

### Kapitel 3: Momente und Abweichungen

Bisherige Überlegungen: Bestimme Erwartungswert einer Zufallsvariablen (z.B. Laufzeit eines Las Vegas Algorithmus).

Jedoch ebenso wichtig: Wie hoch ist die Wahrscheinlichkeit, dass eine Zufallsvariable weit vom Erwartungswert abweicht?

Markovs Ungleichung: Sei  $Y$  eine Zufallsvariable, die nur nicht-negative Werte annimmt. Dann gilt für alle  $t \geq 0$ :

$$\Pr[Y \geq t] \leq \frac{E[Y]}{t}$$

Sei  $X$  eine Zufallsvariable und  $f: \mathbb{R} \rightarrow \mathbb{R}$  eine Funktion.

### 1. Hilfsmittel Markovs Ungleichung

Sei  $X$  eine Zufallsvariable und  $f: \mathbb{R} \rightarrow \mathbb{R}$  eine Funktion.

Dann definierten wir

$$E[f(X)] = \sum_x f(x) \cdot \Pr[X = x]$$

Beweis: Definiere Funktion  $\mathbb{f}$  durch  $\mathbb{f}(y) = \begin{cases} 1 & \text{falls } y \geq t, y > 0 \\ 0 & \text{sonst } y \leq 0 \end{cases}$

$$\Rightarrow \Pr[Y \geq t] = E[\mathbb{f}(Y)]$$

Wegen  $\mathbb{f}(y) \leq \frac{y}{t}$  folgt:

$$\begin{aligned} \Pr[Y \geq t] &= E[\mathbb{f}(Y)] \leq E\left[\frac{Y}{t}\right] \\ &= \frac{E[Y]}{t} \end{aligned}$$

□

## 2. Hilfsmittel: Chebyshevs Schranke

- Sei  $X$  eine Zufallsvariable.  
Im folgenden schreiben wir auch  $\mu_X$  für den Erwartungswert  $E[X]$
- Die Varianz  $\text{var}[X]$  (oder auch  $\sigma_X^2$ ) ist  $E[(X - \mu_X)^2]$
- Die Standardabweichung  $\sigma_X$  von  $X$  ist die positive Quadratwurzel vom  $\sigma_X^2$ .

Chebyshevs Schranke: Sei  $X$  eine Zufallsvariable. Dann gilt für alle  $t > 0$ :

$$\Pr[|X - \mu_X| \geq t \cdot \sigma_X] \leq \frac{1}{t^2}$$

Beweis: Sei  $Y = (X - \mu_X)^2$ .

$$\Rightarrow \Pr[|X - \mu_X| \geq t \cdot \sigma_X] =$$

$$\Pr[(X - \mu_X)^2 \geq t^2 \cdot \sigma_X^2] =$$

$$\Pr[Y \geq t^2 \cdot E[Y]] \stackrel{\leq}{\leftarrow} \text{Markovs Ungleichung}$$

$$\frac{E[Y]}{t^2 \cdot E[Y]} = \frac{1}{t^2}$$

• Eine Anwendung vom Chebyshevs Schranke: Randomisierte Auswahl

Gegeben: Menge  $S$  vom  $n$  verschiedenen Zahlen,  $k \in \{1, \dots, n\}$

Gesucht: Das  $k$ -kleinste Element aus  $S = S_{(k)}$

Für  $t \in S$  sei  $r_S(t)$  der Rang von  $t$  in  $S$ :  
 $S(r_S(t)) = t$ ,  $r_S(S_{(k)}) = k$

### Algorithmus LazySelect

(1) Wähle  $m^{3/4}$  viele Elemente aus  $S$  einfallig, gleichverteilt und mit Zähler aus.

→ Multimenge  $R$  der Größe  $m^{3/4}$

(2) Sortiere  $R$  mit  $O(m^{3/4} \cdot \log(m)) \leq O(m)$  vielen Vergleichen, z.B. mit heapSort.

(3)  $x := k \cdot m^{-\frac{1}{4}}$

$$\lambda := \max\{1, \lfloor x - \sqrt{m} \rfloor\}; h := \min\{m^{\frac{3}{4}}, \lceil x + \sqrt{m} \rceil\}$$

$\alpha := R(\lambda); \beta := R(h);$

Vergleiche  $\alpha$  und  $\beta$  mit jedem Element aus  $S$  ( $2m$  Vergleiche), und bestimme so  $n_S(a)$  und  $n_S(\beta)$ .

(4) if  $k < m^{1/4}$  then  $P := \{y \in S \mid y \leq \beta\}$

elseif  $k > m - m^{1/4}$  then  $P := \{y \in S \mid y \geq \alpha\}$

elseif  $k \in [m^{1/4}, m - m^{1/4}]$  then  $P := \{y \in S \mid \alpha \leq y \leq \beta\}$

(5) if  $S(k) \in P$  und  $|P| \leq 4 \cdot m^{3/4} + 2m^{1/4}$  then

    goto (6)

else goto (1)

(6) Sortiere  $P$  mit  $O(|P| \cdot \log(|P|)) \leq O(m^{3/4} \cdot \log(m)) \leq O(m)$  Vergleichen

Bestimme dann  $P(k - n_S(a) + 1) = S(k)$   
Bzw.  $P(k) = S(k)$  falls  $P = \{y \in S \mid y \leq \beta\}$

- Beachte: In (5) kommen wir in Zeit  $O(n)$  überprüfen, ob  $S(k) \in P$  gilt, da  $n_S(a)$  und  $n_S(\beta)$  bekannt sind.

- Wir wollen im folgenden zeigen, dass LazySelect mit hoher Wahrscheinlichkeit nur einmal (1) – (5) durchläuft.  
Im diesem Fall ist die Gesamtlaufzeit  $2m + O(m)$ .

- Bemerkung: Der beste deterministische Auswahl-Algorithmus hat eine Worst Case Laufzeit von  $3m$  (und ist recht kompliziert).

- Wir untersuchen hier nur den (schwierigsten Fall)  $P = \{y \in S \mid \alpha \leq y \leq \beta\}$   
d.h.  $k \in [m^{1/4}, m - m^{1/4}]$

- Wann haben wir in Schritt (5)  $P_{\text{off}}$  und  $P_{\text{on}}$  wieder zu Schritt (1):

Möglichkeit A:  ~~$S_{(k)} \neq P$~~ , d.h.

$$R_{(l)} = \alpha > S_{(k)} \quad \text{oder} \quad R_{(h)} = \beta < S_{(k)}$$

Möglichkeit B:

$$|P| > 4 \cdot m^{3/4} + 2m^{1/4} - 1$$

- wir werden zeigen, dass beide Möglichkeiten nur mit kleiner Wahrscheinlichkeit eintreten.

### Exkurs: unabhängige Zufallsvariablen

Definition: Zwei Zufallsvariablen  $X$  und  $Y$  sind unabhängig, falls für alle

$$x, y \in \mathbb{R} \text{ gilt:}$$

$$\text{Prob}[X=x \wedge Y=y] = \text{Prob}[X=x] \cdot \text{Prob}[Y=y]$$

Satz (ohne Beweis): Seien  $X$  und  $Y$

unabhängige Zufallsvariablen. Dann gilt:  $E[X \cdot Y] = E[X] \cdot E[Y]$

Satz: Seien  $X_1, X_2, \dots, X_m$  unabhängige Zufallsvariablen. Sei  $X = \sum_{i=1}^m X_i$ .

$$\text{Dann gilt: } \sigma_X^2 = \sum_{i=1}^m \sigma_{X_i}^2 \quad (*)$$

Beweis: Sei  $\mu_i = E[X_i]$ ,

$$\mu = \sum_{i=1}^m \mu_i = E[X]$$

Zur Möglichkeit A:

$$\begin{aligned}
 \text{Es gilt: } \sigma_x^2 &= E[(X-\mu)^2] = \\
 &= E\left[\left(\sum_{i=1}^n (x_i - \mu_i)\right)^2\right] \stackrel{\text{Linearity of expectations}}{=} \\
 &= \sum_{i=1}^n E[(x_i - \mu_i)^2] + 2 \cdot \sum_{i < j} E[(x_i - \mu_i)(x_j - \mu_j)] \\
 &\quad \text{unabhängig, da } X_i \text{ und } X_j \text{ unabhängig.} \\
 &= \sum_{i=1}^n \sigma_{x_i}^2 + \\
 &\quad 2 \cdot \sum_{i < j} E[x_i - \mu_i] \cdot E[x_j - \mu_j] \\
 &= \underbrace{E[X_i]}_{\mu_i} - \mu_j = 0 \\
 &= \sum_{i=1}^n \sigma_{x_i}^2
 \end{aligned}$$

□

Bedeutung (1)  
 $\Pr[\alpha > S_{(k)}] \in O(m^{-\frac{1}{4}})$

Beweis:  $\alpha > S_{(k)}$

$\iff$

$R(\alpha) > S_{(k)}$

$\iff$

weniger als  $k$  der samples in  $R$

sind  $\leq S_{(k)}$

$\Pr[\alpha > S_{(k)}] \leq S_{(k)}$

$S_{(k)} := \begin{cases} 1 & \text{falls } (i\text{-te sample in } R) \leq S_{(k)} \\ 0 & \text{sonst} \end{cases}$

$\rightarrow \Pr[\alpha = 1] = \frac{k}{m}$

$\Pr[\alpha = 0] = 1 - \frac{k}{m}$

$S_{(k)} = \sum_{i=1}^{3m^4} X_i = \text{Anzahl der samples in } R, \text{ die } \leq S_{(k)} \text{ sind.}$

$$\rightarrow \mu_X = m^{3/4} \cdot E[X_i] = \frac{1}{m} \cdot k \cdot m^{3/4}$$

$$= k \cdot m^{-\frac{1}{4}} \stackrel{0}{=} x$$

$$(*) \quad \sum_{i=1}^m \sigma_{X_i}^2 \stackrel{3/4}{=} x$$

Lemma: Sei  $Y$  eine Zufallsvariable mit  $\text{Prob}[Y=1]=p$  und  $\text{Prob}[Y=0]=1-p$  (Bernoulli Verteilung).

Dann gilt  $\sigma_Y^2 = p \cdot (1-p)$

Beweis: Übung

$$\text{Also gilt: } \sigma_X^2 = m^{3/4} \cdot \left(1 - \frac{k}{m}\right) \cdot \frac{k}{m} \leq \frac{1}{4} \cdot m^{3/4}$$

(Berechne: die Funktion  $(1-x) \cdot x$  wird in Intervall  $[0,1]$  maximal für  $x = \frac{1}{2}$ )

$$\rightarrow \sigma_X \leq \frac{1}{2} \cdot m^{3/8}$$

Chesky'scher  $\xrightarrow{x}$

$$\text{Prob}[|X - \mu_X| \geq \sqrt{m}] \leq \text{Prob}[|X - \mu_X| \geq \underbrace{2 \cdot m^{3/8} \cdot \sigma_X}_{\leq \sqrt{m}}] \leq$$

$$\bullet \leq \frac{1}{(2 \cdot m^{3/8})^2} \in O(m^{-\frac{7}{4}}) \quad (**)$$

Nun schätzen wir  $\text{Prob}[a > S_{(k)}]$  ab:

$$\text{Prob}[a > S_{(k)}] = \text{Prob}[X < \bar{\ell}] =$$

$$\bullet = \text{Prob}[X < \max\{1, |x - \sqrt{m}|\}]$$

$$1. \text{ Fall: } |x - \sqrt{m}| \geq 1$$

Dann gelten folgende Implikationen:

$$X < \bar{\ell} \Leftrightarrow X < \lfloor x - \sqrt{m} \rfloor \Rightarrow$$

$$X < x - \sqrt{m} \Rightarrow X - x < -\sqrt{m}$$

$$\Rightarrow |X - x| \geq \sqrt{m}$$

(1)  $\Rightarrow \Pr[X < x] \leq \Pr[|X - x| \geq \sqrt{m}]$

(\*)  $\in O(m^{-\frac{1}{4}})$

2. Fall:  $|x - \sqrt{m}| < 1$

•  $\Rightarrow \lambda = 1$

$$\begin{aligned} \Rightarrow \Pr[X < x] &= \Pr[X = 0] \\ &= \left(1 - \frac{k}{m}\right)^{m^{3/4}} \\ &\leq e^{-k \cdot m^{3/4}} \leq e^{-1} \quad \in O(m^{-\frac{1}{4}}) \end{aligned}$$

Beweis vom Behauptung (2):

$$\begin{aligned} \Pr[\alpha > S_{(k)} \vee \beta < S_{(k)}] &\in O(m^{-\frac{1}{4}}) \\ \Pr[|\beta| > 4 \cdot m^{\frac{3}{4}} + 2m^{\frac{1}{4}} - 1] &\in O(m^{-\frac{1}{4}}) \end{aligned}$$

$$\begin{aligned} \text{Definiere } k_L &:= \max \{1, k - 2 \cdot m^{\frac{3}{4}} - m^{\frac{1}{4}} + 1\} \\ k_h &:= \min \{k + 2 \cdot m^{\frac{3}{4}} + m^{\frac{1}{4}} - 1\} \end{aligned}$$

Dies beendet den Beweis vom Behauptung (1)

Analog zeigt man:

$$\Pr[\beta < S_{(k)}] \in O(m^{-\frac{1}{4}})$$

Damit ergibt sich insgesamt:

$$\begin{aligned} \Pr[S_{(k)} \notin P] &= \\ &= \Pr[\alpha > S_{(k)} \vee \beta < S_{(k)}] \in O(m^{-\frac{1}{4}}) \end{aligned}$$

wegen  $P = \{y \in S \mid \alpha \leq y \leq \beta\}$  gelten  
folgende Implikationen:

$$\alpha \geq S(k_\ell) \wedge \beta \leq S(k_h)$$

$$\Rightarrow |P| \leq k_h - k_\ell + 1 \\ \leq k + 2 \cdot m^{3/4} + m^{1/4} - 1 - k + 2m^{3/4} + m^{1/4} - 1 + 1 \\ = 4 \cdot m^{3/4} + 2m^{1/4} - 1$$

$$D.h.: (|P| > 4 \cdot m^{3/4} + 2m^{1/4} - 1) \rightarrow$$

$$(\alpha < S(k_\ell) \text{ oder } \beta > S(k_h))$$

$$\Rightarrow \text{Prob}[|P| > 4 \cdot m^{3/4} + 2m^{1/4} - 1]$$

$$\leq \text{Prob}[\alpha < S(k_\ell)] + \text{Prob}[\beta > S(k_h)]$$

$$\text{Wir zeigen nun: } \text{Prob}[\alpha < S(k_\ell)] \in O(m^{-\frac{1}{4}})$$

analog kann auf  $\text{Prob}[\beta > S(k_h)] \in O(m^{-\frac{1}{4}})$  gezeigt werden.

Es gilt:  $\alpha < S(k_\ell)$

$$\Leftrightarrow$$

$$R(\ell) < S(k_\ell)$$

$$\Leftrightarrow$$

$$\leq k + 2 \cdot m^{3/4} + m^{1/4} - 1 - k + 2m^{3/4} + m^{1/4} - 1 + 1 \\ \leq m^{3/4} + 2m^{1/4} - 1$$

$$D.h.: (|P| > 4 \cdot m^{3/4} + 2m^{1/4} - 1) \rightarrow$$

$$X_i := \begin{cases} 1 & \text{falls } (\text{i-te sample}) < S(k_\ell) \\ 0 & \text{sonst} \end{cases}$$

$$X := \sum_{i=1}^{m^{3/4}} X_i$$

$$E[X_i] = \text{Prob}[X_i = 1] \\ = \frac{k_\ell - 1}{m}$$

$$\text{Also: } \alpha < S(k_\ell) \Leftrightarrow X \geq \lambda$$

$$\mu_X = m^{3/4} \frac{k_\ell - 1}{m} = m^{-\frac{1}{4}} (k_\ell - 1)$$

$$6\lambda \leq \frac{1}{2} m^{3/8} \quad (\text{folgt wie bei Behauptung (1)})$$

**Chebyshev**  $\rightarrow \text{Prob}[|X - \mu_X| \geq \sqrt{m}] \in O(m^{-\frac{1}{4}})$

1. Fall:  $1 > K - 2 \cdot m^{3/4} - m^{1/4} + 1$

$\rightarrow k_\ell = \max\{1, K - 2 \cdot m^{3/4} - m^{1/4} + 1\}$

$\rightarrow \text{Prob}[\alpha < S_{(k_\ell)}]$

$= \text{Prob}[\alpha < S_{(n)}]$

$= \text{Prob}[\text{mind. } l \text{ samples in } R \text{ sind } < S_{(n)}]$

$= O \in O(m^{-\frac{1}{4}})$

2. Fall:  $1 \leq K - 2 \cdot m^{3/4} - m^{1/4} + 1$

$\rightarrow k_\ell = K - 2 \cdot m^{3/4} - m^{1/4} + 1$

$\rightarrow \mu_X = m^{-\frac{1}{4}} (K - 2 \cdot m^{3/4} - m^{1/4})$

Es gelten nun folgende Implikationen:

$\alpha < S_{(k_\ell)} \Rightarrow X \geq \lambda$

$\Rightarrow X \geq \max\{1, \lfloor x - \sqrt{m} \rfloor\}$

$\Rightarrow X \geq \lfloor x - \sqrt{m} \rfloor$

$\Rightarrow X \geq x - \sqrt{m} - 1 =$   
 $= k \cdot m^{-\frac{1}{4}} - \sqrt{m} - 1$

$\Rightarrow X + 2 \cdot \sqrt{m} - k \cdot m^{-\frac{1}{4}} + 1 \geq \sqrt{m}$   
 $\Rightarrow \underbrace{X - m^{-\frac{1}{4}} (K - 2 \cdot m^{3/4} - m^{1/4})}_{X - \mu_X} \geq \sqrt{m}$

$\Rightarrow |X - \mu_X| \geq \sqrt{m}$

also:  $\text{Prob}[\alpha < S_{(k_\ell)}] \leq$   
 $\text{Prob}[|X - \mu_X| \geq \sqrt{m}] \in O(m^{-\frac{1}{4}})$

Satz: Mit Wahrscheinlichkeit  $1 - O(m^{-\frac{1}{4}})$  findet LazySelect  $S(k)$  im wosten Durchlauf vom  $(n-1)(s)$ . Im diessen Fall ist die Laufzeit  $2m + o(m)$ .

Wahrscheinlichkeitsverstarzung mittels zwei-Punkt-Sampling

Zufallsvariablen  $X_1, X_2, \dots, X_m$  sind paarweise unabhangig falls fur alle

$i, j \in \{1, \dots, m\}$  mit  $i \neq j$  gilt

$$\text{Prob}[X_i = x \mid X_j = y] = \text{Prob}[X_i = x]$$

Im dieses Fall gilt fur  $X = X_1 + X_2 + \dots + X_m$

$$\sigma_X^2 = \sum_{i=1}^m \sigma_{X_i}^2$$

Bei der Verandomisierung von Luby's Algorithmus haben wir eigentlich folgendes getztigt:

Satz: Sei  $p$  eine Primzahl. W hle  $\alpha$  und  $\beta$  unabhangig und gleichverteilt aus  $\mathbb{F}_p = \{0, 1, \dots, p-1\}$  aus.  
Fur  $i \in \{0, \dots, p-1\}$  sei  $Y_i = \alpha \cdot i + \beta \bmod p$ .  
Dann ist auch  $Y_i$  gleichverteilt über  $\mathbb{F}_p$  ( $\text{Prob}[Y_i = y] = \frac{1}{p}$  fur alle  $y \in \mathbb{F}_p$ ) und  $Y_0, Y_1, \dots, Y_{p-1}$  sind paarweise unabhangig.

zur Erinnerung: RP ist die Klasse aller Sprachen  $L$  fur die es einen polynomidellen Monte Carlo Algorithmus

A gilt mit:

- $x \in L \Rightarrow \text{Prob}[A \text{ akzeptiert } x] \geq \frac{1}{2}$
- $x \notin L \Rightarrow \text{Prob}[A \text{ akzeptiert } x] = 0$

Wir stellen uns den Algorithmus A im folgenden wie folgt vor:

- (1) A wählt zufällig und gleichverteilt eine Zahl  $r \in \{0, \dots, m-1\}$ . (wir alle Münzen zu Beginn und sei  $\{0, \dots, m-1\}$  der entstehende Wahrscheinlichkeitsraum).
- Wegen Betwands Postulat können wir außerdem davon ausgehen, dass m eine Primzahl ist.

- (2) A berechnet deterministisch ein Bit  $A(x, r)$  (in Polynomialität).

Dabei gilt:

- $x \in L \Rightarrow$  Für mind. Hälfte aller  $r \in \mathbb{F}_m$  gilt  $A(x, r) = 1$
- $x \notin L \Rightarrow A(x, r) = 0$  für alle  $r \in \mathbb{F}_m$

Beschrifte: m kann exponentiell mit der Inputlänge  $|x|$  wachsen.

Aber: nur  $\log(m)$  viele Zufallszts sind notwendig, um  $\mathcal{N}$  zufällig und gleichverteilt aus  $\mathbb{F}_m$  auszuwählen.

- Für  $x \in L$  ist die Fehlerwahrscheinlichkeit  $(= \Pr[A \text{ fehlerhaft } x \text{ nicht}]) \leq \frac{1}{2}$
- Würs wollen nun die Fehlerwahrscheinlichkeit auf  $\frac{1}{t}$  für ein  $t \leq m$  reduzieren.

Methode 1 Naive Wahrscheinlichkeitsverstärkung.

Weis wie überholen Algorithmus A m mal.

Gibt A bei einer Wiederholung 1 aus, so geben wir insgesamt 1 aus, sonst geben wir 0 aus.

Für  $x \in L$  ist die Fehlerwahrscheinlichkeit jetzt  $\leq \frac{1}{2^m}$

Setze  $m := \log(t)$

$$\rightarrow \text{Fehlerwahrscheinlichkeit} \leq \frac{1}{t}$$

Unser neuer Monte Carlo Algorithmus benötigt insgesamt

$$m \cdot \log(m) = \lceil \log(t) \rceil \cdot \log(m)$$

viele Zufallszüge.

- Bruchung: Für  $x \in L$  gilt

$$\Pr[B \text{ abgeoptiert } x \text{ nicht}] \leq \frac{1}{t}$$

$$\text{Beweis: Sei } Y := \sum_{i=0}^{t-1} A(x, n_i)$$

$$\hookrightarrow \Pr[B \text{ abgeoptiert } x \text{ nicht}] = \\ \Pr[Y = 0]$$

### Methode 2 Zwei-Punkt-Sampling

- (1) Wähle  $\alpha$  und  $\beta$  unabhängig

und gleichverteilt aus  $\mathbb{F}_m$  aus.

$\hookrightarrow 2 \cdot \log(m)$  Zufallszüge notwendig

- (2) Berechne  $n_i := \alpha \cdot i + \beta \bmod m$  sowie  $A(x, n_i) \in \{0, 1\}$  für  $0 \leq i \leq t-1$
- (3) Ist  $A(x, n_i)$  gleich 1, so gehen wir insgesamt 1 aus, sonst gehen wir 0 aus.

Sei  $B$  dieser neue Monte Carlo Algorithmus.

$$\bullet x \notin L \Rightarrow \Pr[B \text{ abgeoptiert } x] = 0$$

- Die Zufallsvariablen  $n_i = \alpha \cdot i + \beta \bmod m$  sind gleichverteilt und paarweise unabhängig  $\square$

- Die Zufallsvariablen  $A(x, n_i) = \alpha \cdot i + \beta \bmod m$  sind gleichverteilt und paarweise unabhängig  $\square$

- $\Pr[B \text{ abgeoptiert } x \text{ nicht}] =$

$$\Rightarrow E[Y] = \sum_{i=0}^{t-1} E[A(x, n_i)] = \\ = \sum_{i=0}^{t-1} \Pr[A(x, n_i) = 1]$$

$$\geq \sum_{i=0}^{t-1} \frac{1}{2} = \frac{t}{2}$$

$N_i$  gleichverteilt auf  $\#F_m$

$$\sigma_y^2 = \sum_{i=0}^{t-1} \sigma_{A(x, N_i)}^2$$

$N_0, \dots, N_{t-1}$   
paarweise unabhängig.

$$\leq \text{Prob}[|y - E[y]| \geq \sqrt{t} \cdot \sigma_y]$$

$$\leq \frac{1}{t}$$

↳ Chernošev

□

$$\begin{aligned} \sigma_{A(x, N_i)}^2 &= \text{Prob}[A(x, N_i) = 0] \cdot \text{Prob}[A(x, N_i) = 1] \\ &= (1 - \text{Prob}[A(x, N_i) = 1]) \cdot \text{Prob}[A(x, N_i) = 1] \\ &\leq \frac{1}{4} \end{aligned}$$

$$\Rightarrow \sigma_y^2 \leq \frac{t}{4} \Rightarrow \sigma_y \leq \frac{\sqrt{t}}{2}$$

$$\Rightarrow \text{Prob}[Y = 0] \leq \text{Prob}[|y - E[y]| \geq \frac{t}{2}]$$

## Stabile Matchings

Gegeben:  $n$  Frauen ( $a, b, c, \dots$ ) und  $n$  Männer ( $x, y, z, \dots$ )

Jede Frau  $a$  (Mann  $x$ ) hat eine Präferenzliste, welche alle Männer (Frauen) enthält.

- Für eine Person  $p$  (Mann oder Frau) und zwei potentielle Partner  $p_1$  und  $p_2$  schreiben wir  $\text{präf}_p(p_1) > \text{präf}_p(p_2)$  falls  $p_1$  in der Präferenzliste von  $p$  vor  $p_2$  steht ( $p$  bevorzugt  $p_1$  gegenüber  $p_2$ )
- Ein Matching ist eine 1-1-Zuordnung von Männern zu Frauen (jede Person ist mit genau einem Partner verheiratet).

Wir schreiben  $\text{partner}(p) = q$

falls  $p$  mit  $q$  verheiratet ist.

- Ein unzufriedenes Paar ist ein Paar  $(x, a)$  ( $x \in \text{Männer}, a \in \text{Frauen}$ ) mit:
  - $\text{präf}_x(a) > \text{präf}_x(\text{partner}(x))$
  - und •  $\text{präf}_a(x) > \text{präf}_a(\text{partner}(x))$
- Ein Matching ist stabil, falls kein unzufriedenes Paar existiert.

Frage: Existiert für beliebe Präferenzlisten ein stabiles Matching?

Beispiel:

$x$ :	$abcd$	$a$ :	$xyzzz'$
$y$ :	$bacd$	$b$ :	$z'zyx$
$z$ :	$adcb$	$c$ :	$xyzzz'$
$z'$ :	$dcalb$	$d$ :	$zz'xy$

Das folgende Matching ist nicht stabil

$$\begin{array}{l} x \longrightarrow a \\ y \longrightarrow b \\ z \longrightarrow c \\ z' \longrightarrow d \end{array}$$

$(z, d)$  ist ein unzufriedenes Paar.

Das folgende Matching ist stabil:

$$\begin{array}{l} x \longrightarrow a \\ y \longrightarrow b \\ z \longrightarrow d \\ z' \longrightarrow c \end{array}$$

Wie findet man ein stabiles Matching?

### Proposal - Algorithmus

Männer machen Angebote,  
Frauen lehnen ab.

forall  $x \in$  Männer do

Kandidaten( $x$ ) = alle Frauen  
endor

while "es existiert unverheirateter Mann" do

- sei  $x$  ein unverheirateter Mann;
- sei Frau  $a \in$  Kandidaten( $x$ ) so, dass:  
 $\text{präf}_x(a) \geq \text{präf}_x(b)$  für alle  
 $b \in$  Kandidaten( $x$ ).
- if "a ist ledig oder  
 $\text{präf}_a(x) > \text{präf}_a(\text{partner}(a))$ "  
then

$\text{partner}(a) := x$ ,  $\text{partner}(x) := a$

\* (der alte Partner von  $a$  (~~der~~  
 $\rightarrow$  ~~nicht ledig war~~) ist jetzt ledig)

endif

Kandidaten( $x$ ) := Kandidaten( $x$ ) \ { $a$ }

endwhile

Satz: Der Proposal-Algorithmus

terminiert nach höchstens  $n^2$   
( $n = \text{Anzahl Männer} = \text{Anzahl Frauen}$ )

Durchlaufen durch die while-Schleife  
mit einem stabilen Matching.

Beweis:

(1) Ist eine Frau  $\overset{a}{\checkmark}$  irgendwann verheiratet,  
so bleibt sie es auch (gilt nicht  
für Männer)

Außerdem nimmt die Präferenz  
ihrer Partner nur zu:

$x_1 = \text{partner}(a)$  zum Zeitpunkt  $t_1$

$x_2 = \text{partner}(a)$  zum Zeitpunkt  $t_2 \geq t_1$

$\Rightarrow \text{präf}_a(x_2) \geq \text{präf}_a(x_1)$

D.h. in jedem Schleifen durchlauf  
heiratet eine Frau zum ersten mal,  
oder sie heiratet einen von ihr  
bevorzugten Partner.

(2) Gilt für einen Mann  $x$  irgendwann  
Kandidaten( $x$ ) =  $\emptyset$ , so muß der  
Algorithmus terminieren:

Kandidaten( $x$ ) =  $\emptyset \Rightarrow$

Alle Frauen sind verheiratet  
(wegen (1)).  $\Rightarrow$

Alle Männer sind verheiratet.

Da in jedem Schleifendurchlauf für einen Mann die Kandidatenmenge kleiner wird, und es am Anfang  $n$  Kandidatenmengen der Größe  $n$  gibt, folgt:

Proposal-Algorithmus terminiert nach höchstens  $n^2$  Schleifendurchläufen

(3) Behauptung: Das berechnete Matching ist stabil:

Annahme:  $(x, a)$  ist am Ende ein unzufriedenes Paar.  $\Rightarrow$

$$-\text{präf}_x(a) > \text{präf}_x(\underbrace{\text{partner}(x)}_{b})$$

$$-\text{präf}_a(x) > \text{präf}_a(\underbrace{\text{partner}(a)}_{y})$$

wegen  $\text{präf}_x(a) > \text{präf}_x(b)$  muß Mann  $x$  der Frau  $a$  ein Angetöt gemacht haben (etwa zum Zeitpunkt  $t$ ) bevor er Frau  $b = \text{partner}(x)$  geheiratet hat.

Dann muß

a) Frau  $a$  Mann  $x$  zum Zeitpunkt  $t$  geheiratet haben und sich später vom  $x$  geschieden haben ( $a$  ist am Ende mit  $y \neq x$  verheiratet)

oder

(b) Frau  $a$  zum Zeitpunkt  $t$  mit einem Mann  $z$  verheiratet gewesen sein, für den gilt  $\text{präf}_a(z) > \text{präf}_a(x)$

Im Fall (a) gilt wegen (1):

$$\text{präf}_a(x) \leq \text{präf}_a(y) \quad \begin{array}{l} \uparrow \\ \text{Partner von } a \\ \text{am Ende.} \end{array}$$

Im Fall (b) folgt analog mit (1):

$$\text{präf}_a(x) < \text{präf}_a(z) \leq \text{präf}_a(y) \quad \begin{array}{l} \uparrow \\ \square \end{array}$$

Im weiteren soll das Average-Case Verhalten des Proposal-Algorithmus betrachtet werden.

Annahme:

1. Die Präferenzlisten der Frauen sind fest aber beliebig gewählt.
2. Die Präferenzlisten der Männer werden zufällig und gleichverteilt gewählt.

Sei Zufallsvariable  $T_p :=$  Anzahl der Angebote von Männern an Frauen im Proposal-Algorithmus unter der oben genannten Inputverteilung.

### 1. Vereinfachung:

Anstatt die Präferenzlisten der Männer zu Beginn zufällig zu wählen, gehen wir davon aus, dass:

Im jedem Schritt ein Mann  $x$  eine Frau  $a$  zufällig aus Kandidaten( $x$ ) auswählt und  $a$  ein Angebot macht.

### Prinzip der verzögerten Entscheidung

Anstatt zu Beginn den gesamten Input zufällig zu wählen, legen wir in jedem Schritt nur soviel zufällig von der Eingabe frei, wie für die Durchführung

dieser Schritts notwendig ist.

2. Vereinfachung: Wir lassen den Schritt "Kandidaten( $x$ ) := Kandidaten( $x$ ) \ { $a$ }" im Proposal-Algorithmus weg.

D.h. in jedem Schritt wählt ein lediger Mann  $x$  zufällig und gleichverteilt eine Frau  $a$  aus und macht  $a$  ein Angebot.

Es ist dabei möglich, dass  $a$  den Mann  $x$  bereits zu einem früheren Zeitpunkt abgewiesen hat.

↳ vergessliche Algorithmus

Zufallsvariable  $T_V$  := Anzahl der Angebote von Männern an Frauen im vergesslichen Algorithmus.

### Beobachtungen

- Weist Frau  $a$  einen Mann  $x$  zum Zeitpunkt  $t$  ab, so wird sie dies auch zum Zeitpunkt  $t' > t$  tun.  
⇒ Proposal-Algorithmus und vergesslicher Algorithmus produzieren gleiches Matching.
- $E[T_p] \leq E[T_v]$   
 $\text{Prob}[T_p > m] \leq \text{Prob}[T_v > m]$
- Angenommen in einem Ablauf des vergesslichen Algorithmus hat zu einem gewissen Zeitpunkt jede Frau mindestens ein Angebot erhalten.  
⇒ Jede Frau ist verheiratet  
⇒ Jeder Mann ist verheiratet  
⇒ Algorithmus terminiert.

## Coupon-Sammler Problem

Gegeben:  $n$  Typen von Coupons. Seien  
die Typen  $1, 2, \dots, n$

In jedem Schritt wird ein Coupon  
eines zufällig und gleichverteilt aus-  
gewählten Typs gezogen.

Zufallsvariable  $X =$  Anzahl der  
Schritte, bis von jedem Typ mindestens  
ein Coupon gezogen wurde.

$$\hookrightarrow E[X] = E[T_V], \text{Prob}[X > m] = \text{Prob}[T_V > m]$$

Sei  $C_1, C_2, \dots, C_X$  die Folge der  
in jedem Schritt ausgewählten  
Coupons-Typen.

$$C_i \in \{1, \dots, n\}$$

- $C_i$  ist ein Erfolg, falls  
 $C_i \notin \{C_1, \dots, C_{i-1}\}$   
 $\hookrightarrow C_1$  und  $C_X$  sind Erfolge
- $C_i$  ist Erfolg  $\Leftrightarrow$  Im  $i$ -ten Schritt wird  
neuer Coupon-Typ  
ausgewählt.

- Seien  $C_{i_1}, C_{i_2}, \dots, C_{i_m}$  die Erfolge  
 $\overset{\parallel}{C_1} \quad \overset{\parallel}{C_X}$   
 $(1 = i_1 < i_2 < \dots < i_m = X)$

$$X_k := i_{k+1} - i_k \text{ für } 0 \leq k < m, \text{ wobei} \\ i_0 := 0$$

$X_k$  ist die Anzahl der Schritte nach  
dem  $k$ -ten Erfolg bis inklusive  
dem  $(k+1)$ -ten Erfolg.

$$\rightarrow \sum_{k=0}^{m-1} X_k = i_m - i_0 = X$$

$$\text{Prob}[X_k = l] = \left(1 - \frac{m-k}{m}\right)^{l-1} \left(\frac{m-k}{m}\right)$$

$$= q^{l-1} \cdot (1-q) \text{ für } q = 1 - \frac{m-k}{k} = \frac{k}{m}$$

(geometrische Verteilung)

$$\rightarrow E[X_k] = \sum_{l=1}^{\infty} q^{l-1} (1-q) \cdot l$$

$$= \sum_{l=0}^{\infty} q^l (l+1) - \sum_{l=1}^{\infty} q^l \cdot l$$

$$= \sum_{l=0}^{\infty} q^l = \frac{1}{1-q} = \frac{m}{m-k}$$

$$\Rightarrow E[X] = \sum_{k=0}^{m-1} E[X_k] = \sum_{k=0}^{m-1} \frac{m}{m-k} =$$

$$= m \cdot \sum_{k=0}^{m-1} \frac{1}{m-k} = m \cdot \sum_{k=1}^m \frac{1}{k} = m \cdot H_m$$

$$\Rightarrow E[X] \in m \cdot \cancel{\log}(m) + O(m)$$

Satz 1: Sei  $m$  = Anzahl verschiedener Coupon-Typen. Dann ist die mittlere Anzahl von Schritten, bis jeder Coupon-Typ mindestens einmal gezogen wurde  $\in m \cdot \cancel{\log}(m) + O(m)$

Korollar: Die mittlere Anzahl von Angeboten im Proposal-Algorithmus (bei zufällig ausgewählten Präferenzlisten für die Männer) ist  $\leq m \cdot \cancel{\log}(m) + O(m)$

Wie weit weicht  $X$  vom  $E[X]$  ab?

Satz 2: Sei  $m = \text{Anzahl der Coupon-Typen}$ ,  $X = \text{Anzahl der Schnitte bis vom jedem Typ mindestens ein Coupon gezogen wurde}$ . Sei  $c \in \mathbb{R}$  Konstante.

$$\text{Sei } m = n \cdot \ln(n) + c \cdot n$$

$$\Rightarrow \lim_{n \rightarrow \infty} \text{Prob}[X > m] = 1 - e^{-e^{-c}}$$

Zum Beweis von Satz 2 benötigen wir einige Hilfsmittel.

Lemma 1 Sei  $c \in \mathbb{R}$  eine Konstante und sei  $k \in \mathbb{N}$  fest gewählt.

$$\text{Sei } m = n \cdot \ln(n) + c \cdot n$$

$$\Rightarrow \lim_{n \rightarrow \infty} \binom{n}{k} \left(1 - \frac{k}{n}\right)^m = \frac{e^{-c \cdot k}}{k!}$$

### Beweis von Lemma 1

O.B.d.A sei  $k^2 \leq n$  um folgenden.  
Komstante

Für  $n \geq 1$ ,  $t \in \mathbb{R}$  mit  $|t| \leq n$  gilt

$$e^{-t} \cdot \left(1 - \frac{t^2}{n}\right) \leq \left(1 - \frac{t}{n}\right)^n \leq e^{-t} \quad (*)$$

Hieraus folgt:

$$\begin{aligned} \left(1 - \frac{t}{n}\right)^{\ln(n)} &= \left(1 - \frac{t}{n}\right)^n \cdot \frac{\ln(n)}{n} \\ &\geq \underbrace{e^{-t \cdot \frac{\ln(n)}{n}}}_{\rightarrow 1 \text{ für } n \rightarrow \infty} \cdot \underbrace{\left(1 - \frac{t^2}{n}\right)^{\frac{\ln(n)}{n}}}_{\rightarrow 1 \text{ für } n \rightarrow \infty} \quad (***) \end{aligned}$$

- Aus  $(*)$  folgt für  $\left(1 - \frac{k}{n}\right)^m = \left(1 - \frac{k}{n}\right)^{n \cdot \frac{m}{n}} = e^{-k \cdot \frac{m}{n}} \left(1 - \frac{k^2}{n}\right)^{\frac{m}{n}} \leq \left(1 - \frac{k}{n}\right)^m \leq e^{-k \cdot \frac{m}{n}}$

$$\bullet \text{Wegen } e^{-k \cdot \frac{m}{m}} = e^{-k \cdot (\ln(m) + c)} = \\ = \frac{1}{m^k} \cdot e^{-k \cdot c} \text{ folgt:}$$

$$\frac{e^{-k \cdot c}}{k!} \cdot \frac{m(m-1)\dots(m-k+1)}{m^k} \left(1 - \frac{k^2}{m}\right)^{\frac{m}{m}} \leq$$

$$\binom{m}{k} \cdot \left(1 - \frac{k}{m}\right)^m \leq$$

$$\cdot \frac{e^{-k \cdot c}}{k!} \frac{m(m-1)\dots(m-k+1)}{m^k} \quad (***)$$

$$\bullet \left(1 - \frac{k^2}{m}\right)^{\frac{m}{m}} = \left(1 - \frac{k^2}{m}\right)^{c + \ln(m)} = \\ \left(1 - \frac{k^2}{m}\right)^c \left(1 - \frac{k^2}{m}\right)^{\ln(m)} \stackrel{(**)}{\geq} \text{ mit } k^2 \leq m$$

$$\left(1 - \frac{k^2}{m}\right)^c \cdot e^{-k \cdot \frac{k^2 \ln(m)}{m}} \cdot \left(1 - \frac{k^4}{m}\right)^{\frac{\ln(m)}{m}}$$

Hieraus folgt mit (\*\*\*)

$$\underbrace{\frac{e^{-k \cdot c}}{k!} \cdot \frac{m \cdot \dots \cdot (m-k+1)}{m^k} \cdot \left(1 - \frac{k^2}{m}\right)^c \cdot e^{-k \cdot \frac{k^2 \ln(m)}{m}} \cdot \left(1 - \frac{k^4}{m}\right)^{\frac{\ln(m)}{m}}}_{\rightarrow 1 \text{ für } m \rightarrow \infty}$$

$$\leq \binom{m}{k} \cdot \left(1 - \frac{k}{m}\right)^m \leq$$

$$\underbrace{\frac{e^{-k \cdot c}}{k!} \cdot \frac{m \cdot \dots \cdot (m-k+1)}{m^k}}_{\rightarrow 1 \text{ für } m \rightarrow \infty}$$

$$\Rightarrow \lim_{m \rightarrow \infty} \binom{m}{k} \left(1 - \frac{k}{m}\right)^m = \frac{e^{-k \cdot c}}{k!}$$

□

## Inklusions-Exklusions-Prinzip

Seien  $\varepsilon_1, \dots, \varepsilon_m$  beliebige Ereignisse.

Dann gilt:

$$\text{Prob} \left[ \bigcup_{i=1}^m \varepsilon_i \right] = \sum_{k=1}^m (-1)^{k+1} \cdot P_k \quad \text{mit}$$

$$P_k = \sum_{1 \leq i_1 < i_2 < \dots < i_k \leq m} \text{Prob} \left[ \bigcap_{j=1}^k \varepsilon_{i_j} \right]$$

## Boole-Bonferroni-Ungleichung

$$\sum_{k=1}^{2l} (-1)^{k+m} \cdot P_k \leq \text{Prob} \left[ \bigcup_{i=1}^m \varepsilon_i \right] \leq$$

$$\sum_{k=1}^{2l+1} (-1)^{k+1} \cdot P_k \quad \text{falls } 2l+1 \leq m$$

## Beweis vom Satz 2:

- Sei  $\varepsilon_i^n$  das Ereignis, dass Coupon-Typ  $i$  nicht in den ersten  $n$  gezogen wird.

$$\text{Prob} [\varepsilon_i^n] = \left(1 - \frac{1}{m}\right)^n$$

- $X > m \Leftrightarrow \bigcup_{i=1}^m \varepsilon_i^m$

$$\text{Sei } P_K^m := \sum_{(k \leq m)} \text{Prob} \left[ \bigcap_{j=1}^k \varepsilon_{i_j}^m \right]$$

Symmetrie  $\rightarrow$

$$P_K^m = \binom{m}{k} \cdot \text{Prob} \left[ \bigcap_{j=1}^k \varepsilon_j^m \right]$$

$$\cdot = \binom{m}{k} \left(1 - \frac{1}{m}\right)^m$$

- Für jedes feste  $k \in \mathbb{N}$  gilt nach Lemma 2:

$$\lim_{n \rightarrow \infty} P_k^n = \frac{e^{-c \cdot k}}{k!} =: P_k$$

- Für  $l \leq m$  sei  $S_l^m := \sum_{j=1}^l (-1)^{j+1} \cdot P_j^n$

Boole-Bonferroni-Ungleichung  $\rightarrow$

$$(*) S_{2 \cdot l}^m \leq \text{Prob} \left[ \bigcup_{i=1}^m \varepsilon_i^m \right] \leq S_{2 \cdot l + 1}^m$$

- Für  $l \leq m$  sei  $S_l := \sum_{j=1}^l (-1)^{j+1} \cdot P_j$

$$= \sum_{j=1}^l (-1)^{j+1} \cdot \frac{e^{-c \cdot j}}{j!}$$

$$\rightarrow \lim_{l \rightarrow \infty} S_l = f(c) := 1 - e^{-(e^{-c})}$$

$\rightarrow$  Für jedes  $\varepsilon > 0$  existiert  $l^* > 0$  mit:

$$\forall l > l^*: |S_l - f(c)| < \varepsilon$$

- Wegen  $\lim_{n \rightarrow \infty} P_k^n = P_k$  (für jedes feste  $k$ )

gilt:  $\lim_{n \rightarrow \infty} S_l^n = S_l$  (für jedes feste  $l$ )

$\rightarrow$  Für jedes  $\varepsilon > 0$  und jedes  $l \in \mathbb{N}$  gilt  $|S_l^n - S_l| < \varepsilon$  für genügend große  $n$ .

$\rightarrow$  Für jedes  $\varepsilon > 0$  existiert  $l^* > 0$ , so dass für jedes feste  $l > l^*$  gilt:  $|S_l^n - f(c)| < 2 \cdot \varepsilon$

falls  $n$  genügend groß.

$\rightarrow |S_{2 \cdot l}^m - S_{2 \cdot l+1}^m| < 4 \cdot \varepsilon$  falls  
 $n$  genügend groß.

Mit (\*) ergibt sich:

$$\left| \underbrace{\text{Prob} \left[ \bigcup_{i=1}^m E_i^m \right]}_{\text{Prob}[X > m]} - f(c) \right| < 4\varepsilon$$

falls  $n$  genügend groß.

$$\rightarrow \lim_{n \rightarrow \infty} \text{Prob}[X > m] = f(c) = 1 - e^{-e^{-c}} \quad \square$$

Aus Satz 2 folgt für jedes  $c \in \mathbb{R}, c > 0$

$$\lim_{n \rightarrow \infty} \text{Prob}[X > n \cdot (\ln(n) + c)] = 1 - e^{-e^{-c}}$$

$$\lim_{n \rightarrow \infty} \text{Prob}[X \leq n \cdot (\ln(n) - c)] = e^{-e^c}$$

$$\begin{aligned} &\rightarrow \lim_{n \rightarrow \infty} \text{Prob}[n(\ln(n) - c) < X \leq n(\ln(n) + c)] \\ &= 1 - (1 - e^{-e^{-c}} + e^{-e^c}) \\ &= \underbrace{e^{-e^{-c}}} - \underbrace{e^{-e^c}} \\ &\text{geht sehr schnell gegen 1} \\ &\text{für große } c. \end{aligned}$$