t$$

$$= a_0 + \sum_{i=1}^{\frac{N}{2}-1} R_i \cos \left(2\pi \frac{i}{N} t + \theta_i \right) + \frac{a_N}{2} \cos \pi t$$

$$\begin{aligned}
 s(t) &= a_0 + \sum_{i=1}^{\frac{N}{2}-1} \left[a_i \cos 2\pi \frac{i}{N} t + b_i \sin 2\pi \frac{i}{N} t \right] + \frac{a_N}{2} \cos \pi t \\
 &= a_0 + \sum_{i=1}^{\frac{N}{2}-1} R_i \cos \left(2\pi \frac{i}{N} t + \theta_i \right) + \frac{a_N}{2} \cos \pi t
 \end{aligned}$$

Frequências: $f_i = \frac{i}{N} = \frac{1}{N}, \frac{2}{N}, \dots, \frac{N}{2} - \frac{1}{N}$

Resolução: $\Delta f = \frac{1}{N}$


"Energia"

$$P(f_i) = R_i^2 = a_i^2 + b_i^2$$

Espectrograma

$$R_i^2 = a_i^2 + b_i^2 \quad i=1, \dots, \frac{N}{2}-1$$

$$f_i = \frac{i}{N}, \dots, \frac{N}{2} - \frac{1}{N}$$



Resolução $\Delta f = 1/N$

Confiança

x_i randomica (ruído branco)

$$E(x) = 0 \quad \text{Pot}(x) = \sigma^2$$

$$\Rightarrow \frac{N R_p^2}{2 \sigma^2} = \chi_2^2 \quad \chi_2^2(.95) = 5.99$$

$$R_p^2 > \frac{12}{N} \sigma^2 \Rightarrow 95\% \text{ confiança}$$




Figure 1.2 Average air temperature at Recife, Brazil, in successive months.









Figure 7.5 Spectra for average monthly air temperature readings at Recife, (a) for the raw data; (b) for the seasonally adjusted data using the Tukey window with $M=24$; (c) the periodogram of the seasonally adjusted data is shown for comparison.

Espectros Típicos



Média, Tendência



Sazonalidade



Ciclo Sazonal




Decompondo a Série


1 - Quebrar S outros efeitos drásticos

Observar o plot da série

Restringir as regiões de trabalho



Corrigir o efeito




Tendência:

2 - Retirada da Tendência

Tipo? observar o plot da série!

ordem 0 $t_j(t) = a_0$ 

ordem 1 $t_j(t) = a_0 + a_1 t$ 

ordem 2 $t_j(t) = a_0 + a_1 t + a_2 t^2$ 

log


exp $t_j(t) = a_0 e^{a_1 t}$

Cálculo da tendência linear:

Cálculo: ajuste por e.m.q.

$$\varepsilon(t) = s(t) - t_j(t)$$

$$F(a_0, a_1) = E[\varepsilon^2(t)] = \frac{1}{N} \sum_{t=1}^N (s(t) - (a_0 + a_1 t))^2$$



Tendência linear : solução analítica

$$s \approx \tilde{s} = t_f(t) = a_0 + a_1 t$$

$$F = E(s - \tilde{s})^2 = E(s - (a_0 + a_1 t))^2$$

$$\frac{\partial F}{\partial a_0} = -2 [E(s) - a_1 E(t) - a_0] = 0 \quad ①$$

$$\frac{\partial F}{\partial a_1} = 2 [a_1 E(t^2) - E(ts) + a_0 E(t)] = 0 \quad ②$$

$\Rightarrow$

$$a_1 = \frac{E(ts) - E(t) E(s)}{E(t^2) - [E(t)]^2}$$

$$a_0 = E(s) - a_1 E(t)$$

Retirada da Tendência

Retirada da tendência

$$s_1(t) = s(t) - t_f(t)$$

linear : $s_1(t) = s(t) - (a_0 + a_1 t)$

$s_1(t)$ – série residual após a retirada da tendência

Tendência:

Tratamento via diferenciação

1. Processar com média móvel

$$s(t) = s_1(t) + \underset{\substack{\uparrow \\ \text{⚡}}}{a_0}$$

*SUAVE E NÃO LINEARMENTE
variante no tempo*

$$s'(t) = \frac{ds}{dt} = \frac{d}{dt} s_1(t) + \epsilon$$

Tempo discreto

$$s'(t) \approx s(t+1) - s(t)$$

⚡

série à prever, SEM MÉDIA MÓVEL

(com mais ruído em HF)

Reconstrução (Taylor):

$$s(t + \Delta t) \approx s(t) + s'(t) \Delta t$$

$$s(t+1) \approx s(t) + \underset{\substack{\uparrow \\ \text{real}}}{s'(t)} + \underset{\substack{\uparrow \\ \text{previsto}}}{\tilde{s}'(t)}$$

Tendência:

2 - Procurar com "tendência linear móvel"

$$s(t) = s_1(t) + a_1 t + a_0$$

$$s'(t) = \frac{ds_1}{dt} + a_1 + \epsilon_0$$

$$s''(t) = \frac{d^2 s_1}{dt^2} + \epsilon$$

Tempo discreto

$$s'(t) = s(t+1) - s(t) \quad t = 1, 2, \dots, N-1$$

$$s''(t) = s'(t+1) - s'(t)$$

$$s''(t) = s(t+2) - 2s(t+1) + s(t)$$

$$t = 1, 2, \dots, N-2$$



série a prever, SEM TENDÊNCIA
LINEAR MÓVEL

Reconstrução (Taylor):

$$s(t+2) = 2s(t+1) - s(t) + \tilde{s}''(t)$$

$$s(t+1) = 2s(t) - s(t-1) + \tilde{s}''(t-1)$$

↑
reais

↑
previsto

Ferramentas básicas para a Análise da Série

Correlograma

+

Espectrograma

+

Fenomenologia

$\Rightarrow$


Sazonalidade

Componentes Senoidais

3 - Sazonalidade


Observar a forma temporal

Observar o espectrograma /
correlograma



Período $P = 6$

períodos $L = \text{Int}(N/P)$



Padrão

$$s_z(i) = \frac{1}{L} \sum_{k=0}^{L-1} s_1(i+kP) \quad i=1, \dots, P$$

Sinal




$$s_z(P) \Rightarrow s_z(0)$$

$$s_1(t) \cong s_z\left(\text{Resto} \frac{t}{P}\right)$$

sazonalidade constante

Retirando a sazonalidade

$$s_2(t) = s_1(t) - s_z\left(\text{Resto}\left(\frac{t}{P}\right)\right)$$



Sazonalidade com amplitude linearmente variável com o tempo

$$s_2(t) \approx \underset{\substack{\uparrow \\ \sim a_0 + a_1 t}}{f(t)} \cdot \underset{\substack{\uparrow \\ \text{cte}(t)}}{s_3(t)}$$

$$\log s_2(t) = \underset{\substack{\uparrow \\ \text{tendencia}}}{\log f(t)} + \underset{\substack{\uparrow \\ \text{sazonalidade} \\ \text{cte}(t)}}{\log s_3(t)}$$






Figure 1.3 Sales of a certain engineering company in successive months.



4 - Ciclos senoidais



Observar o espectrograma



$$cs_1(t) = a_{p_1} \cos \frac{2\pi}{N} p_1 t + b_{p_1} \sin \frac{2\pi}{N} p_1 t$$

Retirar os ciclos senoidais

$$s_3(t) = s_2(t) - cs_1(t) - cs_2(t)$$




Precisão

A precisão da FFT pode ser insuficiente, especialmente para frequências muito altas / muito baixas

$$\Delta f = \frac{1}{N}$$

$$f_k < f < f_{k+1} = f_k + \frac{1}{N}$$



**Se a precisão não for suficiente após o procedimento de extração
a componente continua a aparecer no espectograma !**

Solução:

$$F = \frac{1}{N} \sum_{t=1}^N \left[s_i(t) - \right.$$

Calcular a frequência e os os
coeficientes de Fourier direto
no domínio do tempo,
minimizando F

$$\left(a \cos 2\pi f t + b \sin 2\pi f t \right) \int^2$$

$$\Rightarrow a, b \text{ e } f$$

ótimos


Sub a amostragem

$$\Delta T = 1 \quad f_s = \frac{1}{\Delta T} = 1$$

$$\Delta f = \frac{1}{N} \quad f^* = .5$$

Aliasing, recobrimento do espectro

Repetição de espectro



Solução:

Utilizar filtros anti-aliasing, passa baixas **com fase linear**

Obs:

1 - filtros com fase não linear podem distorcer fortemente o sinal no tempo !

2 – o filtro anti-aliasing com fase linear (FIR) adoça o sinal no tempo, logo também provoca uma (pequena) distorção.

Observações gerais sobre a decomposição da série:

1 – A retirada de uma componente $c(t)$ é válida apenas se a “potência” da série diminui, i.e., se

$$s_4(t) = s_3(t) - c(t) \quad \text{então obrigatoriamente} \quad \frac{1}{N} \sum_{i=1}^N s_3^2(i) > \frac{1}{N} \sum_{i=1}^N s_4^2(i)$$

2 – Usualmente após a retirada de uma componente é recomendável restaurar a média (nula) e a variância (unitária) da série.

5 - Termos não lineares


RNs

$$s_3(t) = n(t) + r(t)$$

Modelados como resposta de uma rede neural

Entradas: valores atrasados da série
(+outras entradas relevantes)

Saída: saída da série no instante de interesse, $t+k$, $k \geq 0$




5 - Termos não lineares $\longrightarrow$ RNs

$$s_3(t) = n(t) + r(t)$$

Correlações significativas

Autocorrelação (parcial)



$$k = 1, 2 \quad s_3(t-1) \quad s_3(t-2)$$


Correlação com amplitude ?

$$s(t) \approx s_0(t) = \text{trend}(t) + c_s(t) + s_z(t)$$

$$r [s_3(t), s_0(t)]$$



É comum a não linearidade depender da amplitude do sinal

A amplitude média $s_0(t)$ é conhecida pela composição com os termos determinísticos !

Preditor para $s_3(t+k)$ 

Entradas: valores atrasados da série
com correlação significativa com a saída
+
outras entradas relevantes, e.g valor previsto
para a saída pelo preditor determinístico, etc.

Saída: saída da série no instante de interesse, $t+k$, $k \geq 0$

Geração dos pares entrada – saída para treinamento, teste e validação**Exemplo: Preditor para $k=0$** 


Relevantes: $s(t-1)$ $s(t-2)$

Todo tempo t gera um par:


$$(entrada, saída) = (\vec{x}, y) = \left(\begin{bmatrix} s(t-1) \\ s(t-2) \end{bmatrix}, s(t) \right)$$


Escolha dos conjuntos de pares para treinamento, teste e validação.

Pares (e, s)



Operação do Preditor






Não recomendável, potencialmente instável

6 - Recomposição da função

$$\tilde{S}(t+k_0) = \left. \begin{aligned} &\tau(t+k_0) + \\ &CS(t+k_0) + \\ &SZ(t+k_0) + \\ &\tilde{S}_3(t+k_0) \end{aligned} \right\} \begin{array}{l} \text{clássico} \\ \\ \\ \text{RN} \end{array}$$

Ex 1 – Fabricação de Cerveja na Austrália 1958 – 1994




Série completa

Aparência, Artefatos (tendência variável)


Tendência

**Série truncada (76-93) e
tendência linear**




Extração da tendência

Série sem tendência




Sazonalidade anual

Padrão sazonal anual




Série sem sazonalidade



Busca de outras sazonalidades e ciclos senoidais


Análise de Fourier




Extração dos ciclos senoidais

Análise no Tempo

e na Frequência




Série residual




Espectrograma da série residual


Série residual à ser prevista pelo modelo NAR



Que atrasos utilizar ?




Auto-correlograma da série



Autocorrelograma da série residual

os atrasos de 11, 38 e 50 meses apresentam confiança maior que 95 %


Rede Neural




6 neurônios na camada intermediária

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%

Uso de Séries Auxiliares

série principal $s(t)$

séries auxiliares $f(t)$, $g(t)$

Pre tratamento da série principal

$$s_3(t) = s(t) - t(t) - cs(t) - s_2(t)$$

Pre tratamento das séries secundarias

Pretratamento das séries secundárias

$$f_3(t) = f(t) - t_s(t) - CS_s(t) - S_{2_s}(t)$$


Retirar tendência $t_s(t)$ do mesmo
tipo que $t(t)$, se existir

Retirar ciclos sazonais $CS_s(t)$
das mesmas frequências da

Retirar sazonalidade $S_{2_s}(t)$ com
mesmo período da de $S_2(t)$, se existir


Verificar correlações significativas

$$r[f_3(t), s(t+k)]$$



significativas $k = 1, 2$

Preditor para $s_3(t+k_0)$



para todo k_i com correlação significativa com $s_3(t+k_0)$

Recomposição da Função

$$\begin{aligned} \tilde{s}(t+k_0) &= \tau(t+k_0) + c s(t+k_0) + \\ &+ s_2(t+k_0) + \tilde{s}_3(t+k_0) \end{aligned}$$

EX 2 - Vazão do Rio Tocantins em São Felix (Alto Tocantins)

Bacia hidrográfica do Alto Tocantins

Uso de Séries auxiliares:


Série alvo:

- Vazão no posto São Félix

Séries auxiliares:

- Chuva: Precipitação pluviométrica na região.
- Vazão em afluentes a montante, nos postos:
 - Colônia dos Americanos,
 - Porto Rio Bagagem,
 - Ceres,
 - Jaraguá,
 - Ponte Quebra-Linha,
 - Tocantinzinho e
 - Porto Uruaçu.


Bacia hidrográfica do Alto Tocantins



Dados: 1974 a 1979

- Treinamento e Teste: 1974 a 1978.
- Validação: 1979


Série alvo: Vazão em São Felix



Média, Tendência

Sazonalidade anual variável; Grandes variações


Séries Auxiliares: Vazão 9 de afluentes à montante:





Pré-processamento da Série Alvo:


Transformação $\ln(\cdot)$:



Vazão em São Félix, escala logarítmica.


Retirada da Tendência

$$tend(t) = 10,23 \cdot 10^{-6} x + 6,4579$$




Série sem tendência.

Análise de Fourier, Retirada da Sazonalidade



Periodograma da série sem tendência.

Período: 365.2 dias >>> 365 dias.



Série sem sazonalidade anual.

Retirada de outras componentes senoidais





Fig. 31 – Espectrograma da série sem sazonalidade anual.

Períodos: 456, 1826 dias



Série final de resíduos para a vazão em São Félix.

>>> Ainda não é estacionária !


Metodologia:

- todas as séries são processadas como no caso anterior, obtendo-se as séries residuais
- é feito o auto-correlograma da série alvo residual para prever os atrasos relevantes para a previsão e
- é feito o correlograma cruzado da série alvo residual com cada uma das séries auxiliares residuais para determinar quais os atrasos de cada série auxiliar residual que são relevantes para prever a série alvo residual.
- é montada uma rede neural cujas entradas são os atrasos relevantes de todas as séries residuais.


Pré-processamento das séries auxiliares

Análogo ao da série alvo


Correlações entre séries de resíduos:



S. Félix, autocorrelação



S. Félix versus Rio Bagagem



S. Félix versus Chuva

Os dados da chuva foram apenas normalizados

Rede Neural

Entradas:

valores atrasados de 1 à 5 dias de cada uma das 9 séries
45 entradas

Saídas:



Vazões em $t+1$, $t+2$ ou $t+5$
1 neurônio linear

Camada intermediária:



1 neurônio !! o mapeamento é linear !

Resultados:

Previsão para 1 dia no futuro:



Previsão para 5 dias no futuro:




Resumo:

Dias Futuros	Erro “batch” (%)	Erro ótimo (%)
1	4,7	4,4
2	8,2	7,3
3	10,5	10,2
4	13,5	13,5
5	17,1	16,2

Ex 3 - Simulação do Fluxo de Veículos em uma Interseção Rodoviária não-semaforizada usando RNs

Intersecção Rua Farani vs. Pinheiro Machado






Semáforo


Sinalização “ceda a vez”

Observar: placa “ceda a vez”


Semáforo

Dados**Intervalo: 15 s (mal arbitrado !)****Carros: 1****Caminhões pequenos: 2****Ônibus: 3****Efeito sinais tráfego****Vehicle Flow Time Series****Approximated Seasonality**



Fourier Analysis - Periodogram



Extraction of main Fourier components



CORRELATIONS between residues series



Resultados:

