

Kapitel 9: Markov-Ketten als Grundlage  
 der Funktionsweise von Suchmaschinen  
 im Internet

Situation:

Eingabe: eine Anfrage, bestehend aus  
 einem oder mehreren Stichworten

Ziel: Bestimme diejenigen Webseiten, deren Inhalt  
 hinsichtlich der Anfrage-Stichworte am  
 "informativsten" ist.

Probleme:

- Es gibt sehr viele Webseiten (in 2005: mehr als 8 Milliarden Stück)
- Ständig kommen neue hinzu
- Viele Webseiten werden (fast) täglich aktualisiert; viele werden nach einiger Zeit auch wieder gelöscht.
- Suchanfragen müssen in Echtzeit beantwortet werden
- Welches sind die "informativsten" Webseiten?

## 9.1 Die Architektur von Suchmaschinen

### Herausforderung:

Für einen sich rasant ändernden Suchraum gigantischer Größe müssen Anfragen ohne merkliche Reaktionszeit beantwortet werden.

Um dies zu gewährleisten, nutzen Suchmaschinen folgende Komponenten:

- Der Crawler durchforstet das Internet, um neue oder veränderte Webseiten zu bestimmen.
- Ab speichern der wichtigsten Informationen:  
Die vom Crawler gefundene Information muss aufbereitet und gespeichert werden
- Indizierung: Die Datenstruktur der gespeicherten Informationen muss in Echtzeit alle (relevanten) Webseiten bestimmen, die die Anfrage-Stichworte enthalten.

- Bewertung der Webseiten: Die ausgewählten Webseiten müssen im Hinblick auf ihren Informationsgehalt bewertet werden.

### Details zum Thema "Indizierung":

- Es werden alle Worte einer jeden Webseite erfasst.
- Fundamentale Datenstruktur: der invertierte Index, der zu jedem Stichwort  $s$  alle Webseiten bestimmt, die  $s$  enthalten. Oft liefert der invertierte Index noch Zusatzinformationen, die die Wichtigkeit des Stichworts innerhalb der Webseite beschreiben (etwa: Häufigkeit des Stichworts, seine Schnittgröße, das Vorkommen des Stichworts in Beschriftungen von Links auf die Webseite).

Insgesamt: Der invertierte Index ist Text-basiert.

- Eine weitere wichtige Datenstruktur: der Link-Index, mit dem die Graph-Struktur des Internets modelliert wird.

Ansatz: Jede Webseite wird durch einen Knoten repräsentiert.

Eine Kante von Knoten  $i$  zu Knoten  $j$  entspricht einem Link von Webseite  $i$  auf Webseite  $j$ .

Der Link-Index (oder: Webgraph) wird üblicherweise als Adjazenzliste gespeichert

### Details zum Thema "Bewertung der Webseiten":

- Ziel: Bestimme die für die gegebenen Anfrage-Stichworte informativsten Webseiten, d.h. sortiere die Webseiten, die die Anfrage-Stichworte enthalten, nach ihrer "Relevanz"

Dabei werden u.a. folgende Kriterien berücksichtigt:

- 1) Häufigkeit und Positionierung der Suchbegriffe auf der jeweiligen Webseite sowie in der Beschriftung von Links, die auf diese Webseite verweisen.
- 2) Die grundlegende Bedeutung einer Webseite.  
Bei Google wird dies durch den so genannten Page-Rank der Webseite modelliert.

Ein etwas anderer Ansatz zur Bewertung der grundlegenden Bedeutung einer Webseite ist der "Hubs and Authorities"-Ansatz von Kleinberg.

Beide Ansätze betrachten allein den Webgraphen (d.h. die Link-Struktur des Internets, nicht den textuellen Inhalt der Webseiten) und gehen von der folgenden Annahme aus:

- Wenn eine Webseite  $i$  einen Link auf Webseite  $j$  enthält, dann
- gibt es eine inhaltliche Beziehung zwischen beiden Webseiten und
  - der Autor der Webseite  $i$  hält die Informationen auf Webseite  $j$  für wertvoll.

Beide Ansätze versuchen, die "relative Wertschätzung" zwischen Webseiten in eine "absolute Relevanz" der Webseiten umzurechnen.

Im Rest von Kapitel 9 werden wir uns etwas genauer ansehen, wie die "absolute Relevanz" einer Webseite modelliert und berechnet werden kann.

## 9.2 Page-Rank, Zufalls-Surfer und Markov-Ketten 9.6

Sei  $G = (V, E)$  mit  $V = \{1, 2, \dots, n\}$  und  $E \subseteq V \times V$  der Webgraph.

D.h.: Knoten von  $G$  repräsentieren Webseiten, und jede Kante  $(i, j) \in E$  modelliert einen Link von Webseite  $i$  auf Webseite  $j$ .

Für jeden Knoten  $i \in V$  sei

$$a_i := \text{Aus-Grad}_G(i)$$

der Ausgangsgrad von  $i$  in  $G$ .

D.h.  $a_i$  ist die Anzahl der Hyperlinks, die von Webseite  $i$  auf andere Webseiten verweisen.

Die "grundlegende Bedeutung" einer Webseite  $i$  wird im Folgenden durch eine Zahl  $PR_i$  (den so genannten Page-Rank von  $i$ ) modelliert.

Der Wert  $PR_i$  soll die Qualität von Webseite  $i$  widerspiegeln (je höher, desto besser) und wird durch einen "Peer-Review" bestimmt:

- Der Page-Rank  $PR_j$  von Webseite  $j$  ist hoch, wenn viele Webseiten  $i$  mit hohem Page-Rank  $PR_i$  auf die Seite  $j$  verweisen.
- Eine Webseite  $i$  mit  $a_i$  ausgehenden Links "vererbt" ihren Page-Rank dabei anteilig an alle Webseiten  $j$  mit  $(i,j) \in E$  um den Anteil  $\frac{PR_i}{a_i}$  weiter.

In dieser Sichtweise müsste also f.a.  $j \in V$  gelten:

$$PR_j = \sum_{\substack{i \in V: \\ (i,j) \in E}} \frac{PR_i}{a_i} \quad (*)$$

Aus praktischen Gründen (mehr dazu: später) wird die Vererbung von  $PR_i$  auf die "Nachfolgeseiten"  $j$  mit  $(i,j) \in E$  meistens um einen "Dämpfungsfaktor"  $d$  (mit  $0 \leq d \leq 1$ ) abgeschwächt und die Werte werden so normiert, dass gilt:

$$PR_1, \dots, PR_n \geq 0 \quad \text{und} \quad \sum_{i \in V} PR_i = 1 \quad ;$$

## Definition 9.1 (Page-Rank)

9.8

Sei  $d$  eine reelle Zahl mit  $0 \leq d \leq 1$ ;

$d$  wird im Folgenden auch Dämpfungsfaktor genannt.

Sei  $G = (V, E)$  mit  $V = \{1, \dots, n\}$  und  $E \subseteq V \times V$  der Webgraph und sei f.a.  $i \in V$   $a_i := \text{AusGrad}_G(i)$ .

Ein Tupel  $PR = (PR_1, \dots, PR_n)$  von reellen Zahlen  $\geq 0$  hat die Page-Rank-Eigenschaft (bzgl. Dämpfungsfaktor  $d$ ),

wenn gilt:

(a)  $\sum_{i \in V} PR_i = 1$  und

(b) f.a.  $j \in V$  gilt:


$$PR_j = \frac{1-d}{n} + d \cdot \sum_{\substack{i \in V: \\ (i,j) \in E}} \frac{PR_i}{a_i} \quad (**)$$

(Beachte: Für  $d=1$  erhält man gerade die Gleichung  $(*)$ ;  
für  $d=0$  ist  $PR_1 = PR_2 = \dots = PR_n = \frac{1}{n}$ .)



Beispiel 9.2

Zur Veranschaulichung der Page-Rank-Eigenschaft betrachten wir den Dämpfungsfaktor  $d := \frac{1}{2}$  und den folgenden (sehr kleinen) Webgraphen, der aus nur drei Dokumenten besteht:



Wir suchen ein Tupel  $PR = (PR_1, PR_2, PR_3)$  von reellen Zahlen  $\geq 0$ , das die Page-Rank-Eigenschaft bzgl.  $d = \frac{1}{2}$  hat, d.h. es gilt:

$$0) \quad PR_1 + PR_2 + PR_3 = 1$$

$$1) \quad PR_1 = \frac{1}{2 \cdot 3} + \frac{1}{2} \cdot PR_3$$

$$2) \quad PR_2 = \frac{1}{6} + \frac{1}{2 \cdot 2} \cdot PR_1$$

$$3) \quad PR_3 = \frac{1}{6} + \frac{1}{2 \cdot 2} \cdot PR_1 + \frac{1}{2} \cdot PR_2$$

Eine Lösung dieses linearen Gleichungssystems (z.B. mittels Gauß-Elimination) liefert:

$$PR_1 = \frac{14}{39}, \quad PR_2 = \frac{10}{39}, \quad PR_3 = \frac{15}{39}.$$

Eine etwas andere Schreibweise der Bedingung (b) in Definition 9.1 zeigt, dass die Tupel  $PR = (PR_1, \dots, PR_n)$ , die die Page-Rank-Eigenschaft (bzgl  $d$ ) besitzen, gerade die Eigenvektoren zum Eigenwert 1 der folgenden Matrix

$$P = \left( P_{ij} \right)_{i,j=1,\dots,n} = \begin{pmatrix} P_{1,1} & \dots & P_{1,n} \\ \vdots & & \vdots \\ P_{n,1} & \dots & P_{n,n} \end{pmatrix}$$

sind: F.a.  $i, j \in \{1, \dots, n\}$  sei

$$P_{ij} := \begin{cases} \frac{1-d}{n} + \frac{d}{a_i} & , \text{ falls } (i,j) \in E \\ \frac{1-d}{n} & , \text{ falls } (i,j) \notin E \end{cases}$$

Beobachtung 9.3: Für jedes Tupel  $X = (X_1, \dots, X_n)$  von reellen Zahlen mit  $\sum_{i=1}^n X_i = 1$  gilt:

$$X \cdot P = \left( \frac{1-d}{n} + d \cdot \sum_{\substack{i \in V: \\ (i,j) \in E}} \frac{X_i}{a_i} \right)_{j=1,\dots,n}$$

Beweis:

$$X \cdot P = (x_1, \dots, x_n) \cdot \begin{pmatrix} p_{11} & \dots & p_{1n} \\ \vdots & & \vdots \\ p_{n1} & \dots & p_{nn} \end{pmatrix}$$

Die  $j$ -te Komponente von  $X \cdot P$  ist also:

$$\sum_{i=1}^n x_i \cdot p_{ij} \stackrel{\text{Def } p_{ij}}{=} \sum_{i=1}^n x_i \cdot \frac{1-d}{n} + \sum_{\substack{i \in V: \\ (i,j) \in E}} x_i \cdot \frac{d}{a_i}$$

$$= \frac{1-d}{n} \cdot \sum_{i=1}^n x_i + d \cdot \sum_{\substack{i \in V: \\ (i,j) \in E}} \frac{x_i}{a_i}$$

$$\stackrel{\sum_{i=1}^n x_i = 1}{=} \frac{1-d}{n} + d \cdot \sum_{\substack{i \in V \\ (i,j) \in E}} \frac{x_i}{a_i} \quad \square$$

Folgerung 9.4:

Ein Tupel  $PR = (PR_1, \dots, PR_n)$  von reellen Zahlen  $\geq 0$  hat genau dann die Page-Rank-Eigenschaft (bzgl  $d$ ), wenn gilt:

(a)  $\sum_{i=1}^n PR_i = 1$  und

(b)  $PR \cdot P = PR$ ,

d.h.  $PR$  ist ein Eigenvektor der Matrix  $P$ .

(bzw. eine Lösung des linearen Gleichungssystems  $PR \cdot ((\begin{smallmatrix} 1 & 0 \\ 0 & 1 \end{smallmatrix}) - P) = 0$

zum Eigenwert 1

Um den Page-Rank der einzelnen Webseiten zu berechnen, müssen wir also "nur" einen Eigenvektor zum Eigenwert 1 der Matrix  $P$  bestimmen

(z.B. durch Lösen des linearen Gleichungssystems

$$PR \cdot \left( \begin{pmatrix} 1 & & 0 \\ & \ddots & \\ 0 & & 1 \end{pmatrix} - P \right) = 0 \text{ ).}$$

### Probleme:

- Das ist sehr aufwändig, da der Webgraph sehr groß ist.
- Ist "der" Eigenvektor <sup>zum Eigenwert 1</sup> überhaupt eindeutig bestimmt? Muss es einen solchen geben? Kann es evtl. verschiedene solche Eigenvektoren von  $P$  geben?

Um diese Probleme zu bewältigen, hilft uns die Theorie der Markov-Ketten sowie die folgende Sichtweise auf die Matrix  $P$ :

## Der Zufalls-Surfer (Random-Surfer):

Ein Zufalls-Surfer beginnt auf einer beliebigen Webseite und verfolgt beliebige Links, ohne dabei auf Inhalte zu achten.

Der Eintrag  $P_{ij}$  in der Matrix  $P$  gibt dabei die Wahrscheinlichkeit an, mit der der Zufalls-Surfer in einem Schritt von Seite  $i$  zu Seite  $j$  wechselt. Die Wahl

$$P_{ij} = \begin{cases} \frac{1-d}{n} + \frac{d}{a_i} & , \text{ falls } (i,j) \in E \\ \frac{1-d}{n} & , \text{ falls } (i,j) \notin E \end{cases}$$

bedeutet dabei: Wenn der Zufalls-Surfer auf Webseite  $i$  ist, so wählt er

- mit Wahrscheinlichkeit  $d$  einen Link, der von Seite  $i$  ausgeht — und jeder der  $a_i$  ausgehenden Links wird mit derselben Wahrscheinlichkeit,  $\frac{d}{a_i}$ , ausgewählt
- mit Wahrscheinlichkeit  $(1-d)$  eine beliebige Webseite im Webgraphen — und jede der  $n$  Webseiten wird mit derselben Wahrscheinlichkeit,  $\frac{1-d}{n}$ , ausgewählt.

Beachte: Die Werte  $P_{ij}$  können wir tatsächlich als Wahrscheinlichkeiten interpretieren, da

gilt:  $P_{ij} \geq 0$  (f.a.  $i, j \in \{1, \dots, n\}$ ) und

f.a.  $i \in \{1, \dots, n\}$  gilt:  $\sum_{j=1}^n P_{ij} = 1$

(denn:  $\sum_{j=1}^n P_{ij} = \sum_{j=1}^n \frac{1-d}{n} + \sum_{\substack{j \in V: \\ (i,j) \in E}} \frac{d}{a_i} = (1-d) + a_i \cdot \frac{d}{a_i} = 1$ ).

Mit dieser Sichtweise auf die Matrix  $P$  gilt für den "modifizierten Webgraphen"  $G' = (V, E')$  mit  $V = \{1, \dots, n\}$  und  $E' = V \times V$ , dass  $(G', P)$  eine Markov-Kette im folgenden Sinn ist:

(Schreibweisen: Markov, Markow, Markoff)

## Definition 9.5 (Markov-Kette)

Eine Markov-Kette  $(\hat{G}, \hat{P})$  besteht aus einem gerichteten Graphen  $\hat{G} = (\hat{V}, \hat{E})$  mit

$\hat{V} = \{1, \dots, n\}$  (für ein geeignetes  $n \in \mathbb{N}$ ) und

einer Matrix

$$\hat{P} = (\hat{P}_{ij})_{i,j=1,\dots,n} = \begin{pmatrix} \hat{P}_{11} & \dots & \hat{P}_{1n} \\ \vdots & & \vdots \\ \hat{P}_{n1} & \dots & \hat{P}_{nn} \end{pmatrix}$$

so dass gilt:

(1) f.a.  $i, j \in \{1, \dots, n\}$  mit  $(i, j) \notin \hat{E}$  ist  $\hat{P}_{ij} = 0$

und

(2) für jede Zeile  $i \in \{1, \dots, n\}$  gilt:

$$\sum_{j=1}^n \hat{P}_{ij} = 1$$

Die Matrix  $\hat{P}$  heißt Übergangsmatrix.

Falls zusätzlich gilt:

(3) f.a.  $i, j \in \{1, \dots, n\}$  ist  $\hat{P}_{ij} \geq 0$ ,

so heißt  $\hat{P}$  auch stochastische Matrix.

Der Eintrag  $\hat{P}_{ij}$  kann dann als Wahrscheinlichkeit

aufgefasst werden, mit der ein  
 "Zufalls-Surfer im Graphen  $\hat{G}$ " in einem  
 Schritt von Knoten  $i$  zu Knoten  $j$  springt.

### Definition 9.6 (Stationäre Verteilung)

Sei  $(\hat{G}, \hat{P})$  eine Markov-Kette mit  $\hat{G} = (\hat{V}, \hat{E})$  und  
 $\hat{V} = \{1, \dots, m\}$ .

(a) Eine Verteilung auf  $\hat{V}$  ist ein Vektor  
 $x = (x_1, \dots, x_m)$  von reellen Zahlen  $\geq 0$  mit  

$$\sum_{i=1}^m x_i = 1.$$

( $x_i$  kann dabei als Wahrscheinlichkeit dafür  
 aufgefasst werden, dass der "Zufalls-Surfer auf  $\hat{G}$ "  
 sich zu Beginn auf Knoten  $i$  befindet).

(b) Eine Verteilung  $x$  auf  $\hat{V}$  heißt  
Stationäre Verteilung, falls gilt:  $x \cdot P = x$   
 (d.h.  $x$  ist ein Eigenvektor zum Eigenwert 1  
 von  $P$ ).



Beachte: Gemäß Folgerung 9.4 gilt für den "modifizierten Webgraphen  $G'$ " und die Matrix  $P$  folgendes:

Ein Tupel  $PR = (PR_1, \dots, PR_n)$  hat genau dann die Page-Rank-Eigenschaft (bzgl  $d$ ), wenn  $PR$  eine stationäre Verteilung (für die Markov-Kette  $(G', P)$ ) ist.

Die Theorie der Markov-Ketten wurde in der Literatur gut untersucht. Insbesondere ist ein nützliches Kriterium bekannt, das garantiert, dass eine stationäre Verteilung existiert, eindeutig bestimmt ist und sehr effizient näherungsweise berechnet werden kann: Dies ist bei so genannten ergodischen Markov-Ketten (siehe Definition 9.7) der Fall.

Notation:

Ist  $\hat{P}$  eine  $n \times n$ -Matrix und  $k \geq 1$  eine natürliche Zahl, so ist

$$\hat{P}^k := \underbrace{\hat{P} \cdot \dots \cdot \hat{P}}_{k\text{-mal}} \quad \text{die } n \times n\text{-Matrix, die aus}$$

dem Matrix-Produkt von  $k$  Kopien von  $\hat{P}$  entsteht.

Wenn  $\hat{P}$  eine stochastische Matrix ist, so können wir den Eintrag  $(\hat{P}^k)_{ij}$  in Zeile  $i$  und Spalte  $j$  der Matrix  $\hat{P}^k$  auffassen als die Wahrscheinlichkeit, dass der "Zufalls-Surfer auf  $\hat{G}$ " innerhalb von genau  $k$  Schritten von Knoten  $i$  zu Knoten  $j$  gelangt.

Definition 9.7 (Ergodische Markov-Ketten)

Eine Markov-Kette  $(\hat{G}, \hat{P})$  mit  $\hat{G} = (\hat{V}, \hat{E})$  und  $\hat{V} = \{1, \dots, n\}$  heißt ergodisch, wenn f.a.

$i_1, i_2 \in \{1, \dots, n\}$  und alle  $j \in \{1, \dots, n\}$  gilt:

Die Grenzwerte  $\lim_{k \rightarrow \infty} (\hat{P}^k)_{i_1 j}$  und  $\lim_{k \rightarrow \infty} (\hat{P}^k)_{i_2 j}$

existieren und es gilt:  $\lim_{k \rightarrow \infty} (\hat{P}^k)_{i_1 j} = \lim_{k \rightarrow \infty} (\hat{P}^k)_{i_2 j} > 0$ .

Beachte:

Ist  $(\hat{G}, \hat{P})$  ergodisch, so gilt:

1) Die Matrix

$$\hat{P}^\infty := \lim_{k \rightarrow \infty} (\hat{P}^k) := \left( \lim_{k \rightarrow \infty} (\hat{P}^k)_{ij} \right)_{i,j=1 \dots n}$$

ist wohldefiniert (da die Grenzwerte existieren),

und

2) alle Zeilen in  $\hat{P}^\infty$  sind identisch.

Notation:  $\pi^\infty := (\pi_1^\infty, \dots, \pi_n^\infty)$  sei die 1. Zeile von  $\hat{P}^\infty$ .

Somit ist  $\hat{P}^\infty = \begin{pmatrix} \pi_1^\infty \\ \vdots \\ \pi_n^\infty \end{pmatrix} = \begin{pmatrix} \pi_1^\infty & \dots & \pi_n^\infty \\ \pi_1^\infty & \dots & \pi_n^\infty \\ \vdots & & \vdots \\ \pi_1^\infty & \dots & \pi_n^\infty \end{pmatrix}$ , und

für jede Verteilung  $X = (X_1, \dots, X_n)$  gilt:  $X \cdot \hat{P}^\infty = \pi^\infty$ .

Daher gilt: Wenn der Zufalls-Surfer auf  $\hat{G}$

seinen Startknoten gemäß einer beliebigen

Anfangsverteilung  $X = (X_1, \dots, X_n)$  wählt und

hinreichend viele zufällige Schritte macht, so

ist die Wahrscheinlichkeit, bei Knoten  $j \in \hat{V}$  zu

landen, beliebig nah bei  $\pi_j^\infty$ .

Die Wahl des Anfangsknotens ist für einen hinreichend langen "Random Walk" also ohne Belang, und die "Grenzwertverteilung"  $\pi^\infty$  einer ergodischen Markov-Kette "vergisst" den Startpunkt eines "Random Walk".

Daher gilt folgender Satz:

### Satz 9.8

Jede ergodische Markov-Kette  $(\hat{G}, \hat{P})$  besitzt eine eindeutig bestimmte stationäre Verteilung  $\chi$ , und es gilt:  $\chi = \pi^\infty$ .

### Beobachtung 9.9:

Ist  $G'$  der "modifizierte Webgraph" und  $P$  die Übergangsmatrix für Dämpfungsfaktor  $d$  ( $0 \leq d \leq 1$ ),

so gilt:

- (a) Falls  $d < 1$ , so ist die Markov-Kette  $(G', P)$  ergodisch. (hier ohne Beweis), und gemäß Satz 9.8 ist  $\pi^\infty$  das eindeutig bestimmte Tupel, das die Page-Rank-Eigenschaft bzgl  $d$  hat.

(b) Falls  $d=1$  ist, so ist  $(G', P)$

nicht unbedingt ergodisch, denn der Zufalls-Surfer wird z.B. auf Webseiten, aus denen keine Hyperlinks heraus führen gefangen.

(Das ist der auf Seite 9.7 erwähnte "praktische Grund" wegen dem der Dämpfungsfaktor  $d$  eingeführt wurde).

### 9.3 Die effiziente Berechnung des Page-Rank

Wir wählen einen Dämpfungsfaktor  $d < 1$  und nutzen Beobachtung 9.9 (a).

Als Anfangsverteilung für den Zufalls-Surfer wählen wir die Gleichverteilung  $X^{(0)} := \underbrace{\left(\frac{1}{n}, \dots, \frac{1}{n}\right)}_{n\text{-mal}}$

Für  $k=1, 2, 3, \dots$  berechnen wir nach und nach die Vektoren  $X^{(k)} := X^{(k-1)} \cdot P$ .

Somit gilt f.ä.  $k \in \mathbb{N}$ :  $X^{(k)} = X^{(0)} \cdot P^k$ .

Da  $(G', P)$  ergodisch ist, wissen wir, dass

$PR := \pi^\infty$  das eindeutig bestimmte Tupel ist, das die Page-Rank-Eigenschaft bzgl.  $d$  hat.

Außerdem gilt: 
$$\pi^\infty = \lim_{k \rightarrow \infty} (x^{(0)} \cdot P^k) = \lim_{k \rightarrow \infty} (x^{(k)})$$

Für näherungsweise Berechnung von  $\pi^\infty$ .

beginnen wir mit  $x^{(0)} = (\frac{1}{n}, \dots, \frac{1}{n})$  und

berechnen nacheinander für  $k = 1, 2, 3, \dots$  den

Vektor  $x^{(k)} := x^{(k-1)} \cdot P$ .

Aufgrund des hohen Zusammenhangs des Webgraphen konvergiert die Folge  $(x^{(0)}, x^{(1)}, x^{(2)}, \dots)$  sehr schnell gegen  $\pi^\infty$ .

Für eine schnelle Berechnung des Vektor-Matrix-Produkts  $x^{(k)} := x^{(k-1)} \cdot P$  wird

ausgenutzt, dass  $P$  viele "identische" Einträge der Form  $\frac{1-d}{n}$

hat. Außerdem ist die Berechnung des

Vektor-Matrix-Produkts sehr gut parallelisierbar.

Derzeit werden mehrere Tausend PCs eingesetzt, die mehrere Stunden zur Berechnung des Page-Ranks benötigen.

(... was in Anbetracht der Tatsache, dass es mehrere Milliarden Webseiten gibt, erstaunlich gering ist).

Mehr zum Thema "Suchmaschinen" und "Markov-Ketten" können Sie in der Veranstaltung "Internet Algorithmen" bei Prof. Georg Schützer lernen!