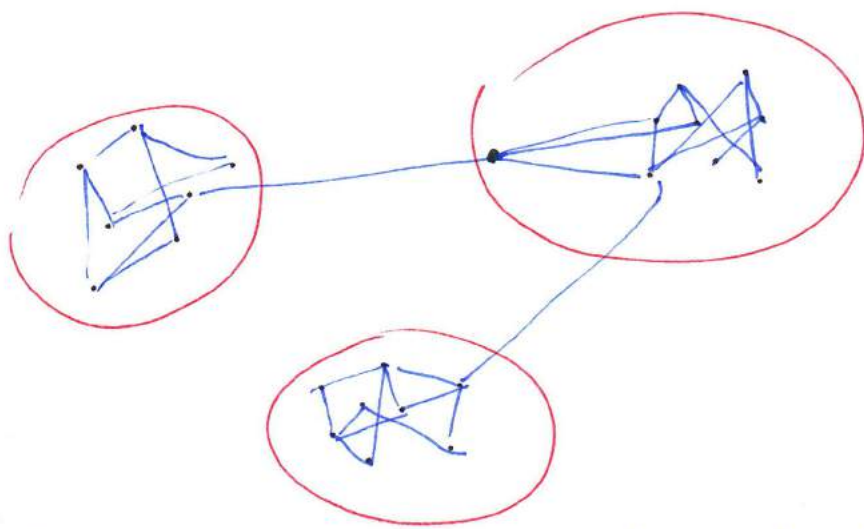
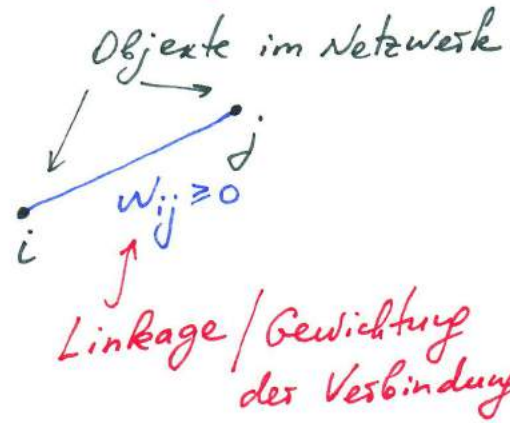


Clustering II



"Community Detection"




z.B. • Personen im sozialen Netzwerk

w_{ij} = Anzahl von Kontakten zwischen i und j

• Objekte mit einem Ähnlichkeitsmaß (Waren, Zeilen, Zeitreihen etc.)

$w_{ij} = S(i, j)$ $\xrightarrow{\text{similarity}}$ $\xrightarrow{\text{Anzahl von Merkmalen}}$




• Daten $x_i \in \mathbb{R}^p, i=1, \dots, n$

$$w_{ij} = K(d(x_i, x_j)) = e^{-\frac{\|x_i - x_j\|^2}{2 \cdot \sigma}} \quad \begin{matrix} x_i = x_j \Rightarrow w_{ij} = 1 \\ x_i \neq x_j \Rightarrow w_{ij} < 1 \end{matrix}$$

\uparrow Kernel $\quad \uparrow$ Dissimilarity $\quad \leftarrow$ Gauß-Kernel

$\xrightarrow{\kappa}$ κ -Clustering $(\kappa-1)$ Features ausreichend, aber p Merkmale vorhanden




Ansatz: Informationsverbreitung im Netzwerk

$\left[\begin{matrix} \text{Spectral} \\ \text{Clustering} \end{matrix} \right]$ Zwei Personen sind ähnlich, wenn sie in etwa den selben Informationszustand im Netzwerk über die längere Zeit auslösen

Informationsverbreitung

$W := (w_{ij}) \in \mathbb{R}^{n \times n}$ - symmetrische Gewichtungsmatrix

$D := \text{diag} \left(\underbrace{\sum_{i=1}^n w_{ij}}_{\text{Grad von } j = \text{Gesamtgewichtung von } j}, j=1, \dots, n \right)$



$P := W \cdot D^{-1} = \left(\frac{w_{ij}}{\sum_{i=1}^n w_{ij}} \right)$

↑ Übergangsmatrix

← Wahrscheinlichkeit des Übergangs von j nach i

$\Rightarrow e^T \cdot P = e^T, P \geq 0$

P - stochastische Matrix, d.h. Spaltensumme ist 1.

$x(0) = e_j = \begin{pmatrix} 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{pmatrix} \leftarrow j\text{-te Stelle}$

"Information wird von der Person j ausgelöst"

$x^j(t) = P \cdot x^j(t-1) = P^2 x^j(t-2) = \dots = P^t \cdot x^j(0) = P^t \cdot e_j$

Information zum Zeitpunkt t Information zum Zeitpunkt t-1

$\Rightarrow x^j(t) = P^t \cdot e_j$

↑ t-te Potenz von P

Informationen Zustand

Struktur von P^t :

• $S := D^{-1/2} \cdot W \cdot D^{-1/2}$ - symmetrisch $\Rightarrow S v_i = d_i \cdot v_i, i=1, \dots, n$

Also: $v_j^T \cdot S \cdot v_i = v_j^T \cdot d_i \cdot v_i = \begin{cases} d_i, & i=j \\ 0, & i \neq j \end{cases}$

$\Rightarrow V^T \cdot S \cdot V = \Lambda$

(= $\text{diag}(d_1, \dots, d_n)$)
o.B.d.A. monoton fallend sortiert

$\Rightarrow \boxed{S = V \cdot \Lambda \cdot V^T}$

Eigenvektoren sind paarweise orthogonal, d.h. $v_j^T \cdot v_i = \begin{cases} 1, & i=j \\ 0, & i \neq j \end{cases}$

Mit $V = (v_1, \dots, v_n)$ gilt:

- $V^T \cdot V = I \Rightarrow V^T \cdot V \cdot V^{-1} = V^{-1}$
- $V \cdot V^T = V \cdot V^{-1} = I$

• $P = W \cdot D^{-1} = D^{1/2} \cdot \underbrace{D^{-1/2} \cdot W \cdot D^{-1/2}}_S \cdot D^{-1/2} = \underbrace{D^{1/2} \cdot V}_\Phi \cdot \Lambda \cdot \underbrace{V^T \cdot D^{-1/2}}_\Psi$

$\Rightarrow \boxed{P = \Phi \cdot \Lambda \cdot \Psi}$

$\Phi_1 \dots \Phi_n$ Spalten
 $\Psi_1^T \dots \Psi_n^T$ Zeilen

und $\Psi \cdot \Phi = V^T \cdot D^{-1/2} \cdot D^{1/2} \cdot V = V^T \cdot V = I$

bi-orthonormale Matrizen, d.h. $\Psi_i^T \cdot \Phi_j = \begin{cases} 1, & i=j \\ 0, & i \neq j \end{cases}$

$$P^t = \underbrace{\Phi \cdot \Lambda \cdot \Psi}_{=I} \cdot \underbrace{\Phi \cdot \Lambda \cdot \Psi}_{=I} \cdot \dots \cdot \underbrace{\Phi \cdot \Lambda \cdot \Psi}_{=I} = \Phi \cdot \Lambda^t \cdot \Psi \quad (3)$$

$$\Rightarrow x^j(t) = P^t \cdot e_j = \Phi \cdot \Lambda^t \cdot \Psi \cdot e_j = \Phi \cdot \begin{pmatrix} \lambda_1^t & & 0 \\ & \ddots & \\ 0 & & \lambda_n^t \end{pmatrix} \cdot \begin{pmatrix} \psi_{1j} \\ \vdots \\ \psi_{nj} \end{pmatrix} = \Phi \cdot \begin{pmatrix} \lambda_1^t \psi_{1j} \\ \vdots \\ \lambda_n^t \psi_{nj} \end{pmatrix}$$

Insgesamt: $x^j(t) = \Phi \cdot F^j(t)$ j-te Spalte von Ψ $=: F^j(t)$ "Diffusion Map"

$$\| D^{-1/2} \cdot (x^j(t) - x^l(t)) \|^2 = \| D^{-1/2} \cdot \Phi \cdot (F^j(t) - F^l(t)) \|^2 =$$

↑
Gewichtung der Norm

Unterschied im Informationszustand ausgelöst durch j bzw. l

$z^T \cdot z = \|z\|^2$ - Euklidische Norm

$$= \| \underbrace{D^{-1/2} \cdot D^{1/2}}_{=I} \cdot \underbrace{V \cdot (F^j(t) - F^l(t))}_{=a} \|^2 = (V \cdot a)^T \cdot V \cdot a = a^T \cdot \underbrace{V^T \cdot V}_{=I} \cdot a =$$

$$= \|a\|^2 = \| F^j(t) - F^l(t) \|^2$$

"Diffusion Distance"

Reduktion der Dimension

Eigenwerte / Eigenvektoren

$$P \cdot \Phi_j = \Phi \cdot \Lambda \cdot \Psi \cdot \Phi_j = \Phi \cdot e_j \cdot \lambda_j = \lambda_j \cdot \Phi_j \quad j=1, \dots, n$$

λ_j Eigenwert von P
 Φ_j Eigenvektor von P

ii) $|\lambda_j| \leq 1$, insbesondere $\lambda_1 = 1$ und Φ_1 - Google-Ranking
"alle Eigenwerte einer stochastischen Matrix sind betragsmäßig kleiner als 1 oder gleich 1"

$$\Psi_i^T \cdot P = \underbrace{\Psi_i^T \cdot \Phi}_{e_i^T} \cdot \Lambda \cdot \Psi = e_i^T \cdot e_i \cdot \lambda_i = \lambda_i \cdot \Psi_i^T \Rightarrow \lambda_1 = 1 \text{ und } \Psi_1^T = e^T$$

$e^T \cdot P = e^T$

erste Komponente von $F^j(t)$ ist 1, also irrelevant:
 $\lambda_1^t \cdot \psi_{1j} = 1^t \cdot 1 = 1 \quad \forall j=1, \dots, n$

letzte Komponenten von $F^j(t)$ sind klein, also vernachlässigbar:
 $\lambda_k^t \cdot \psi_{kj} \rightarrow 0, \dots, \lambda_n^t \cdot \psi_{nj} \rightarrow 0$ für $t \rightarrow \infty$
 $\in (0,1)$ k-Clustering $\in (0,1)$ Langfristige Informationsverbreitung

Reduktion auf k - $F^t(t) = \begin{pmatrix} d_2^t \cdot \psi_{2j} \\ \vdots \\ d_k^t \cdot \psi_{kj} \end{pmatrix} \in \mathbb{R}^{k-1}$ (4)

↑
Anzahl von Features

↑
 k -Diffusion Map

Spectral Clustering

① Wähle t groß genug und konstruiere k -Diffusion Map:

$$\begin{array}{ccc} 1 & & n \\ \downarrow & \dots & \downarrow \\ k-F^1(t) & & k-F^n(t) \in \mathbb{R}^{k-1} \end{array}$$

② Wende auf n Datensätze in \mathbb{R}^{k-1} k -Means an.
(bzgl. der euklidischen Norm)
 \approx "Diffusion Distance"