

Inside PageRank

Markov-Chain-Theory

Studienstiftung Salem 2008

29. August 2008

Das Random-
Surfer-Modell

Random Walk im
Internet

Markov Chains

Konvergenzverhalten

Konvergenz bei
Markov Chains
Matrixtheorie

Modifikation von H

Anpassung der
Hyperlinkmatrix

Das Random-Surfer-Modell

Random Walk im Internet
Markov Chains

Konvergenzverhalten

Konvergenz bei Markov Chains
Matrixtheorie

Modifikation von H

Anpassung der Hyperlinkmatrix

Das Random-
Surfer-Modell

Random Walk im
Internet
Markov Chains

Konvergenzverhalten

Konvergenz bei
Markov Chains
Matrixtheorie

Modifikation von H

Anpassung der
Hyperlinkmatrix

Modell

Ein Internetbenutzer bewegt sich zufällig durch das Internet entlang dessen Linkstruktur. Die Menge der Seiten wird mit $S = \{S_1, \dots, S_n\}$ bezeichnet. Die Wahrscheinlichkeiten h_{ij} , mit denen der Surfer dem Link von S_i nach S_j folgt, bilden die *Hyperlinkmatrix* H . In Sackgassen springt der Surfer willkürlich auf eine der Seiten aus S .

Stochastische Matrix

H ist stochastische Matrix, d.h. alle Zeilensummen sind gleich 1.

Spektralradius

Der Spektralradius einer stochastischen Matrix $\rho(H) = 1$.

Beweis:

$$\text{a) } \|H\|_{\infty} = 1; \|H\|_{\infty} \geq \rho(H)$$

$$\text{b) } Pe = e; 1 \leq \rho(H)$$

$$\Rightarrow 1 \leq \rho(H) \leq 1 \Rightarrow \rho(H) = 1$$

Das Random-
Surfer-Modell

Random Walk im
Internet

Markov Chains

Konvergenzverhalten

Konvergenz bei
Markov Chains
Matrixtheorie

Modifikation von H

Anpassung der
Hyperlinkmatrix

Definition

Unter einer Markov Chain versteht man einen stochastischen Prozess mit Zustandsraum $S = \{S_1, \dots, S_n\}$, der der Markov-Bedingung

$$P(X_{t+1} = S_j | X_t = S_{i_t}, X_{t-1} = S_{i_{t-1}}, \dots, X_0 = S_{i_0}) = P(X_{t+1} = S_j | X_t = S_{i_t})$$

genügt, wobei X_t den Zustand zum Zeitpunkt t repräsentiert (diskrete Zeit).

Das Modell des Random Surfers stellt eine stationäre Markov Chain dar, wobei H die Rolle der Übergangsmatrix zukommt.

Das Random-Surfer-Modell

Random Walk im Internet

Markov Chains

Konvergenzverhalten

Konvergenz bei Markov Chains
Matrixtheorie

Modifikation von H

Anpassung der Hyperlinkmatrix

Definition

Spaltenvektoren $p^T = (p_1, \dots, p_n)$, deren Spaltensumme gleich 1 ist, nennt man Wahrscheinlichkeitsvektoren.

Wahrscheinlichkeitsvektoren in Markov Chains

Zur Initialisierung der Markov Chain wählt man einen Wahrscheinlichkeitsvektor $p^T(0) = (p_1(0), \dots, p_n(0))$, der angibt, mit welcher Wahrscheinlichkeit der Random Surfer auf welcher Seite aus S beginnt. Der Wahrscheinlichkeitsverteilungsvektor $p^T(t) = (p_1(t), \dots, p_n(t))$ listet die Wahrscheinlichkeiten auf, dass der Random Surfer zum Zeitpunkt t auf einer bestimmten Seite ist.

Das Random-Surfer-Modell

Random Walk im Internet

Markov Chains

Konvergenzverhalten

Konvergenz bei Markov Chains
Matrixtheorie

Modifikation von H

Anpassung der Hyperlinkmatrix

Die Markov Chain in Aktion

Sei $\vec{p}^T(0) = (p_1(0), \dots, p_n(0))$ die Initialisierung einer Markov Chain mit Übergangsmatrix H . Wir berechnen die Wahrscheinlichkeit, dass der Surfer zum Zeitpunkt $t = 1$ auf der Seite S_j ist:

$$\begin{aligned} p_j(1) &= P(X_1 = S_j) \\ &= \sum_{i=1}^n P(X_1 = S_j \wedge X_0 = S_i) \\ &= \sum_{i=1}^n P(X_0 = S_i) P(X_1 = S_j | X_0 = S_i) \\ &= \sum_{i=1}^n p_i(0) h_{ij} \\ &\Rightarrow \vec{p}^T(1) = \vec{p}^T(0) H \\ &\Rightarrow \text{Allg. : } \vec{p}^T(t) = \vec{p}^T(0) H^t \end{aligned}$$

Was wollen wir?

Um ein Ranking zu erstellen, muss unsere Markov Chain gegen einen stationären Zustand konvergieren, der durch den Wahrscheinlichkeitsverteilungsvektor π beschrieben wird. Wir suchen deshalb nach Kriterien, die die Existenz dieses stationären Zustands garantieren und passen unsere Matrix entsprechend an.

Schön wäre: H primitiv, denn...

Das Random-Surfer-Modell

Random Walk im Internet
Markov Chains

Konvergenzverhalten

Konvergenz bei Markov Chains
Matrixtheorie

Modifikation von H

Anpassung der Hyperlinkmatrix

Satz:

Sei $A \in \mathbb{R}^{n \times n}$ stochastisch und primitiv. Dann existiert

$$\lim_{t \rightarrow \infty} p^T(0)A^t = \pi^T$$

und es gilt $\pi^T A = \pi^T$.

Die stationäre Wahrscheinlichkeitsverteilung π^T ist der eindeutige Eigenvektor zum Eigenwert 1.

Das Random-Surfer-Modell

Random Walk im Internet

Markov Chains

Konvergenzverhalten

Konvergenz bei Markov Chains
Matrixtheorie

Modifikation von H

Anpassung der Hyperlinkmatrix

Definition

Eine nichtnegative Matrix $A \in \mathbb{R}^{n \times n}$ heißt primitiv, wenn sie

- irreduzibel ist und
- nur einen einzigen Eigenwert auf dem Spektralradius besitzt.

Definition

Eine nichtnegative Matrix $A \in \mathbb{R}^{n \times n}$ heißt reduzibel, wenn es eine Permutationsmatrix P gibt, sodass

$$P^T A P = \begin{pmatrix} X & Y \\ 0 & Z \end{pmatrix}, \text{ wobei } X \text{ und } Z \text{ quadratisch sind.}$$

Sonst heißt sie irreduzibel.

Das Random-Surfer-Modell

Random Walk im Internet
Markov Chains

Konvergenzverhalten

Konvergenz bei Markov Chains
Matrixtheorie

Modifikation von H

Anpassung der Hyperlinkmatrix

Satz (Frobenius)

Eine nichtnegative Matrix $A \in \mathbb{R}^{n \times n}$ ist genau dann irreduzibel, wenn ihr gerichteter Graph stark verknüpft ist.

Satz (Perron)

Sei $A \in \mathbb{R}^{n \times n}$ positiv und $r = \rho(A)$. Dann gilt:
 r ist Eigenwert von A und r ist der einzige Eigenwert auf dem Spektralkreis von A .

Das Random-Surfer-Modell

Random Walk im Internet
Markov Chains

Konvergenzverhalten

Konvergenz bei Markov Chains
Matrixtheorie

Modifikation von H

Anpassung der Hyperlinkmatrix

Erster Gedanke

Überprüfen, ob H irreduzibel ist und nur einen Eigenvektor mit Betrag 1 besitzt. Aufwändig!

Besser: Störung von H

Modifikation von H zur Google-Matrix G durch

$$G = \alpha H + (1 - \alpha)ev^T,$$

wobei $\alpha \in (0, 1]$ und v Wahrscheinlichkeitsvektor.

Das Random-
Surfer-Modell

Random Walk im
Internet
Markov Chains

Konvergenzverhalten

Konvergenz bei
Markov Chains
Matrixtheorie

Modifikation von H

Anpassung der
Hyperlinkmatrix

Eigenschaften von G

- a) G ist stochastisch
 - b) Der Graph ist trivialerweise stark verknüpft und G damit irreduzibel (Frobenius)
 - b) G ist positiv und besitzt damit nur einen Eigenwert auf dem Spektralkreis (Perron)
- \Rightarrow Es existiert ein stationärer Zustand π^T mit $\pi^T G = \pi^T$.
Die Einträge von π^T entsprechen den Zeitanteilen, die der Random Surfer auf der jeweiligen Webseite verbracht hat.

Das Random-Surfer-Modell

Random Walk im Internet
Markov Chains

Konvergenzverhalten

Konvergenz bei Markov Chains
Matrixtheorie

Modifikation von H

Anpassung der Hyperlinkmatrix