

Agrupamento de Séries Temporais e sua Aplicação na Análise de Processos Geofísicos e Ambientais

Manuel G. Scotto

Departamento de Matemática
IST, ULisboa



Conteúdo

- Agrupamento de objetos;
- Métodos de agrupamento de séries temporais;
- Aplicações (**dados geofísicos e ambientais**);
- Bibliografia.


Agrupamento de objetos

- O processo de agrupamento tem por finalidade **criar grupos** de dados/objetos, de acordo com o seu **grau de semelhança**.

Agrupamento de objetos

- O processo de agrupamento tem por finalidade **criar grupos** de dados/objetos, de acordo com o seu **grau de semelhança**.

What is a natural grouping among these objects?



Agrupamento de objetos

- O agrupamento é feito de tal forma que os objetos pertencentes à mesma classe sejam o mais **semelhantes** entre si do que objetos em classes diferentes, de acordo com algum **critério definido a priori**.

Agrupamento de objetos

- O agrupamento é feito de tal forma que os objetos pertencentes à mesma classe sejam o mais **semelhantes** entre si do que objetos em classes diferentes, de acordo com algum **critério definido a priori**.

Clustering is subjective



Simpson's Family



School Employees



Females



Males

Agrupamento de Séries Temporais



Agrupamento de Séries Temporais



Caixa Geral
de Depósitos

 Santander

 BPI

 Millennium
bcp

 Montepio

 BancoBIC

 NOVO BANCO

 CA
Crédito Agrícola

 DM
DEPARTAMENTO
DE MATEMÁTICA
TÉCNICO LISBOA

Agrupamento de Séries Temporais

facebook

waze




skype™

twitter

Agrupamento de Séries Temporais

El delantero más desacertado de Europa

Goles marcados y goles esperados de los delanteros de las cinco grandes ligas



Fuente: Wikipedia y elaboración propia

KIKO LLANERAS / EL PAÍS

Etapas no agrupamento de objetos

- Seleção de objetos e variáveis;
- Seleção da medida de proximidade;
- Escolha do método de formação de clusters;
- Apresentação e discussão dos resultados.

Seleção de objetos e variáveis

Code Client	Type Client	Sector	Cod-Sector	Age	Connection	Loans	Money

Seleção de objetos e variáveis

Code Client	Type Client	Sector	Cod-Sector	Age	Connection	Loans	Money
-------------	-------------	--------	------------	-----	------------	-------	-------




Seleção de objetos e variáveis

Code Client	Type Client	Sector	Cod-Sector	Age	Connection	Loans	Money
-------------	-------------	--------	------------	-----	------------	-------	-------



Seleção de objetos e variáveis



Seleção da Medida de Proximidade

Measure	Formula
D1: Euclidean distance	$d_{ij} = \left[\sum_{k=1}^p w_k^2 (x_{ik} - x_{jk})^2 \right]^{1/2}$
D2: City block distance	$d_{ij} = \sum_{k=1}^p w_k x_{ik} - x_{jk} $
D3: Minkowski distance	$d_{ij} = \left(\sum_{k=1}^p w_k^r x_{ik} - x_{jk} ^r \right)^{1/r} \quad (r \geq 1)$
D4: Canberra distance (Lance and Williams, 1966)	$d_{ij} = \begin{cases} 0 & \text{for } x_{ik} = x_{jk} = 0 \\ \sum_{k=1}^p w_k x_{ik} - x_{jk} / (x_{ik} + x_{jk}) & \text{for } x_{ik} \neq 0 \text{ or } x_{jk} \neq 0 \end{cases}$
D5: Pearson correlation	$\delta_{ij} = (1 - \phi_{ij})/2 \text{ with}$ $\phi_{ij} = \sum_{k=1}^p w_k (x_{ik} - \bar{x}_{i\bullet})(x_{jk} - \bar{x}_{j\bullet}) / \sqrt{\left[\sum_{k=1}^p w_k (x_{ik} - \bar{x}_{i\bullet})^2 \sum_{k=1}^p w_k (x_{jk} - \bar{x}_{j\bullet})^2 \right]}$ where $\bar{x}_{i\bullet} = \sum_{k=1}^p w_k x_{ik} / \sum_{k=1}^p w_k$
D6: Angular separation	$\delta_{ij} = (1 - \phi_{ij})/2 \text{ with}$ $\phi_{ij} = \sum_{k=1}^p w_k x_{ik} x_{jk} / \sqrt{\left(\sum_{k=1}^p w_k x_{ik}^2 \sum_{k=1}^p w_k x_{jk}^2 \right)}$

Tipo de métodos

- **Métodos não hierárquicos:** os métodos não hierárquicos criam os k melhores grupos, em que k é imposto à partida;
- **Métodos hierárquicos**

Métodos não hierárquicos

Os métodos por partição constroem k grupos e classificam os elementos nos k grupos de acordo com os seguintes requisitos:

Métodos não hierárquicos

Os métodos por partição constroem k grupos e classificam os elementos nos k grupos de acordo com os seguintes requisitos:

- cada grupo **contém pelo menos** um elemento;
- cada elemento **pertence a um só** grupo.

Métodos não hierárquicos

Os métodos por partição constroem k grupos e classificam os elementos nos k grupos de acordo com os seguintes requisitos:


- cada grupo **contém pelo menos** um elemento;
- cada elemento **pertence a um só** grupo.

O algoritmo procura uma partição de tal forma que os objetos pertencentes a um mesmo grupo estejam o **mais próximo** possível e que casos em grupos diferentes estejam o **mais afastados** possível (**princípio de coesão interna e isolamento externo**).



Algoritmo

- 1 Selecionar a partição inicial;
- 2 Colocar cada objeto no grupo que tem o centróide mais próximo dele.
- 3 Recalcular os centróides dos novos grupos;
- 4 Repetir os passos 2 e 3 até não haver mais recolocações.



k -means







k -means



k -means




k -means



Escolha do Método de Formação de Grupos

Métodos hierárquicos (MH)

Nos MH existem **2 procedimentos**: aglomerativo e divisivo




Métodos hierárquicos

- Método do vizinho **mais próximo** (*single linkage*);
- Método do vizinho **mais afastado** (*complete linkage*);
- Método de ligação **por média** (*average linkage*);
- Método de Ward.

Escolha do Método de Formação de Grupos

Método do vizinho **mais próximo** (*single linkage*)


$$d_{AB} = \min_{a \in A, b \in B} \{d(a, b)\}.$$



Escolha do Método de Formação de Grupos

Método do vizinho **mais afastado** (*complete linkage*)


$$d_{AB} = \max_{a \in A, b \in B} \{d(a, b)\}.$$



Escolha do Método de Formação de Grupos

Método de ligação **por média** (*average linkage*);

$$d_{AB} = (|A||B|)^{-1} \sum_{a \in A} \sum_{b \in B} d(a, b).$$



Agrupamento de objetos

- Embora uma parte significativa dos métodos de agrupamento propostos na literatura sejam para classificar dados sem estrutura de dependência temporal, nos últimos anos têm vindo a ser propostos vários métodos para **classificar séries temporais**.



Série temporal?

Wikipedia: Uma série temporal é uma sequência de realizações (observações) de uma variável ao longo do tempo. Dito de outra forma, é uma sequência de pontos (dados numéricos) em ordem sucessiva, geralmente ocorrendo em intervalos uniformes. Portanto, uma série temporal é uma sequência de números coletados em intervalos regulares durante um período de tempo.




Exemplos de Séries Temporais

- Concentrações horárias, em μgm^{-3} , de O₃ em Els Torms (TOR), Víznar (VIZ), Paio Pires (PP) e Custóias (CUS)




Exemplos de Séries Temporais

- Número semanal de novos casos de Human Papilloma Virus (HPV) num hospital de Girona (Catalunya/España)



Exemplos de Séries Temporais

- Número semanal de dias com chuva em Bremen (Alemanha) durante o período 2000-2010




Agrupamento de séries temporais

- A **análise de séries temporais** geofísicas e ambientais tem suscitado um **interesse crescente** pela sua relevância científica e socioeconómica e pelo seu papel na identificação, compreensão e mitigação das alterações climáticas.
- A disponibilidade cada vez mais generalizada, e de forma aberta e gratuita, de dados meteorológicos de estações, satélites torna cada vez mais evidente a necessidade de ferramentas para **resumir a informação** contida nesse enorme volume de dados.
- Neste contexto, as **técnicas para agrupamento** de séries temporais assumem um papel de relevo.

Agrupamento de séries temporais

- Uma **questão fundamental** que surge sempre em qualquer processo de agrupamento de séries temporais é definir a noção de **semelhança** entre as séries.
- No contexto da classificação de séries temporais a definição de tal medida torna-se **particularmente complexa**, devido ao caráter dinâmico das séries.

Agrupamento de Séries Temporais



Agrupamento de séries temporais

Nos últimos anos têm sido propostas um conjunto alargado de medidas de similaridade para o agrupamento de séries temporais que, de grosso modo, podem ser agrupadas em **4 categorias**:

- baseadas em **modelos** (*model-based*);
- baseadas em **características** das séries (*feature-based*);
- baseadas em **previsões** (*future-information-based*);
- baseadas em medidas de **complexidade** (*complexity-based*).

Medidas baseadas em modelos

- O procedimento neste caso é ajustar primeiro um **modelo paramétrico** a cada uma das séries e representar cada uma delas através do correspondente **vetor de estimativas pontuais dos parâmetros** do modelo.
- A seguir constrói-se uma **medida de distância** entre o conjunto de vetores **dois a dois**.

Distância de Piccolo

Para processos AR(I)MA invertíveis, Piccolo (1990) introduziu a distância de Minkowski de segunda ordem em que os vetores de parâmetros contêm as estimativas pontuais dos parâmetros na sua representação AR:

Distância de Piccolo

Para processos AR(I)MA invertíveis, Piccolo (1990) introduziu a distância de Minkowski de segunda ordem em que os vetores de parâmetros contêm as estimativas pontuais dos parâmetros na sua representação AR:

- Um processo estacionário (X_t) admite uma representação ARMA(p, q), se X_t verificar

$$X_t = \psi_1 X_{t-1} + \cdots + \psi_p X_{t-p} + Z_t + \theta_1 Z_{t-1} + \cdots + \theta_q Z_{t-q},$$

onde $Z_t \sim WN(0, \sigma_Z^2)$ e $\psi_p \neq 0, \theta_q \neq 0$.

Distância de Piccolo

O processo (X_t) é invertível se verifica

$$Z_t = \sum_{j=0}^{\infty} \pi_j X_{t-j}, \quad \forall t.$$

Distância de Piccolo

O processo (X_t) é invertível se verifica

$$Z_t = \sum_{j=0}^{\infty} \pi_j X_{t-j}, \quad \forall t.$$

- **Distância de Piccolo:**

$$d^{Pic}(X_N, Y_N) := \sqrt{\sum_{i=1}^p (\pi_{i,X} - \pi_{i,Y})^2},$$

$p = \max(p_1, p_2)$, sendo $p_1, p_2 \in \mathbb{N}$ as ordens dos modelos ajustados às séries X_N e Y_N , na sua representação AR, e

Distância de Piccolo

- **Distância de Piccolo (cont):**

$$\pi_X = [\pi_{1,X} \ \pi_{2,X} \cdots \pi_{p_1,X}]'$$

e

$$\pi_Y = [\pi_{1,Y} \ \pi_{2,Y} \cdots \pi_{p_2,Y}]'$$

os correspondentes parâmetros associados a cada um dos modelos.

Note-se que $\pi_{i,X} = 0$ se $i > p_1$ e $\pi_{i,Y} = 0$ se $i > p_2$.

Distância de Maharaj

Maharaj (1996) considerou uma extensão da medida de Piccolo em que as distâncias entre os parâmetros dos modelos são ponderadas pelas matrizes de autocovariância, $W_X(p)$ e $W_Y(p)$, dos modelos autorregressivos ajustados às séries X_N e Y_N , e as correspondentes variâncias do ruído branco, $\sigma_{Z_X}^2$ e $\sigma_{Z_Y}^2$, associado a cada um dos modelos.

Distância de Maharaj

- **Distância de Maharaj:**

$$d^{Mah}(\mathbf{X}_N, \mathbf{Y}_N) := \sqrt{N}(\pi_X - \pi_Y)' W^{-1}(\pi_X - \pi_Y),$$

sendo

$$W = \sigma_{Z_X}^2 W_X^{-1}(p) + \sigma_{Z_Y}^2 W_Y^{-1}(p).$$

Medidas baseadas em características das séries

Galeano e Peña (2000) propuseram a seguinte versão ponderada da distância euclidiana para comparar funções de autocorrelação amostrais, considerando um desfasamento de h unidades, obtidas a partir de séries \mathbf{X}_N e \mathbf{Y}_N .

Distância de Galeano e Peña

- **Distância de Galeano e Peña:**

$$d^{ACF}(\mathbf{X}_N, \mathbf{Y}_N) := \sqrt{(\hat{\rho}_{\mathbf{X}} - \hat{\rho}_{\mathbf{Y}})' \Omega (\hat{\rho}_{\mathbf{X}} - \hat{\rho}_{\mathbf{Y}})},$$

sendo Ω uma qualquer matriz de pesos.

Distância de Galeano e Peña

- **Distância de Galeano e Peña (cont):**

Caiado et al. (2006) consideraram **três** definições para Ω :

- ser a matriz identidade. Neste caso a medida d^{ACF} torna-se na distância euclidiana.
- A segunda é considerar pesos com um decaimento geométrico sendo que, nesse caso, a medida d^{ACF} é dada pela expressão

$$\sqrt{\sum_{i=1}^h \alpha(1-\alpha)^i (\hat{\rho}_X(i) - \hat{\rho}_Y(i))^2}, \quad 0 < \alpha < 1.$$

Distância de Galeano e Peña


- **Distância de Galeano e Peña (cont):**


Caiado et al. (2006):

- a terceira proposta é usar a distância de Mahalanobis entre as autocorrelações, sendo o Ω a matriz de covariâncias amostrais dos coeficientes de autocorrelação com elementos dados pela fórmula de Bartlett truncada.

Importante

- Uma das **limitações** destas medidas é o facto de ter que se assumir que a estrutura de dependência do processo permanece **inalterada** ao longo do tempo.
- No entanto, em muito casos a **dinâmica** das séries temporais **muda** ao longo do tempo, seja por causa de mudanças de regime, por mudanças de forma ou por uma combinação das duas.
- Nestas situações torna-se possível que em determinados intervalos ao longo do tempo, uma série seja mais “**provável**” pertencer à uma determinada classe enquanto, noutras janelas temporais, seja mais “**provável**” pertencer a uma outra classe.





Distância de D'Urso e Maharaj

D'Urso e Maharaj (2009) propuseram o método A-FCM (*Autocorrelation-based Fuzzy C-Mean*). Este método assenta no cálculo dos pesos associados à atribuição das séries em cada uma das C classes definidas *a priori*. Este cálculo é feito a partir da minimização da função objetivo

$$\sum_{k=1}^K \sum_{c=1}^C u_{k,c}^m \sum_{r=1}^h (\hat{\rho}_{X_{(k)}}(r) - \hat{\rho}_c(r))^2,$$

Distância de D'Urso e Maharaj (cont)

$$\sum_{k=1}^K \sum_{c=1}^C u_{k,c}^m \sum_{r=1}^h (\hat{\rho}_{X_{(k)}}(r) - \hat{\rho}_c(r))^2, \quad (u_{k,c} > 0),$$

sujeita à restrição $\sum_{c=1}^C u_{k,c} = 1$, em que $u_{k,c}$ representa o grau de pertença da k -éssima série temporal na c -éssima classe, $m > 1$ controla o grau de imprecisão (*fuzziness*) da partição em C classes, $\hat{\rho}_{X_{(k)}}(r)$ é o valor estimado da função de autocorrelação da k -éssima série temporal e $\hat{\rho}_c(r)$ representa o valor estimado da ACF da série temporal representativa (*centroid time series*) da c -éssima classe.

Distância de Lafuente-Rego e Vilar (2016)

Uma maneira alternativa de agrupar séries temporais é comparar as suas **ACF's quantílicas**. A função de autocorrelação quantílica proporciona informação adicional sobre a estrutura de dependência entre as observações associadas a pares de quantis, para cada uma das séries e também entre séries.

Para um conjunto de quantis $q_{\tau_1}, q_{\tau_2}, \dots, q_{\tau_r}$, associados às ordens $0 < \tau_1 < \dots < \tau_r < 1$, definidas *a priori*, e um conjunto de desfasamentos $h_1 < \dots < h_L$, seja

$$d^{QCF}(\mathbf{X}_N, \mathbf{Y}_N) := \sum_{i=1}^L \sum_{j=1}^r \sum_{l=1}^r \left(\hat{\gamma}_{h_i}^{\mathbf{X}_N}(\tau_i, \tau_j) - \hat{\gamma}_{h_i}^{\mathbf{Y}_N}(\tau_i, \tau_l) \right)^2,$$

Distância de Lafuente-Rego e Vilar (2016) (cont)

com

$$\hat{\gamma}_I^Z(\tau, \tau') = \frac{1}{N-I} \sum_{t=1}^{N-I} I(Z_t \leq \hat{q}_\tau) I(Z_{t+I} \leq \hat{q}_{\tau'}) - \tau\tau',$$

sendo $I(\cdot)$ a função indicatriz e \hat{q}_τ e $\hat{q}_{\tau'}$ quantis empíricos.

Notar que $\hat{\gamma}_I^Z(\tau, \tau')$ é um estimador de

$$\gamma_I^Z(\tau, \tau') = \text{Cov}\{I(Z_t \leq q_\tau), I(Z_{t+I} \leq q_{\tau'})\} = P(Z_t \leq q_\tau, Z_{t+I} \leq q_{\tau'}) - \tau\tau'.$$

Medidas baseadas em características das séries

Quando o propósito da classificação é agrupar séries temporais consoante o seu **grau de dependência extremal conjunta**, o adequado é considerar medidas de similaridade que incorporem informação sobre a relação de interdependência nas caudas.

Distância de Durante et al., Luca e Zuccolotto

- **Durante et al. (2015) e De Luca e Zuccolotto (2011)** introduziram a medida

$$d^{TD}(\mathbf{X}_N, \mathbf{Y}_N) := -\log(\lambda_L),$$

sendo λ_L o coeficiente de dependência de cauda esquerda,

$$\lambda_L := \lim_{x \rightarrow 0^+} P(U_1 \leq x | U_2 \leq x) = \lim_{x \rightarrow 0^+} \frac{C(x, x)}{x},$$

em que $U_1 = F(X)$ e $U_2 = F(Y)$, e $C(\cdot)$ representa uma função cópula. A medida $d^{TD} \geq 0$, sendo que valores reduzidos implicam séries fortemente dependentes na cauda.

Distância de Durante et al., Luca e Zuccolotto

De Luca e Zuccolotto (2011) propuseram

$$C(x_1, x_2) = 1 - \left\{ 1 - [(1 - (1 - x_1)^\kappa)^{-\theta} + (1 - (1 - x_2)^\kappa)^{-\theta} - 1]^{-1/\theta} \right\}^{\frac{1}{\kappa}}.$$

Neste caso $\lambda_L = 2^{-1/\theta}$. De Luca e Zuccolotto (2015) consideraram uma extensão do modelo anterior em que θ varia no tempo em função de um conjunto de covariáveis. De referir que de forma perfeitamente análoga, é possível definir a medida d^{TD} considerando o coeficiente de dependência de cauda direita

$$\lambda_U := \lim_{x \rightarrow 1^-} P(U_1 > x | U_2 > x).$$

Distância de D'Urso e Maharaj

- **Distância de D'Urso e Maharaj (2012):**

D'Urso e Maharaj introduziram um método de agrupamento em que o afastamento entre pares de séries temporais é obtido através de uma **medida que pondera**, por um lado, a distância entre as variâncias de onduletas associadas a pares bivariados de séries temporais, para um conjunto de escalas definidas *a priori*; e uma outra equivalente para as correspondentes covariâncias de onduletas.

Distância de D'Urso e Maharaj

- **Distância de D'Urso e Maharaj (2012) (cont):**

A dita medida entre o i -éssimo e o j -éssimo par $\mathbf{Z}_i := (\mathbf{X}_{i,N}, \mathbf{Y}_{i,N})$ e $\mathbf{Z}_j := (\mathbf{X}_{j,N}, \mathbf{Y}_{j,N})$, é da forma

$$d^W(\mathbf{Z}_i, \mathbf{Z}_j) := \left\{ (a_{wv} \cdot d_{wv}(\mathbf{Z}_i, \mathbf{Z}_j))^2 + (a_{wc} \cdot d_{wc}(\mathbf{Z}_i, \mathbf{Z}_j))^2 \right\}^{\frac{1}{2}},$$

em que os pesos $a_{wv}, a_{wc} \geq 0$ ($a_{wv} + a_{wc} = 1$), e d_{wv} e d_{wc} correspondem às distâncias entre as variâncias e as co-variâncias de onduletas associadas, entre o i -éssimo e o j -éssimo par, sendo dadas pelas expressões

Distância de D'Urso e Maharaj

- Distância de D'Urso e Maharaj (2012) (cont):

$$d_{wv}(\mathbf{Z}_i, \mathbf{Z}_j) := \sum_{r=1}^R \| \text{diag}(\mathcal{C}_{\mathbf{Z}_i}(\nu_r)) - \text{diag}(\mathcal{C}_{\mathbf{Z}_j}(\nu_r)) \|,$$

$$d_{wc}(\mathbf{Z}_i, \mathbf{Z}_j) := \sum_{r=1}^R \| \gamma_{\mathbf{Z}_i}(\nu_r) - \gamma_{\mathbf{Z}_j}(\nu_r) \|,$$

onde R representa o número de escalas, \mathcal{C} é a matriz de variâncias/covariâncias de onduletas, sendo a componente da covariância representada pela função γ , no termo d_{wc} .

Medidas baseadas em previsões

Nos casos em que o objetivo do agrupamento relaciona-se com o desempenho das previsões futuras das séries temporais, torna-se necessário definir medidas de distância para **comparar densidades de previsão**.

Medidas baseadas em previsões



- **Distância de Alonso et al.:** com este objetivo, Alonso et al. (2006) introduziram a medida

$$d^F(\mathbf{X}_N, \mathbf{Y}_N) := \int (f_{\mathbf{X}_{N+h}}(x) - f_{\mathbf{Y}_{N+h}}(x))^2 dx,$$

sendo $f(\cdot)$ a função de densidade de previsão h passos à frente associada a um modelo autorregressivo de ordem p .




KYOTO PROTOCOL




Kyoto protocol

- The **objective** of the **Kyoto conference** was to establish a legally binding international agreement, whereby all the participating nations commit themselves to tackling the issue of **global warming** and **greenhouse gas emissions**;
- The target agreed upon was an average reduction of 5.2% from 1990 levels by the year 2012;
- Under the protocol, only the Annex I countries have committed themselves to national or joint reduction targets, that range from a joint reduction of 8% for the European Union and others, to 7% for the US (non-binding as the US is not a signatory), 6% for Japan and 0% for Russia.

Agrupamento de Séries Temporais



Agrupamento de Séries Temporais



Medidas baseadas em previsões

Quando o que está em causa é o agrupamento das séries em termos de **previsões de longo prazo** a partir, por exemplo, da comparação de distribuições de **valores de retorno** associadas a períodos de retorno definidos *a priori*, uma abordagem que entre em linha de conta com as propriedades extremais das séries torna-se mais adequada.

Medidas baseadas em previsões

- **Scotto et al. (2010)**: distância L_2 de Wasserstein ponderada

$$d^{EVT}(\mathbf{X}_N, \mathbf{Y}_N) := \left(\int_0^1 (F_{x_p}^{-1}(y|\mathbf{x}_N) - F_{y_p}^{-1}(y|\mathbf{y}_N))^2 y(1-y) dy \right)^{1/2},$$

em que F_{z_p} representa a distribuição preditiva *a posteriori* do valor de retorno z_p associado a um período de retorno de $1/p$ unidades de tempo.

Distâncias baseadas em subamostragem

- Alonso e Maharaj (2006): $X_N \sim P_X$ e $Y_N \sim P_Y$

Distâncias baseadas em subamostragem

- Alonso e Maharaj (2006): $X_N \sim P_X$ e $Y_N \sim P_Y$

Testar $\mathcal{H}_0 : P_X = P_Y$ vs $\mathcal{H}_1 : P_X \neq P_Y$

Distâncias baseadas em subamostragem

- Alonso e Maharaj (2006): $\mathbf{X}_N \sim P_{\mathbf{X}}$ e $\mathbf{Y}_N \sim P_{\mathbf{Y}}$

Testar $\mathcal{H}_0 : P_{\mathbf{X}} = P_{\mathbf{Y}}$ vs $\mathcal{H}_1 : P_{\mathbf{X}} \neq P_{\mathbf{Y}}$

Seja $T_{N,m} := N \sum_{k=1}^m (\hat{\rho}_{\mathbf{X}}(k) - \hat{\rho}_{\mathbf{Y}}(k))^2$

Distâncias baseadas em subamostragem:

- ① Seja $\mathbf{X}_j = (X_j, X_{j+1}, \dots, X_{j+l-1})$ e $\mathbf{Y}_j = (Y_j, Y_{j+1}, \dots, Y_{j+l-1})$ para $j = 1, 2, \dots, N-l+1$.
- ② Para cada subamostra calcular

$$T_{l,m}^{(j)} := l \sum_{k=1}^m (\hat{\rho}_{\mathbf{X}_j}(k) - \hat{\rho}_{\mathbf{Y}_j}(k))^2.$$

- ③ Estimar a distribuição de $T_{N,m}$

$$\hat{G}_{N,l}(x) = \frac{1}{N-l+1} \sum_{j=1}^{N-l+1} I(T_{l,m}^{(j)} \leq x).$$

- ④ O valor crítico do teste, $q_{1-\alpha}$, é

$$q_{1-\alpha} := \inf\{x : \hat{G}_{N,l}(x) \geq 1 - \alpha\}.$$

Information Systems 53 (2015) 16–38



Contents lists available at ScienceDirect

Information Systems

journal homepage: www.elsevier.com/locate/infosys




Time-series clustering – A decade review



Saeed Aghabozorgi, Ali Seyed Shirkhorshidi*, Teh Ying Wah

Department of Information System, Faculty of Computer Science and Information Technology, University of Malaya (UM),
50603 Kuala Lumpur, Malaysia



Thank you!

