

Markov-Ketten und Google's Page-Rank

- 1 Wir geben einen kurzen Überblick über die Arbeitsweise von **Suchmaschinen** für das Internet.
 - ▶ Eine Suchmaschine erwartet als Eingabe ein Stichwort oder eine Liste von Stichworten
 - ▶ und gibt als Ausgabe eine Liste von Links auf möglichst informative Webseiten zu diesen Stichworten. Die Liste soll so sortiert sein, dass
die informativsten Links am „weitesten oben“ stehen.
- 2 Gleichzeitig geben wir eine Einführung in
Markov-Ketten,
einem wichtigen Werkzeug in der Modellierung einfacher stochastischer Prozesse.

Die von Suchmaschinen zu bewältigenden Datenmengen sind immens! [Quelle](#)
(Zuletzt besucht am 09.12.2014.)

Danach gab es 2012

- 634 Millionen Websites,
wobei 51 Millionen in 2012 hinzugekommen sind,
- 3,5 Milliarden Webseiten,
- 2,4 Milliarden Internetnutzer weltweit
- und eine 1,2 Billionen, also 10^{12} Suchanfragen auf Google allein.

Und dann müssen Suchanfragen auch noch in „Echtzeit“ beantwortet werden.

Die zentrale Aufgabe:

Bewerte den Informationsgehalt der Webseiten

in Bezug auf die jeweilige Kombination der Suchbegriffe!

Die Architektur von Suchmaschinen

Suchmaschinen: Die wichtigsten Komponenten

Anfragen für einen sich rasant ändernden Suchraum gigantischer Größe sind ohne merkbare Reaktionszeit zu beantworten.

- (1) **Web-Crawler** durchforsten das Internet, um neue oder veränderte Webseiten zu identifizieren.
- (2) Die von den Crawlern gefundenen Informationen werden in einer komplexen **Datenstruktur** gespeichert, um bei Eingabe von Suchbegriffen in „Echtzeit“ alle relevanten Webseiten ermitteln zu können.
- (3) **Bewerte die Webseiten**

*hinsichtlich ihrer Relevanz für mögliche Suchbegriffe wie auch hinsichtlich ihrer **generellen** Bedeutung im Internet.*

Datenstrukturen für Suchmaschinen

Die Datenstruktur: Index und invertierter Index

1. Im **Index** werden alle vom Crawler gefundenen Webseiten w gespeichert:
 - ▶ URL (d.h. die Adresse) und Inhalt von w .
 - ▶ Der Inhalt von w wird analysiert: Alle vorkommenden Worte werden in Häufigkeit und Sichtbarkeit (Vorkommen in Überschriften, Schriftgröße etc.) erfasst.
 - ▶ Die auf w zeigenden Hyperlinks werden ebenfalls analysiert:
 - ★ Welche Begriffe tauchen in der Beschriftung des Links auf?
 - ★ Wie prominent ist der Link platziert?
2. Aus dem Index wird der **invertierte Index** erzeugt, der zu jedem möglichen Suchbegriff eine Liste aller Webseiten enthält, die den Suchbegriff enthalten.
 - ▶ Für jede in der Liste auftauchende Webseite w wird die Sichtbarkeit des Begriffs innerhalb von w und innerhalb der auf w zeigenden Seiten aufgeführt.
 - ▶ Mit diesen Zusatzinformationen und mit Hilfe ihrer

„grundsätzlichen“ Bedeutung

wird die Seite w in die Liste eingereiht.

- ★ Wie die Einreihung erfolgt, ist Betriebsgeheimnis der Suchmaschinenbetreiber.

Wie bestimmt man **die grundsätzliche Bedeutung einer Webseite?**

Der Page-Rank einer Webseite

Peer Review: Die grundsätzliche Bedeutung einer Webseite

Im Ansatz des „**Peer Review**“ wird die folgende Annahme gemacht:

Wenn eine Webseite i einen Link auf eine Webseite j enthält, dann

1. gibt es eine inhaltliche Beziehung zwischen beiden Webseiten, und
2. der Autor der Webseite i hält die Informationen auf Webseite j für wertvoll.

Der **Web-Graph**,

also die Link-Struktur des Internets

spielt im Peer-Review eine besondere Rolle. Zur Erinnerung:

- Die Webseiten sind Knoten und
- die Hyperlinks sind die gerichteten Kanten des Webgraphen.

Page-Rank: Notation

Um die „grundlegende Bedeutung“ einer Webseite zu messen, berücksichtigt der Page-Rank nur die Link-Struktur des Internets, nicht aber den Inhalt der Seite.

$W_{\text{EB}} = (V, E)$ bezeichne im Folgenden den Web-Graphen.

- Der Einfachheit halber nehmen wir an, dass die Webseiten mit den Zahlen $1, \dots, n$ durchnummeriert sind, und dass $V = \{1, 2, \dots, n\}$ gilt.
- Für jeden Knoten $i \in V$ ist

$$a_i := \text{Aus-Grad}_{W_{\text{EB}}}(i)$$

der Ausgangsgrad von i in W_{EB} , also die Anzahl der Hyperlinks, die von der Webseite i auf andere Webseiten verweisen.

- Für eine Webseite $j \in V$ schreiben wir $\text{Vor}_{W_{\text{EB}}}(j)$, um die Menge aller Webseiten zu bezeichnen, die einen Link auf j enthalten, d.h.

$$\text{Vor}_{W_{\text{EB}}}(j) = \{i \in V : (i, j) \in E\}.$$

Die Elemente in $\text{Vor}_{W_{\text{EB}}}(j)$ heißen (direkte) Vorgänger von j .

Page-Rank mittels Peer Review

Wir messen die „grundlegende Bedeutung“ einer Webseite i durch die Zahl

$$PR_i,$$

den Page-Rank von i .

*Der Wert PR_i soll das „Renommee“ der Webseite i widerspiegeln:
 PR_i soll umso größer sein, je höher das Renommee der Webseite i ist.*

Wann sollte PR_i groß sein?

Wenn genügend viele Webseiten mit großem Page-Rank auf i zeigen!

Wir fordern, dass eine Webseite i ihren Page-Rank an alle Webseiten j zu gleichen Teilen „vererbt“, auf die i zeigt.


$$PR_j = \sum_{i \in \text{Vor}_{\text{WEB}}(j)} \frac{PR_i}{a_i}.$$

Wir erhalten ein **Gleichungssystem**: Eine Gleichung für jeden Knoten j .

Schauen wir mal, was passiert

Senken, also Knoten vom Ausgangsgrad 0, vererben ihren Page-Rank nicht.
Ist das problematisch?

Betrachte den folgenden „Webgraphen“ $WEB = (V, E)$:



Die einzigen Page-Rank Werte, die die Gleichungen

$$PR_j = \sum_{i \in \text{Vor}_{WEB}(j)} \frac{PR_i}{a_i}.$$

erfüllen, sind $PR_1 = PR_2 = PR_3 = PR_4 = 0$ und diese Werte sollen die

„grundlegende Bedeutung“

der 4 Seiten widerspiegeln?

Das Entfernen von Senken

Um Senken loszuwerden:


1. Füge von jeder Senke Kanten zu *allen* Knoten hinzu oder
2. lösche rekursiv(!) alle Senken, bis ein Graph ohne Senken übrig bleibt.

Welche Transformation auch immer durchgeführt wird: Der Web-Graph wird durch einen gerichteten Graphen $WEB = (V, E)$ **ohne Senken** repräsentiert.

Haben wir das Problem gelöst?

Was passiert, wenn bestimmte Knoten nur unter sich verbunden sind, aber keine Kante zu einem anderen Knoten des Graphen WEB besitzen?

Betrachte den folgenden Graphen $WEB = (V, E)$:



Man kann sich leicht davon überzeugen, dass Page-Rank Werte die Gleichung

$$PR_j = \sum_{i \in \text{Vor}_{WEB}(j)} \frac{PR_i}{a_i}.$$

genau dann erfüllen, wenn $PR_1 = PR_2 = PR_3 = 0$ und $PR_4 = PR_5$ gilt.

Das darf doch wohl nicht wahr sein!

Gehört unser Ansatz „in die Tonne“
oder stimmt die Grundidee?

Woran liegt's?

(a) Der Ausweg?


- ▶ Füge Kanten von einer Webseite i zu **allen** anderen Webseiten ein,
- ▶ „**dämpfe**“ aber den Beitrag der neuen Seiten mit dem Faktor $1 - d$ für $0 \leq d \leq 1$.

(b) Ein Tupel $PR = (PR_1, \dots, PR_n) \in \mathbb{R}^n$ hat die **Page-Rank-Eigenschaft** bezüglich d , wenn für alle $j \in V$ gilt:

$$PR_j = \frac{1-d}{n} + d \cdot \sum_{i \in \text{Vor}_{\text{WEB}}(j)} \frac{PR_i}{a_i}.$$

Der neue Page-Rank: Ein Beispiel für $d = \frac{1}{2}$

Betrachte den folgenden Graphen $WEB = (V, E)$:



Wir suchen ein Tupel $PR = (PR_1, PR_2, PR_3)$ von reellen Zahlen mit der Page-Rank-Eigenschaft bezüglich $d = 1/2$:

- (1) $PR_1 = \frac{1}{2 \cdot 3} + \frac{1}{2} \cdot \frac{PR_3}{1}$,
- (2) $PR_2 = \frac{1}{2 \cdot 3} + \frac{1}{2} \cdot \frac{PR_1}{2}$
- (3) $PR_3 = \frac{1}{2 \cdot 3} + \frac{1}{2} \cdot \left(\frac{PR_1}{2} + \frac{PR_2}{1} \right)$.

Wir lösen das lineare Gleichungssystem und erhalten

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

Page-Rank: Die wichtigen Fragen

Wir müssen auch im Allgemeinen ein lineares Gleichungssystem lösen.

- (a) Ist das Gleichungssystem überhaupt lösbar und wenn ja, ist die Lösung eindeutig?
- (b) Und wie soll man, bitte schön, ein Gleichungssystem mit mehreren Milliarden Zeilen und Spalten lösen?
 - ▶ Unsere Rechner sind mittlerweile so mächtig: kein Problem mit Gaußscher Eliminierung!
 - ▶ **Denkste!** Ein Gleichungssystem dieser Dimension können wir auch mit allen Rechnern dieser Welt nicht knacken, wenn ...
...wir eine Gaußsche Eliminierung ausführen müssen.
- (c) Und selbst wenn es genau eine Lösung PR gibt und wir diese Lösung irgendwie bestimmen können:

Gibt PR_i das Renommee der Webseite i wieder?

Wir betrachten gleich einen rivalisieren Ansatz mit dem Page-Rank aus

Perspektive des Zufallssurfers.

Der Zufallssurfer

Ein Tupel $\pi \in \mathbb{R}^n$ heißt eine **Verteilung** (auf $\{1, \dots, n\}$), falls π die beiden folgenden Eigenschaften hat:

- $\pi_i \geq 0$ für alle $i \in \{1, \dots, n\}$ und
- $\sum_{i=1}^n \pi_i = 1$ gilt.

Wir benutzen Verteilungen, um **Irrfahrten** (engl: Random Walks) im Webgraphen $\text{WEB} = (V, E)$ zu beschreiben:

Dazu legen wir für jeden Knoten $k \in V$ eine Verteilung

$$(p_{i,1}, \dots, p_{i,n})$$

fest, so dass $p_{i,j}$ die Wahrscheinlichkeit ist, in einem Schritt von i zum Knoten j zu springen.

Mit welcher Wahrscheinlichkeit $p_{i,j}$ soll unser Surfer vom Knoten i auf den Knoten j springen?

Wenn der Zufallssurfer auf einer Webseite i ist, so wählt er

- die **Option „Webgraph“** mit Wahrscheinlichkeit d .
 - ▶ Daraufgehend wird einer der $a_i = \text{Aus-Grad}_{\text{WEB}}(i)$ ausgehenden Links mit Wahrscheinlichkeit $\frac{1}{a_i}$ ausgewürfelt.
- die **Option „wildes Hüpfen“** mit Wahrscheinlichkeit $(1 - d)$.
 - ▶ Daraufgehend wird eine der n Webseiten mit Wahrscheinlichkeit $\frac{1}{n}$ ausgewürfelt.

Setze

$$p_{i,j} = \begin{cases} \frac{1-d}{n} + d \cdot \frac{1}{a_i} & \text{falls } (i,j) \text{ eine Kante von WEB ist,} \\ \frac{1-d}{n} & \text{sonst.} \end{cases}$$

(d ist der Dämpfungsfaktor und $a_i = \text{Aus-Grad}_{\text{WEB}}(i)$.)

Die Übergangsmatrix

Die Übergangsmatrix $P_d(\text{WEB})$

wird definiert durch

$$P_d(\text{WEB}) := \begin{pmatrix} p_{1,1} & \cdots & p_{1,n} \\ \vdots & & \vdots \\ p_{n,1} & \cdots & p_{n,n} \end{pmatrix}$$

wobei

$$p_{i,j} = \begin{cases} \frac{1-d}{n} + d \cdot \frac{1}{a_i} & \text{falls } (i,j) \text{ eine Kante von WEB ist,} \\ \frac{1-d}{n} & \text{sonst.} \end{cases}$$

Für jedes $i \in \{1, \dots, n\}$ ist die i te Zeile

$$(p_{i,1}, \dots, p_{i,n})$$

tatsächlich eine Verteilung, denn

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

Eine $n \times n$ Matrix P heißt **stochastisch**, wenn

(1) $P_{i,j} \geq 0$ für alle $i, j \in \{1, \dots, n\}$ und


(2) für jede Zeile $i \in \{1, \dots, n\}$ gilt: $\sum_{j=1}^n P_{i,j} = 1$.

Die Matrix P ist also genau dann stochastisch, wenn jede Zeile eine Verteilung ist.

Die Matrix $P_d(\text{WEB})$ der Übergangswahrscheinlichkeiten ist also eine stochastische Matrix.

Die Übergangsmatrix

Für den Wert $d = \frac{1}{2}$ und den Graphen WEB



ist beispielsweise $P_{1/2}(\text{WEB})_{1,1} = \frac{1}{6}$,

$P_{1/2}(\text{WEB})_{1,2} = \frac{1}{6} + \frac{1}{4} = \frac{5}{12} = P_{1/2}(\text{WEB})_{1,3}$ und $P_{1/2}(\text{WEB})_{2,3} = \frac{1}{6} + \frac{1}{2} = \frac{2}{3}$.

Die vollständige Übergangsmatrix ist

$$P_{1/2}(\text{WEB}) = \begin{pmatrix} \frac{1}{6} & \frac{5}{12} & \frac{5}{12} \\ \frac{1}{6} & \frac{1}{6} & \frac{2}{3} \\ \frac{2}{3} & \frac{1}{6} & \frac{1}{6} \end{pmatrix}.$$

Zusammenfassung: Wie misst man Renommee?

- ① Der Peer-Review Ansatz: Ein Tupel $PR = (PR_1, \dots, PR_n) \in \mathbb{R}^n$ hat die **Page-Rank-Eigenschaft** bezüglich d , wenn für alle $j \in V$ gilt:

$$PR_j = \frac{1-d}{n} + d \cdot \sum_{i \in \text{Vor}_{\text{WEB}}(j)} \frac{PR_i}{a_i}.$$

- ② Der **Zufallssurfer** führt eine zufällige **Irrfahrt** durch: Er springt mit Wahrscheinlichkeit $p_{i,j}$ von der Webseite i zur Webseite j , wobei

$$p_{i,j} = \begin{cases} \frac{1-d}{n} + d \cdot \frac{1}{a_i} & \text{falls } (i,j) \text{ eine Kante von WEB ist,} \\ \frac{1-d}{n} & \text{sonst.} \end{cases}$$

Als Konkurrenz zum Page-Rank PR:

PR_j^* = die relative Häufigkeit mit der Seite j in einer unendlich langen Irrfahrt besucht wird.

- ③ $P_d(\text{WEB}) := \begin{pmatrix} p_{1,1} & \cdots & p_{1,n} \\ \vdots & & \vdots \\ p_{n,1} & \cdots & p_{n,n} \end{pmatrix}$ heißt Übergangsmatrix des Zufallssurfers.

Markov-Ketten, das mathematische Modell für Irrfahrten

Der Zufallssurfer traversiert den Webgraphen durch eine Irrfahrt.
Was müssen wir über Irrfahrten wissen? Den Graphen und die Übergangsmatrix.

$G = (V, E)$ sei ein gerichteter Graph mit Knotenmenge $V = \{1, \dots, n\}$.
Die (homogene) **Markov-Kette** \mathcal{M} wird beschrieben durch das Paar

$$\mathcal{M} := (G, P)$$

mit dem Graphen G und der Übergangsmatrix P .

- (a) G hat keine Senke, d.h. $\text{Aus-Grad}_G(v) > 0$ gilt für alle Knoten v von G .
- (b) Die Matrix P ist eine stochastische Matrix mit n Zeilen und n Spalten.
Es ist $P_{i,j} = 0$ genau dann, wenn (i, j) keine Kante in G ist.

Die Knoten von G nennt man häufig auch **Zustände**.

Wie stellt man eine Markov-Kette grafisch dar? Siehe Tafel

Die von einer Markov-Kette erzeugte Irrfahrt

Sei $\mathcal{M} = (G, P)$ eine Markov-Kette mit dem Graphen $G = (V, E)$ und π eine auf V definierte Wahrscheinlichkeitsverteilung.

\mathcal{M} beginne mit Wahrscheinlichkeit π_i im Zustand $i \in V$.

Welche Irrfahrt wird von \mathcal{M} erzeugt?

1. $X_k(\pi)$ bezeichne den von \mathcal{M} nach k Schritten erreichten Zustand.
 - ▶ Es gilt $X_0(\pi) = i$ mit Wahrscheinlichkeit π_i .
 - ▶ $X_k(\pi)$ ist eine Zufallsvariable.
2. Die Kette $\mathcal{M} = (G, P)$ erzeugt eine unendlich lange Irrfahrt in G , beschrieben durch die unendliche Folge

$$X_0(\pi), X_1(\pi), X_2(\pi), \dots, X_k(\pi), \dots$$

- ▶ **Wichtige Eigenschaft:** Der zu jedem Zeitpunkt $k > 0$ angenommene Zustand $X_k(\pi)$ hängt nur vom Vorgänger-Zustand $X_{k-1}(\pi)$ ab.

Markov-Ketten: Was möchte man gerne wissen?

Markov-Ketten: Alter und neuer Page-Rank

Der vollständige, gerichtete Graph $\vec{K}_n = (\mathbf{V}, \mathbf{E}_n)$ besitzt Knotenmenge $V = \{1, \dots, n\}$ und Kantenmenge $E_n = \{(u, v) : u, v \in \{1, \dots, n\}\}$.

Sei WEB der Webgraph. Die **Webkette** \mathcal{W} wird beschrieben durch das Paar

$$\mathcal{W} := (\vec{K}_n, P_d(\text{WEB})).$$

Die Webkette muss uns helfen, den alten und neuen Page-Rank zu verstehen!

Was möchte man gerne wissen?

- ? Wie hängen PR und PR*, also alter und neuer Page-Rank zusammen?
 - ▶ Existiert der alte Page-Rank überhaupt?
 - ▶ Hängt der neue Page-Rank von der Startverteilung des Zufallssurfers ab?
- ? Lässt sich der alte, bzw. der neue Page-Rank effizient berechnen?

Markov-Ketten: Irrfahrten auf ungerichteten Graphen (1/2)

Viele Mähroboter, die ohne GPS-Ortung arbeiten, mähen den Rasen nach dem Zufallsprinzip.

- Der Roboter fährt gerade Strecken über den Rasen und wendet dann am Rand zufällig in einem von endlich vielen Winkeln.
- Wird tatsächlich jede Stelle des Rasens hochwahrscheinlich gemäht?

(a) Sei $G = (V, E)$ ein ungerichteter, zusammenhängender Graph $G = (V, E)$.

- ▶ Sei d_v die Anzahl der Nachbarn von v .
- ▶ Hat die Irrfahrt den Knoten v erreicht, dann wird die Irrfahrt mit Wahrscheinlichkeit $1/d_v$ mit einem Nachbarn v_i ($1 \leq i \leq d_v$) fortgesetzt.

(b) Die Markov-Kette (G', P) dieser Irrfahrt besitzt den Graphen $G' = (V, E')$,

- ▶ wobei G und G' dieselbe Knotenmenge V besitzen
- ▶ und eine **gerichtete** Kante (i, j) genau dann in G' vorkommt, wenn $\{i, j\}$ eine (**ungerichtete**) Kante von G ist,

sowie die Übergangsmatrix P mit

$$P_{i,j} := \begin{cases} \frac{1}{d_i} & \text{falls } \{i, j\} \text{ eine Kante von } G \text{ ist,} \\ 0 & \text{sonst.} \end{cases}$$

Was möchte man gerne wissen?

- (?) Ab welcher Länge besucht eine Irrfahrt wahrscheinlich alle Knoten von G ?
- ▶ Die erwartete Länge einer Irrfahrt, die alle Knoten des Graphen $G = (V, E)$ besucht, ist höchstens $2|V| \cdot |E|$. (Siehe Vorlesung „Effiziente Algorithmen“.)
Man sagt auch, dass die „Cover-Time“ des Graphen durch $2|V| \cdot |E|$ beschränkt ist.
 - ▶ Für reguläre Graphen, also für Graphen in denen jeder Knoten dieselbe Anzahl von Nachbarn besitzt, beträgt die Cover-Time höchstens $4 \cdot |V|^2$.
- (?) Was ist die relative Häufigkeit mit der ein Knoten $i \in V$ in einer genügend langen Irrfahrt besucht wird?
- ▶ Antwort später.


Ein Spieler tritt gegen das Casino an:

Bei einem Einsatz von 1 € ist der Gewinn/Verlust in jeder Runde ebenfalls 1 €.

Der Spieler hat ein Kapital von K €, das Casino von N €.

Die **Markov-Kette**:

- Wir verwenden die Zustände $0, \dots, M$ mit $M = K + N$
- und erlauben Übergänge vom Zustand $0 < i < n$ zu den Zuständen $i - 1$ und $i + 1$ mit der Wahrscheinlichkeit von jeweils $1/2$.
 - Die Kette beginnt im Zustand K .
 - Im Zustand 0 ist der **Spieler ruiniert**, im Zustand M das **Casino gesprengt**: Die Kette verbleibt in jedem der beiden Zustände mit Wahrscheinlichkeit 1.



Was möchte man gerne wissen?

- ? Wie groß ist die Wahrscheinlichkeit s_K , dass der Spieler die Bank sprengt, wenn Casino und Spieler bis zum bitteren Ende spielen?
 - ▶ Es ist $s_K = K/M$.
 - ▶ Gute Chancen, die Bank zu sprengen, selbst wenn K sehr viel kleiner als N ist!
- ? Leider(?) sind in professionellen Casinos alle Spiele unfair.
 - ▶ $p < 1/2$ ist die Gewinnwahrscheinlichkeit des Spieler und $q := 1 - p$ die Komplementärwahrscheinlichkeit.
 - ▶ Es kann gezeigt werden:

$$s_K = \frac{\left(\frac{q}{p}\right)^K - 1}{\left(\frac{q}{p}\right)^M - 1} \leq \frac{\left(\frac{q}{p}\right)^K}{\left(\frac{q}{p}\right)^M} = \left(\frac{q}{p}\right)^{-N}.$$

Die Erfolgswahrscheinlichkeit s_K für den Spieler fällt **exponentiell** mit N :
Für die meisten Glücksspiele ist eine Teilnahme nicht besonders clever!


Zwei Substanzen sind durch eine Membran getrennt, aber Moleküle wandern über die Membran zwischen den beiden Substanzen.

Modellierung: In jedem Schritt wird eines der N Partikel gleichverteilt, also mit Wahrscheinlichkeit $1/N$ ausgewählt und auf die jeweils andere Seite verschoben.

Unsere **Markov-Kette** (G, P) besitzt den Graphen $G = (V, E)$ mit

- Knotenmenge $V = \{0, 1, \dots, N\}$
- und den Kanten $i \rightarrow i + 1$ und $i \rightarrow i - 1$ für $i = 1, \dots, N - 1$ sowie den Kanten $0 \rightarrow 1, N \rightarrow N - 1$

und die Übergangsmatrix P mit $P_{i,j} := \begin{cases} \frac{i}{N} & \text{falls } j = i - 1, \\ 1 - \frac{i}{N} & \text{falls } j = i + 1, \\ 0 & \text{sonst.} \end{cases}$



Was möchte man gerne wissen?

Angenommen, wir lassen Partikel „hinreichend oft“ wandern:


Mit welcher Wahrscheinlichkeit besitzt die linke Seite genau ℓ Partikel?

Wir werden diese Frage später beantworten.

Markov-Ketten: Warteschlangen

Wir modellieren die **Warteschlange** vor einer Supermarktkasse:

- Die **unendliche** Menge $V = \mathbb{N}$ ist Zustandsmenge:
Im Zustand $i \in V$ warten i Kunden an der Kasse.
- Pro Zeitschritt bezahlt (höchstens) ein Kunde, neue Kunden treffen ein.
Z.B. treffen k neue Kunden mit Wahrscheinlichkeit 2^{-k-1} ein.



Was möchte man wissen? Was ist die erwartete Länge der Warteschlange?

Ein Schritt einer Markov-Kette, Das Vektor-Matrix Produkt

Vektor-Matrix und Matrizenprodukt

(a) Um das **Vektor-Matrix Produkt**

$$y = x^T \cdot A$$

für eine $n \times m$ Matrix A reeller Zahlen und ein Tupel $x \in \mathbb{R}^n$ zu berechnen:

- ▶ interpretiere x als Zeilenvektor, den man dann nacheinander mit allen Spalten von A multiplizieren muss, also

$$y_i = \sum_{\ell=1}^n x_{\ell} \cdot a_{\ell,i}.$$

(b) Um das **Matrizenprodukt**

$$C = A \cdot B$$

für eine $n \times m$ Matrix A und eine $m \times r$ Matrix B zu berechnen:

- ▶ Multipliziere die i te Zeile von A mit der j ten Spalte von B (für $i \in \{1, \dots, n\}$ und $j \in \{1, \dots, r\}$), also

$$c_{i,j} = \sum_{\ell=1}^m a_{i,\ell} \cdot b_{\ell,j}.$$

Wieso reden wir plötzlich über das Vektor-Matrix Produkt?

Sei (G, P) eine Markov-Kette. Wenn wir mit Wahrscheinlichkeit π_i im Knoten i starten, dann sind wir nach einem Schritt im Knoten j mit Wahrscheinlichkeit

$$\sum_{i=1}^n \pi_i \cdot P_{i,j} \stackrel{\text{toll!}}{=} (\pi \cdot P)_j.$$

(Wir interpretieren Verteilungen als Zeilenvektoren.) Die Kette,

wenn in Verteilung π gestartet,

befindet sich nach einem Schritt **in der Verteilung**

$$\pi \cdot P,$$

D.h. $(\pi \cdot P)_j$ ist die Wahrscheinlichkeit, den Zustand j in einem Schritt zu erreichen.

Und wenn wir die Markov-Kette k Schritte lang beobachten?

- (a) **Rekursionsanfang:** Die Kette befindet sich in der Verteilung $\pi^{(0)} := \pi$,
- (b) **Rekursionsschritt:** Wenn sich die Kette nach k Schritten in der Verteilung $\pi^{(k)}$ befindet, dann befindet sie sich nach $k + 1$ Schritten in der Verteilung

$$\pi^{(k+1)} := \pi^{(k)} \cdot P.$$

Mit vollständiger Induktion nach k :

Nach k Schritten befindet sich die Kette in der Verteilung

$$\pi^{(k)} = \pi \cdot P^k,$$

wenn wir in der Verteilung π beginnen.

Was ist die „Grenzverteilung“? Existiert der Grenzwert $\lim_{k \rightarrow \infty} \pi \cdot P^k$?

Zusammenfassung: Was ist bisher passiert?

- (a) Wie definiert man das **Renommee einer Webseite** w ?
- ▶ Mit PR_w , falls das Tupel PR die **Page-Rank-Eigenschaft** besitzt oder
 - ▶ mit der Wahrscheinlichkeit PR_w^* mit der der **Zufallssurfer** die Seite w besucht?
- (b) Der Zufallssurfer unternimmt eine **Irrfahrt**. Mit einer Markov-Kette $\mathcal{M} = (G, P)$ können wir Irrfahrten im gerichteten Graphen G untersuchen.
- ▶ Wenn (i, j) eine Kante von G ist, dann läuft die Irrfahrt in einem Schritt von Zustand i nach Zustand j mit Wahrscheinlichkeit $P_{i,j}$.
- (c) Irrfahrten und das **Vektor-Matrix-Produkt**:
- Wenn sich die Kette $\mathcal{M} = (G, P)$ anfänglich in der Verteilung π befindet,
- ▶ (d.h. Zustand i wird mit Wahrscheinlichkeit π_i besucht)
- dann befindet sie sich nach k Schritten im Zustand $\pi \cdot P^k$.
- ▶ (d.h. Zustand i wird mit Wahrscheinlichkeit $(\pi \cdot P^k)_i$ besucht)

Ergodische Ketten: Schöne Markov-Ketten

Die Grenzverteilung einer Markov-Kette

$\mathcal{M} = (G, P)$ sei eine Markov-Kette. Die Verteilung

$$\mathcal{G}(\mathcal{M})$$

heißt **Grenzverteilung der Kette**, wenn für **alle** Anfangsverteilungen π gilt:

$$\lim_{k \rightarrow \infty} \pi \cdot P^k = \mathcal{G}(\mathcal{M}).$$

Sei $\mathcal{W} := (\vec{K}_n, P_d(\text{WEB}))$ die Webkette. Was ist $\lim_{k \rightarrow \infty} \pi \cdot (P_d(\text{WEB}))^k$?

- (a) Die Webkette befindet sich anfänglich in der Verteilung $\pi \implies$ der Zufallssurfer beginnt mit Wahrscheinlichkeit π_i auf der Webseite i .
- (b) Nach k Schritten hat der Zufallssurfer Seite j mit W.k. $(\pi \cdot (P_d(\text{WEB}))^k)_j$ erreicht: Die Kette befindet sich nach k Schritten in Verteilung $\pi \cdot (P_d(\text{WEB}))^k$.

Und **wenn** die Webkette eine Grenzverteilung besitzt, dann ist

$$\mathcal{G}(\mathcal{W}) = \lim_{k \rightarrow \infty} \pi \cdot (P_d(\text{WEB}))^k \stackrel{\text{TOLL!}}{=} \text{PR}^*.$$

Sachte, sachte,
existiert die Grenzverteilung überhaupt?

Wenn wir träumen dürften,

Wenn $\mathcal{M} = (G, P)$ eine **schöne** Markov-Kette ist,

(a) dann existiert die „**Grenzmatrix**“ $P^\infty := \lim_{k \rightarrow \infty} P^k$ und

(b) die Irrfahrt vergisst ihren Startpunkt: Für alle i, i^*, j gilt

$$(P^\infty)_{i,j} = \lim_{k \rightarrow \infty} (P^k)_{i,j} = \lim_{k \rightarrow \infty} (P^k)_{i^*,j} = (P^\infty)_{i^*,j}.$$

Also sind alle Zeilen von P^∞ identisch.

Wenn \mathcal{M} schön ist, dann existieren Grenzwerte und alle Zeilen der Grenzmatrix P^∞ stimmen mit der ersten Zeile

$$z = ((P^\infty)_{1,j} : 1 \leq j \leq n) = ((\lim_{k \rightarrow \infty} P^k)_{1,j} : 1 \leq j \leq n)$$

überein. Also gilt $\lim_{k \rightarrow \infty} \pi \cdot P^k \stackrel{!}{=} \pi \cdot \lim_{k \rightarrow \infty} P^k = \pi \cdot P^\infty = \pi \cdot \begin{pmatrix} z \\ \vdots \\ z \end{pmatrix} = z$

für **jede** Anfangsverteilung $\pi \implies$

Für eine schöne Kette \mathcal{M} gilt $\text{PR}^* = \mathcal{G}(\mathcal{M}) = ((P^\infty)_{1,j} : 1 \leq j \leq n)$.

„schön“ = ergodisch

Eine Markov-Kette (G, P) mit $G = (V, E)$ ist **ergodisch**, wenn

- (a) die Grenzwahrscheinlichkeiten $\lim_{k \rightarrow \infty} (P^k)_{i,j}$ und $\lim_{k \rightarrow \infty} (P^k)_{i^*,j}$ für alle Zustände i, i^*, j existieren und übereinstimmen sowie
- (b) $\lim_{k \rightarrow \infty} (P^k)_{i,j} > 0$ für alle Zustände i, j gilt.

Und die Konsequenz:

Die Markov-Kette $\mathcal{M} = (G, P)$ sei ergodisch. Dann gilt für jede Verteilung π

$$\lim_{k \rightarrow \infty} \pi \cdot P^k = \left(\lim_{k \rightarrow \infty} (P^k)_{1,1}, \dots, \lim_{k \rightarrow \infty} (P^k)_{1,n} \right).$$

Insbesondere ist

$$\mathcal{G}(\mathcal{M}) = \left(\lim_{k \rightarrow \infty} (P^k)_{1,1}, \dots, \lim_{k \rightarrow \infty} (P^k)_{1,n} \right)$$

die Grenzverteilung der Kette.

Wenn die Webkette \mathcal{W} ergodisch ist, gilt $\text{PR}^* := \mathcal{G}(\mathcal{W})$.

Das Leben ist hart, oder?

Der Graph G sei **bipartit**.

- Wenn wir eine Irrfahrt in einem Knoten i beginnen, ist

$$(P^{2k+1})_{i,i} = 0,$$

denn ein bipartiter Graph hat keine Kreise ungerader Länge.

- Der Grenzwert $\lim_{k \rightarrow \infty} (P^k)_{i,i}$ existiert nicht, wenn $\lim_{k \rightarrow \infty} (P^{2k})_{i,i} > 0$ gilt

:-((

Aber der vollständige Graph \vec{K}_n der Webkette ist doch nicht bipartit!

:))

Eine Kette ist ergodisch, wenn ihr **Graph schön** ist

Sei G ein gerichteter Graph.

- (a) G heißt genau dann **irreduzibel**, wenn G stark zusammenhängend ist.
- (b) Ein Zustand $i \in V$ hat die **Periode** p , wenn die Längen aller (nicht notwendigerweise einfachen) Wege von i nach i durch p teilbar sind.
 G heißt **aperiodisch** \iff kein Zustand besitzt eine Periode $p > 1$.

Die Markov-Kette (G, P) ist ergodisch $\iff G$ ist irreduzibel und aperiodisch.

\implies :

- i) G muss irreduzibel sein, denn $\lim_{k \rightarrow \infty} (P^k)_{i,j} > 0$ wird für alle i, j gefordert.
- ii) Der Zustand i darf keine Periode haben, denn sonst existiert $\lim_{k \rightarrow \infty} (P^k)_{i,i}$ nicht!

\impliedby : Siehe Mathematik 3.


- (a) Die Webkette $\mathcal{W} = (\vec{K}_n, P_d(\text{WEB}))$ ist **ergodisch**, denn für alle Knoten i, j besitzt \vec{K}_n eine Kante (i, j) .
- ▶ \vec{K}_n ist sicherlich irreduzibel, denn es gibt eine Kante zwischen je zwei Knoten
 - ▶ und aperiodisch, denn wir können in einem Schritt von i nach i laufen.

Wie bestimmt man die Grenzverteilung $\mathcal{G}(\mathcal{W})$?

- (b) Die Markov-Kette $\mathcal{M} = (G', P)$ zu einer Irrfahrt auf einem **zusammenhängenden, nicht-bipartiten** Graphen $G = (V, E)$ ist **ergodisch**.
- ▶ Zur Erinnerung: Es ist $G' = (V, \{(i, j) : \{i, j\} \in E\})$.
 - ▶ G ist zusammenhängend \implies der Graph G' der Kette ist irreduzibel.
 - ▶ Warum ist G' aperiodisch? Sei u ein Zustand von G' .
 - ★ u ist Teil eines Kreises in G' der Länge 2: Laufe von u zu einem Nachbarn und zurück.
 - ★ G ist genau dann nicht bipartit, wenn G einen Kreis ungerader Länge hat.

Wie sieht die Grenzverteilung $\mathcal{G}(\mathcal{M})$ aus?


(c) „Gambler's Ruin“: Die Kette



ist **nicht ergodisch**, denn die Zustände 0 und $M = K + N$ sind „**absorbierend**“ und der Graph ist nicht irreduzibel.

(d) Die Ehrenfest-Kette ist **nicht ergodisch**: Der Graph der Kette ist bipartit.

- Führe Eigenschleifen mit Wahrscheinlichkeit ϵ ein.



- Jeder Knoten hat die Periode 1 aufgrund der Eigenschleifen: Die neue Kette ist also irreduzibel wie auch aperiodisch und deshalb **ergodisch**.
- Wie sieht ihre Grenzverteilung aus?

(e) Die „Warteschlangenkette“ ist irreduzibel und aperiodisch, aber sie besitzt **unendlich viele Zustände**: Im Allgemeinen folgt Ergodizität leider nicht.

Der alte und der neue Page-Rank

- ! Der neue Page-Rank PR^* stimmt mit der Grenzverteilung $\mathcal{G}(W)$ der Webkette überein.
- ? Stehen alter und neuer Page-Rank miteinander in Beziehung?
- ? Lässt sich der neue, bzw. der alte Page-Rank effizient berechnen?

Stationäre Verteilungen

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

Eine Verteilung π auf V heißt **stationär** für die Markov-Kette (G, P) , falls

$$\pi \cdot P = \pi.$$

- Die Kette (G, P) , wenn in der Verteilung π gestartet, befindet sich nach einem Schritt in der Verteilung $\pi \cdot P = \pi$.
- Die Verteilung π ist stationär für $(G, P) \iff$ die Kette bleibt in π „stecken“.

Der Page-Rank ist eine stationäre Verteilung!

Der Page-Rank PR ist eine Verteilung. (Siehe Tafel).

Sei $P = P_d(\text{WEB})$ die Übergangsmatrix der Webkette.

$$\begin{aligned} \text{PR}_j & \stackrel{\text{Definition von PR}}{=} \frac{1-d}{n} + d \cdot \sum_{i \in \text{Vor}_{\text{WEB}}(j)} \frac{\text{PR}_i}{a_i} \\ & \stackrel{\text{PR ist eine Verteilung}}{=} \sum_{i \in \{1, \dots, n\}} \frac{1-d}{n} \cdot \text{PR}_i + d \cdot \sum_{i \in \text{Vor}_{\text{WEB}}(j)} \frac{\text{PR}_i}{a_i} \\ & \stackrel{\text{Definition von } P_d(\text{WEB})}{=} \sum_{i \in \{1, \dots, n\}} \text{PR}_i \cdot (P_d(\text{WEB}))_{i,j} = (\text{PR} \cdot P_d(\text{WEB}))_j. \end{aligned}$$

Der Page-Rank ist eine stationäre Verteilung der Webkette!

Der Hauptsatz für ergodische Markov-Ketten

$\mathcal{M} = (G, P)$ sei eine **ergodische** Markov-Kette.

Dann gibt es genau eine **stationäre Verteilung** σ und σ stimmt mit der **Grenzverteilung** überein, d.h. es gilt

$$\mathcal{G}(\mathcal{M}) = \sigma.$$

Die stationäre Verteilung ist gleichzeitig Grenzverteilung! Und warum stimmt das?

Die wichtige Konsequenz: Für die Webkette gilt

$$\mathbf{PR} = \mathbf{PR}^*.$$

Alter und neuer Page-Rank stimmen überein.

Schritt 1: Die Grenzverteilung ist stationär!

$$\begin{aligned}(\mathcal{G}(\mathcal{M}) \cdot P)_j &= \sum_{i=1}^n \left(\lim_{k \rightarrow \infty} (P^k)_{1,i} \right) \cdot P_{i,j} = \lim_{k \rightarrow \infty} \sum_{i=1}^n (P^k)_{1,i} \cdot P_{i,j} \\ &= \lim_{k \rightarrow \infty} \sum_{i=1}^n (P^{k+1})_{1,j} = \lim_{k \rightarrow \infty} \sum_{i=1}^n (P^k)_{1,j} \\ &= (\mathcal{G}(\mathcal{M}))_j.\end{aligned}$$

Es bleibt zu zeigen, dass $\mathcal{G}(\mathcal{M})$ die einzige stationäre Verteilung ist.

Schritt 2: Es gibt genau eine stationäre Verteilung

Sei π eine beliebige stationäre Verteilung für die Kette (G, P) .

1. Dann ist $\pi = \pi \cdot P$ und deshalb gilt $\pi = \pi \cdot P^k$ für jede natürliche Zahl k .
Es folgt $\pi = \lim_{k \rightarrow \infty} \pi \cdot P^k$.
2. Wir dürfen Limes und Summe miteinander vertauschen und erhalten

$$\pi = \lim_{k \rightarrow \infty} \pi \cdot P^k = \pi \cdot \lim_{k \rightarrow \infty} P^k = \pi \cdot P^\infty = \mathcal{G}(\mathcal{M}).$$

Es ist $\pi = \mathcal{G}(\mathcal{M})$.

Stationäre Verteilungen: Beispiele

Symmetrische Ketten

Sei (G, P) eine Markov-Kette und die Matrix P sei **symmetrisch**, d.h. $P_{i,j} = P_{j,i}$ gilt für alle Knoten i, j . Dann ist die Gleichverteilung $\sigma = (1/n, \dots, 1/n)$ stationär.

Warum?

$$\begin{aligned}(\sigma \cdot P)_j &= \sum_{i=1}^n \sigma_i \cdot P_{i,j} = \sum_{i=1}^n \frac{1}{n} \cdot P_{i,j} = \frac{1}{n} \cdot \sum_{i=1}^n P_{i,j} \\ &\stackrel{P \text{ ist symmetrisch}}{=} \frac{1}{n} \cdot \sum_{i=1}^n P_{j,i} \stackrel{P \text{ ist stochastisch}}{=} \frac{1}{n} = \sigma_j.\end{aligned}$$

Also gilt $\sigma \cdot P = \sigma$ und die Gleichverteilung ist tatsächlich stationär \implies Jeder der n Zustände hat die Wahrscheinlichkeit $\frac{1}{n}$.

Irrfahrten in ungerichteten Graphen

Sei $G = (V, E)$ ein ungerichteter, zusammenhängender und nicht-bipartiter Graph. Dann besucht eine Irrfahrt den Knoten v mit Wahrscheinlichkeit

$$\pi_v = \frac{d_v}{2|E|}.$$

Ein Knoten wird mit Wahrscheinlichkeit proportional zu seinem Grad besucht!

- ✓ Die Markov-Kette für Irrfahrten in ungerichteten Graphen ist ergodisch.
- ! Zeige: Die Verteilung π mit $\pi_v := \frac{d_v}{2|E|}$ ist stationär. ($d_v = |\text{Nachbarn von } v|$.)
- ! Zeige $\pi \cdot P = \pi$ (für die Übergangsmatrix P).

$$\begin{aligned}(\pi \cdot P)_v &= \sum_{u \in V} \pi_u \cdot P_{u,v} = \sum_{u \in V} \frac{d_u}{2|E|} \cdot P_{u,v} = \sum_{u \in V, \{u,v\} \in E} \frac{d_u}{2|E|} \frac{1}{d_u} \\ &= \sum_{u \in V, \{u,v\} \in E} \frac{1}{2|E|} = \frac{d_v}{2|E|} = \pi_v. \quad \checkmark\end{aligned}$$

Die Verteilung π mit

$$\pi_i = \binom{n}{i} / 2^n$$

für $i = 0, \dots, n$ ist stationär. (Übungsaufgabe.)


- 1 π ist die einzige stationäre Verteilung und
- 2 π stimmt mit der Grenzverteilung überein.

Auf der linken Seite der Membrane befinden sich ℓ Partikel mit Wahrscheinlichkeit

$$\binom{n}{\ell} / 2^n.$$

Man sagt, dass π eine **Binomialverteilung** ist.

Stationäre Verteilungen im „Gambler's Ruin“



- 1 Wenn wir im Zustand 0 starten, bleiben wir stecken:
Die Verteilung $(1, 0, \dots, 0)$ ist stationär.
- 2 Gleiches gilt für den Zustand M : Die Verteilung $(0, \dots, 0, 1)$ ist stationär.
- 3 Alle „Konvexkombinationen“, also alle Verteilungen

$$(\lambda, 0, \dots, 0, 1 - \lambda)$$

für $0 \leq \lambda \leq 1$ sind stationär.

Diese Markov-Kette hat **unendlich** viele stationäre Verteilungen!

Lässt sich der Page-Rank schnell und gut approximieren?

Sei $\mathcal{M} = (G, P)$ eine ergodische Markov-Kette.

1. Sei $\pi^{(0)} := \pi$ eine beliebige Verteilung auf $\{1, \dots, n\}$ und setze

$$\pi^{(k+1)} = \pi^{(k)} \cdot P.$$

2. Nach k Schritten befindet sich die Kette in der Verteilung

$$\pi^{(k)} := \pi \cdot P^k.$$

3. Wenn k genügend groß ist, dann ist

$$\pi^{(k)} = \pi \cdot P^k \approx \pi \cdot P^\infty = \mathcal{M}(\mathcal{G}).$$

- Es ist $\pi^{(k)} \approx \mathcal{G}(\mathcal{M})$ wenn k „genügend“ groß ist.
- Um $\pi^{(k)}$ zu bestimmen, berechne

$$\pi^{(1)} = \pi^{(0)} \cdot P, \pi^{(2)} = \pi^{(1)} \cdot P, \dots, \pi^{(k)} = \pi^{(k-1)} \cdot P.$$

- ✓ Die Berechnung eines jeden der k Vektor-Matrix Produkte ist „hochgradig parallelisierbar“.
- ✓ $\pi^{(k)} \approx \mathcal{G}(\mathcal{M})$ bereits für kleine Werte von k :
 - ▶ Das Web ist „hoch-gradig zusammenhängend“.
 - ▶ Die Hypothese des „**Kleine-Welt-Phänomens**“ besagt, dass in vielen sozialen Netzwerken (fast) jeder Mensch mit jedem anderen über eine Kette von höchstens **6** Bekanntschaftsbeziehungen verbunden ist.

:-))

Es ist alles gut!

:-))

Zusammenfassung

Zusammenfassung: Markov-Ketten

Die Kette $\mathcal{M} = (G, P)$ besteht aus einer stochastischen Übergangsmatrix P und einem gerichteten Graphen $G = (\{1, \dots, n\}, E)$ mit $(i, j) \in E \iff P_{i,j} > 0$.

- (a) Ein Schritt der Markov-Kette \mathcal{M} kann durch das Matrix-Vektor Produkt $\pi \cdot P$ beschrieben werden:
- ▶ Wenn ein Zustand i mit Wahrscheinlichkeit π_i ausgewürfelt wird, dann befindet sich die Kette nach einem Schritt im Zustand j mit Wahrscheinlichkeit $(\pi \cdot P)_j$.
- (b) Eine **stationäre Verteilung** σ ist Lösung des linearen Gleichungssystems

$$\sigma \cdot P = \sigma.$$

- (c) (G, P) ist **ergodisch**, wenn G irreduzibel (bzw. stark zusammenhängend) und aperiodisch ist.
- ▶ **Der Hauptsatz für ergodische Markov-Ketten:** Eine ergodische Kette besitzt genau eine **stationäre Verteilung** $\mathcal{G}(\mathcal{M})$ und $\mathcal{G}(\mathcal{M})$ ist die **Grenzverteilung**.
 \implies die Wahrscheinlichkeit, dass Zustand i am Ende einer langen Irrfahrt angenommen wird, konvergiert gegen $(\mathcal{G}(\mathcal{M}))_i$.

Zusammenfassung: Page-Rank

Für eine Anfrage a wählt Google zuerst eine Menge $\mathcal{M}(a)$ von Webseiten aus, die für a relevant sind. Die Seiten werden dann u. a. nach ihrem Page-Rank geordnet.

- (a) Durch das Hinzufügen von „neuen Kanten“ wird die Webkette **ergodisch**.
- (b) Der Ansatz des **Peer-Reviews**:
 - ▶ Die Webseite v vererbt ihr Renommee anteilig auf jede Webseite w , auf die sie einen Hyperlink gesetzt hat.
 - ▶ Der Page-Rank ist die stationäre Verteilung der Webkette.
- (c) Der Ansatz des **Zufallssurfers**:
 - ▶ Die Webkette ist ergodisch: Die Grenzwahrscheinlichkeit π_v , also die Wahrscheinlichkeit, dass der Zufallssurfer die Seite v am Ende einer langen Irrfahrt besucht, konvergiert gegen den Page-Rank der Seite v .
 - ▶ Der Page-Rank wird bereits durch kurze Irrfahrten scharf approximiert. :-))