

Föreläsning 12: linjär algebra för gymnasister

Förra gången: Markovkedjor.

Kom ihåg:

Def. Låt $\{X_1, X_2, \dots\}$ vara en sekvens av utfallsvektorer i \mathbb{R}^m . Om det finns en stokastisk matris A så att

$$X_{n+1} = A X_n$$

för alla $n \geq 1$ så kallas sekvensen för en Markovkedja.

Vi lärde oss även vad en stokastisk matris är. Detta bevisas även idag:

Def. En kvadratisk $(m \times m)$ -matris $A = (a_{ij})$

kallas stokastisk om

(i) alla element i A är icke negativa,
 $a_{ij} \geq 0 \quad \forall i, j = 1, \dots, m.$

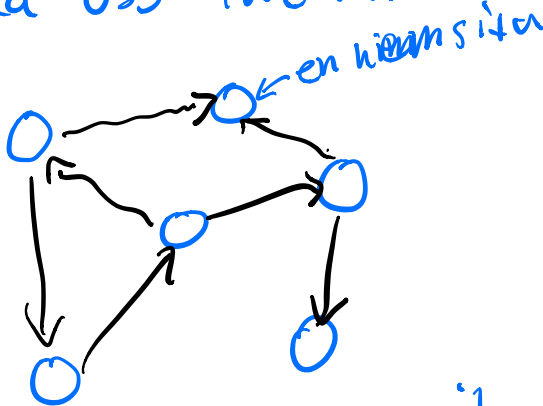
(ii) dvs kolumnsommorna är alla lika med ett,
$$\sum_{j=1}^m a_{ij} = 1 \quad \forall i=1, \dots, m.$$

IDAG: Google och Informationsöversökning

Sökmotor / Söktjänst

Mål: Reda ut vilka hemsidor som är mest relevanta för en given sökning.

Vi kan tänka oss internet som en graf.




Problem: ~ 10 miljarder hemsidor.

Vissa söktjänster söker igenom webben efter innehåll och skapar ett index med nyckelord för att underlätta för webbanvändaren.

(Ex: WebCrawler 1994, Brian Pinkerton)

Rangordnar hemsidorna 1, 2, 3, ... $\approx 10^{10}$ stycken




Olika sätt att rangordna på:

- 1) Antalet länkar på en sida.
- 2) Rangordna efter sidor som innehåller flest ord från sökningen.
- 3) Hur många länkar som en sida har till sig.

Problem: Algoritmer kan skapa hemsidor för att få fler länkar till sig.

Ex: två personer söker jobb inom IT.



PageRank:

Matematisk modell: Låt P_1, \dots, P_n beteckna hemsidor och låt $|P_j|$ vara antalet länkar från hemsida P_j .

Definition. **Rangen** till en hemsida P_i skriver vi som $r(P_i)$ och där

$$r(P_i) = \sum_{j \rightarrow i} \frac{r(P_j)}{|P_j|}$$


(Rekursiv def.).

Definition. **Länkmatrixen.** Låt P_1, \dots, P_n vara hemsidor. Länkmatrixen H är en $n \times n$ -matrix där

$$H_{ij} = \begin{cases} \frac{1}{|P_j|} & \text{om } j \rightarrow i \\ 0 & \text{annars.} \end{cases}$$

(i,j) i H

Exempel: Betrakta följande "internet"



$$\begin{cases} r(P_1) = \frac{r(P_2)}{3} + \frac{r(P_4)}{2} \\ r(P_2) = \frac{r(P_4)}{2} \\ r(P_3) = r(P_1) + \frac{r(P_2)}{3} \\ r(P_4) = \frac{r(P_3)}{3} + r(P_3) \end{cases}$$

(*)

och

$$H = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

Annotations: H_{21} (row 2, col 1), H_{31} (row 3, col 1), P_3 (row 3), P_4 (row 4), V_2 (row 2), V_3 (row 3), V_4 (row 4).

$$\underline{R = HR.}$$

Observera att (*) $\Leftrightarrow R = HR$ där $R = \begin{pmatrix} r(P_1) \\ r(P_2) \\ r(P_3) \\ r(P_4) \end{pmatrix}$

Definiera $R = \begin{pmatrix} r(P_1) \\ r(P_2) \\ r(P_3) \\ r(P_4) \end{pmatrix} > 0$ som rangeringsvektor.

och den bästa hemsidan är sidan $\arg \max_i \{r(P_i)\}$.

Finns det lösningar? För att garantera existensen av lösningar sätts

$$HX = \lambda \cdot X \leftarrow \begin{matrix} \text{eigenvektor} \\ \text{egen värde} \end{matrix}$$

där $X = (x_1, \dots, x_n)$.

Så, detta betyder att värdet (rangen) av en hemsida P_j antas vara

proportionell mot värdena som lämnas till P_j .

Proposition, låt X vara en vektor så att $HX = \lambda X$. Antag att elementen i $X = (x_1, \dots, x_n)$ inte summerar till noll dvs. $x_1 + x_2 + x_3 + \dots + x_n \neq 0$. Då är $\lambda = 1$ (ett egenvärde).

Bevis. Låt H vara lämnematrisen

$$H = \begin{pmatrix} h_{11} & h_{12} & \dots & h_{1n} \\ \vdots & \vdots & \ddots & \vdots \\ h_{n1} & h_{n2} & \dots & h_{nn} \end{pmatrix}.$$

Vi vet att H är stoiskeisk & y
 $h_{ij} \geq 0$ $\forall i, j$ men även $\sum_{j=1}^n h_{ij} = 1$

$$\begin{aligned} \sum_{j=1}^n h_{ij} &= \left| h_{ij} = \frac{1}{|P_j|} \right| \\ &= \sum_{k=1}^n \frac{|P_j|}{|P_j|} = \frac{|P_j|}{|P_j|} = 1. \end{aligned}$$

Vår equation: $H\bar{X} = z\bar{X}$

$$\Rightarrow \begin{pmatrix} h_{11} & \dots & h_{1n} \\ \vdots & \ddots & \vdots \\ h_{n1} & \dots & h_{nn} \end{pmatrix} \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} = z \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$$

H \bar{X} z \bar{X}

$$\Rightarrow \left(\begin{array}{c} \sum_{k=1}^n h_{1k} x_k \\ + \\ \sum_{k=1}^n h_{2k} x_k \\ \vdots \\ \sum_{k=1}^n h_{nk} x_k \end{array} \right) = z \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$$

Summera båda kolumnerna:

$$\sum_{j=1}^n \sum_{k=1}^n h_{jk} x_k = z \sum_{k=1}^n x_k$$

$$\sum_{k=1}^n \left[\sum_{j=1}^n h_{jk} \right] x_k = z \sum_{k=1}^n x_k$$

$$= \sum_{k=1}^n x_k = z \sum_{k=1}^n x_k$$

ÖVNING 2 Fixa felet i beviset $\lambda = 1$ ∇

Hur ser rangordningen ut för
"värt" internet? Lös

$$R = HR.$$

$$\Leftrightarrow (H - I)R = 0$$

$$R = \begin{pmatrix} x \\ y \\ z \\ w \end{pmatrix}$$

$$\Leftrightarrow \begin{pmatrix} 1 & 2/3 & 0 & -1/2 & | & 0 \\ 0 & 1 & 0 & -1/2 & | & 0 \\ -1 & -1/3 & 1 & 0 & | & 0 \\ 0 & -1/3 & -1 & 1 & | & 0 \end{pmatrix}$$

Gauss
 $\sim \dots \sim \Rightarrow \begin{cases} x = \frac{2}{3}t \\ y = \frac{1}{2}t \\ z = \frac{5}{6}t \\ w = t \end{cases}, \text{ där } t \in \mathbb{R}$

Så, summan av elementen i $R = 1$

$$S=1$$

$$\frac{2}{3}t + \frac{1}{2}t + \frac{5}{6}t + t = 1$$

$$\Leftrightarrow t = 1/3$$

$$\Rightarrow R = \begin{pmatrix} 2/9 \\ 1/6 \\ 5/18 \\ 1/3 \end{pmatrix} > 0.$$

∴ Hemsida P₄ rangordnas först.
Följs av P₃...