

**Bachelor-Seminarvortrag** über das  
Kapitel 9 Approximate Counting

aus dem Buch *Finite Markov Chains and Algorithmic Applications*

von *Olle Häggström*

Verfasser: Julius Witte

Studiengang: 1-Fach Bachelor im 6. Semester

Dozent: Prof. Dr. Matthias Löwe

Datum: 06.05.2012

## Kapitel 9: Approximate Counting

Die Kombinatorik handelt von endlichen Objekten und Mengen, wobei wir uns hier mit Permutationen und Graphen beschäftigen. Die Hauptfragestellung ist dann immer die gleiche: *Wir haben eine Menge  $S$ . Welche Anzahl an Elementen besitzt diese?* Wir wollen nun folgendes Beispiel kennenlernen, welches uns durch das ganze Kapitel begleiten wird.

**Beispiel 9.1:** Sei  $q \in \mathbb{N}$  und  $G=(V,E)$  ein Graph. Wieviele  $q$ -Färbungen gibt es für  $G$ ?  $\rightarrow S$  entspricht der Menge der  $q$ -Färbungen auf  $G$ .

**Definition:** Ein Graph  $G=(V,E)$  besteht aus der Kantenmenge  $E$  und der Eckenmenge  $V$ . Falls eine Kante 2 Ecken miteinander verbindet, so heißen diese Nachbarn. 2 verschiedene Ecken können höchstens von einer Kante verbunden werden.

**Definition:** Eine  $q$ -Färbung ( $q \geq 2$ ) auf einem Graph  $G=(V,E)$  ist eine Anordnung von den Farben  $\{1, \dots, q\}$ , sodass kein Nachbar einer Ecke dieselbe Farbe annimmt wie die Ecke selbst. Die  $q$ -Färbungen sind gleichverteilt auf der Menge aller möglichen  $q$ -Färbungen auf  $G$ . Dann ist

$$p_{G,q}(\xi) = \begin{cases} \frac{1}{Z} & \xi \text{ ist } q\text{-Färbung auf } G, \\ 0 & \text{sonst.} \end{cases}$$

die Gleichverteilung, wobei  $Z$  der Anzahl aller  $q$ -Färbungen auf  $G$  entspricht.

Wir möchten uns in diesem Kapitel mit Algorithmen beschäftigen, die das Zählproblem aus Beispiel 9.1 lösen. Durch die folgende Betrachtung des *naiven Algorithmus* wollen wir eine Motivation für einen geeigneten und guten Algorithmus erreichen:

**Beispiel 9.2:** Beim *naiven Algorithmus* geht man wie folgt vor:

- man betrachtet alle  $q^k$  möglichen Konfigurationen  $\xi \in \{1, \dots, q\}^V$  auf  $G$
- falls  $\xi$  eine  $q$ -Färbung ist, macht man einen Strich
- am Ende zählt man alle Striche zusammen und erhält somit die Anzahl aller  $q$ -Färbungen auf  $G$

**Bemerkung:** Der naive Algorithmus liefert stets die exakte Anzahl, die Laufzeit jedoch wächst exponentiell, weil man jedes Mal  $q^k$  Konfigurationen überprüfen muss. Also ist er nur für kleine  $k$  bzw. kleine Graphen  $G$  geeignet.

Dies motiviert uns, schnellere Algorithmen zu finden. Deshalb betrachten wir nun einen Algorithmus mit polynomieller Laufzeit, das bedeutet, dass ihre Laufzeit durch ein Polynom  $p(k)$  für alle bel. Größen  $k$  des Zählproblems begrenzt ist. Wenn mit großer Wahrscheinlichkeit dieser existieren sollen, müssen wir natürlich auch eine geringere Genauigkeit in Kauf nehmen:

- gehe über vom Zählen zum Approximieren
- erlaube dem Algorithmus, unter einer bestimmten W'keit (erheblich) falsche Werte zu liefern

Wir kommen deshalb zu folgender Definition:

**Definition 9.3:** *Ein Algorithmus mit folgenden Eigenschaften heißt randomisiertes polynomielle-Zeit Approximations Schema:*

1. *der Algorithmus liefert mit mindestens  $\frac{2}{3}$  W'keit einen Wert zwischen  $(1 - \epsilon)N$  und  $(1 + \epsilon)N$ , wobei  $N$  das wahre Ergebnis des Zählproblems ist*
2.  *$\forall \epsilon > 0$  existiert ein Polynom  $p_\epsilon(k)$ , sodass für alle bel. Größen  $k$  des Zählproblems der Algorithmus nach maximal  $p_\epsilon(k)$  Schritten abbricht*

Warum fordert man ausgerechnet  $\frac{2}{3}$  W'keit? In Wahrheit ist nichts spezielles an  $\frac{2}{3}$ , man kann eigentlich jede beliebige Zahl aus  $(\frac{1}{2}, 1)$  wählen. Falls wir aber eine W'keit sehr nah an 1 fordern, so muss unser Algorithmus erheblich länger laufen und damit dieser mit den Eigenschaften aus Definition 9.3 existiert, muss man auch einen größeren Fehler  $\epsilon$  tolerieren.

Jetzt kommen wir zum Hauptteil des Kapitels:

**Theorem 9.4:** *Man habe feste  $q, d \in \mathbb{N}$ , sodass  $d \geq 2$  und  $q > 2d^2$ . Betrachte das Zählen von  $q$ -Färbungen auf einem Graph  $G$ , dessen Ecken jeweils höchstens  $d$  Nachbarn haben. Dann existiert ein randomisiertes polynomielle-Zeit Approximations Schema.*

**Bemerkung:**

- eine explizite Beschreibung des Algorithmus liefert der 1. Teil des Beweises. Im 2. Teil zeigt man daraufhin, dass genau dieser der Definition 9.3 genügt
- $d \geq 2$  ist keine ernste Einschränkung:

- 1.Fall:  $d = 0$   
Die Ecken haben keine Nachbarn.  
→ man hat  $q^k$  mögliche q-Färbungen
- 2.Fall:  $d = 1$   
Jede bel. Ecke hat also höchstens einen Nachbarn.  
→ Graph existiert nur aus:
  1.  $s$  isolierten Ecken, also solchen die keinen Nachbarn haben
  2.  $l$  Paaren von Ecken, die genau durch eine Kante verbunden sind
 → es gibt  $q^s q^l (q - 1)^l = q^{s+l} (q - 1)^l$  mögliche q-Färbungen

### 1. Teil des Beweises von Theorem 9.5:

Sei  $G=(V,E)$  ein Graph mit der Kantenmenge  $E = \{e_1, \dots, e_{\tilde{k}}\}$ . Da nach Annahme des Theorems von jeder Ecke höchstens  $d$  Kanten ausgehen können, folgt dann für insgesamt  $k$  Ecken, dass  $\tilde{k} \geq dk$ .

Definiere die Untergraphen  $G_j=(V, \{e_1, \dots, e_j\}) \forall j = 0, \dots, \tilde{k}$ . Insbesondere ist  $G = G_{\tilde{k}}$ .

Sei  $Z_j$  die Anzahl der q-Färbungen auf  $G_j \rightarrow$  wir suchen also  $Z_{\tilde{k}}$ .

Man schreibe  $Z_{\tilde{k}}$  durch das Teleskopprodukt um:

$$Z_{\tilde{k}} = \frac{Z_{\tilde{k}}}{Z_{\tilde{k}-1}} \cdot \frac{Z_{\tilde{k}-1}}{Z_{\tilde{k}-2}} \cdot \dots \cdot \frac{Z_1}{Z_0} \cdot Z_0. \quad (1)$$

Warum schreiben wir nun  $Z_{\tilde{k}}$  als Teleskopprodukt? Wir möchten einen Algorithmus finden der unser  $Z_{\tilde{k}}$  schätzt. Wenn wir also jeden Faktor einigermaßen genau schätzen können, so haben wir auch mit einer bestimmten Genauigkeit einen Schätzer für unser  $Z_{\tilde{k}}$ .

$G_0$  hat keine Kanten  $\rightarrow Z_0 = q^k$ .

Betrachte also alle Quotienten  $\frac{Z_j}{Z_{j-1}}$  für  $j = 1, \dots, \tilde{k}$ :

Seien  $x_j, y_j$  die Ecken, die die Kante  $e_j$  verbindet. Dann kommen wir jetzt zur wichtigsten Erkenntnis unseres Beweises:

*Die q-Färbungen auf  $G_j$  sind genau die q-Färbungen  $\xi$  auf  $G_{j-1}$ , welche  $\xi(x_j) \neq \xi(y_j)$  erfüllen.* Dabei beschreibt  $\xi(v)$  die Farbe der q-Färbung  $\xi$  an der Ecke  $v$ . Zur Erklärung der obigen Aussage:

Wenn wir eine q-Färbung auf  $G_{j-1}$  haben, bedeutet dies, dass die Bedingungen einer q-Färbung bzgl. der Kanten  $e_1, \dots, e_{j-1}$  erfüllt sind. Ecken, die noch durch keine Kante verbunden sind und somit auch keine Nachbarn haben, haben die Möglichkeit aus allen  $q$  Farben zu wählen. Fügen wir jetzt eine weitere Kante  $e_j$  bel. hinzu und erfüllen wir die Bedingung  $\xi(x_j) \neq \xi(y_j)$ , also dass die benachbarten Ecken  $x_j$  und  $y_j$  nicht die gleiche Farbe annehmen,

dann haben wir eine gültige q-Färbung bzgl. der Kanten  $e_1, \dots, e_j$  und somit eine auf  $G_j$ . Folglich beschreibt  $\frac{Z_j}{Z_{j-1}}$  den Anteil der q-Färbungen auf  $G_{j-1}$ , die  $\xi(x_j) \neq \xi(y_j)$  erfüllen.

Weiterhin ist  $p_{G_{j-1},q}(\xi) = \begin{cases} \frac{1}{Z_{j-1}} & \xi \text{ ist q-Färbung auf } G_{j-1}, \\ 0 & \text{sonst.} \end{cases}$

Nach obiger Aussage ist  $Z_j = |\{X \text{ ist q-Färbung auf } G_{j-1} | X(x_j) \neq X(y_j)\}|$

$$\Rightarrow \frac{Z_j}{Z_{j-1}} = p_{G_{j-1},q}(X(x_j) \neq X(y_j)). \quad (2)$$

Diese Gleichung liefert uns einen Algorithmus für  $\frac{Z_j}{Z_{j-1}}$ : Wir haben bereits gesehen, dass wir unsere Gleichverteilung  $p_{G_{j-1},q}$  mithilfe des *Gibbs sampler* schätzen können. Weil wir nun aber noch den Anteil der Konfigurationen  $X$  schätzen wollen, die  $X(x_j) \neq X(y_j)$  erfüllen, also eine q-Färbung auf  $G_j$  sind, gehen wir wie folgt vor:

1. starte Gibbs sampler in bel., aber fester Konfiguration  $\xi \in \{1, \dots, q\}^V$  und lasse ihn  $n$  Schritte laufen
2. wiederhole diese Simulation, also das Durchführen von 1., endlich oft und betrachte den Anteil der Endkonfigurationen, die q-Färbungen sind. Die Endkonfiguration ist dabei die Konfiguration die man im  $n$ -ten Schritt des Gibbs sampler erhält.

Wenn wir diesen Algorithmus also für alle  $j = 1, \dots, \tilde{k}$  durchführen, erhalten wir einen für  $Z_{\tilde{k}}$ . □

Für den 2. Teil des Beweises benötigen wir zuerst 3 Hilfslemmata:

**Lemma 9.5:**  $\epsilon \in [0, 1]$ ,  $k \in \mathbb{N}$  und  $a_1, \dots, a_k, b_1, \dots, b_k > 0$ , sodass

$$\left(1 - \frac{\epsilon}{2k}\right) \leq \frac{a_j}{b_j} \leq \left(1 + \frac{\epsilon}{2k}\right) \text{ für } j = 1, \dots, k.$$

Dann gilt für  $a = \prod_{i=1}^k a_i$  und  $b = \prod_{i=1}^k b_i$ , dass

$$(1 - \epsilon) \leq \frac{a}{b} \leq (1 + \epsilon).$$

**Beweis:** Man erkennt leicht, dass aus

$$\left(1 - \frac{\epsilon}{2k}\right)^2 \geq \left(1 - \frac{2\epsilon}{2k}\right)$$

$$\Rightarrow \left(1 - \frac{\epsilon}{2k}\right)^3 \geq \left(1 - \frac{\epsilon}{2k}\right) \left(1 - \frac{2\epsilon}{2k}\right) \geq \left(1 - \frac{3\epsilon}{2k}\right).$$

Führt man dies weiter fort, so erhält man

$$\left(1 - \frac{\epsilon}{2k}\right)^k \geq \left(1 - \frac{k\epsilon}{2k}\right).$$

Deswegen ist

$$\begin{aligned} \frac{a}{b} &= \prod_{j=1}^k \frac{a_j}{b_j} \geq \prod_{j=1}^k \left(1 - \frac{\epsilon}{2k}\right) = \left(1 - \frac{\epsilon}{2k}\right)^k \\ &\geq 1 - \frac{k\epsilon}{2k} = 1 - \frac{\epsilon}{2} \geq 1 - \epsilon. \end{aligned}$$

Für die zweite Ungleichung benutzen wir, dass  $\exp(x) \geq x + 1 \forall x \in \mathbb{R}$  und  $\exp\left(\frac{x}{2}\right) \leq x + 1 \forall x \in [0, 1]$ .

$$\begin{aligned} \Rightarrow \frac{a}{b} &= \prod_{j=1}^k \frac{a_j}{b_j} = \prod_{j=1}^k \left(1 + \frac{\epsilon}{2k}\right) \leq \prod_{j=1}^k \exp\left(\frac{\epsilon}{2k}\right) \\ &= \exp\left(\frac{\epsilon}{2}\right) \leq 1 + \epsilon. \end{aligned}$$

□

**Lemma 9.6:** Sei  $d, q \in \mathbb{N}$  mit  $d \geq 2$  und  $q > 2d^2$ . Sei  $G=(V,E)$  Graph, dessen Ecken jeweils nicht mehr als  $d$  Nachbarn haben. Dann gilt für zufällige  $q$ -Färbungen  $X$ , dass

$$p_{G,q}(X(x) \neq X(y)) \geq \frac{1}{2} \quad \forall x, y \in V.$$

**Beweis:** Seien o.B.d.A.  $x$  und  $y$  keine Nachbarn, da Nachbarn nie dieselbe Farbe haben dürfen und somit immer  $p_{G,q}(X(x) \neq X(y)) = 1$  ist. Betrachte zuerst die  $q$ -Färb.  $X(V - \{x\})$  auf allen Ecken außer  $x$  und dann erst die Farbe bei  $x$ :

$p_{G,q}$  gleichverteilt  $\rightarrow p_{G,q}(X(x) = \cdot | X(V - \{x\}))$  ist gleichverteilt auf allen Farben die kein Nachbar von  $x$  annimmt.

Wir können aus mind.  $q-d$  Farben bei  $x$  wählen, da wir höchstens  $d$  Nachbarn haben.

$\rightarrow p_{G,q}(X(x) = \cdot | X(V - \{x\})) \leq \frac{1}{q-d}$  für alle festen, aber bel.  $X(V - \{x\})$ .

Wir nehmen uns jetzt eine bel. Ecke  $y$  aus  $X(V - \{x\})$ , die kein Nachbar

von  $x$  ist. Wegen der Beliebigkeit von  $X(V - \{x\})$  können wir dann jede bel. Farbe bei  $y$  betrachten und es gilt stets:  $p_{G,q}(X(x) = X(y)) \leq \frac{1}{q-d}$ .

$$\begin{aligned} \Rightarrow p_{G,q}(X(x) \neq X(y)) &= 1 - p_{G,q}(X(x) = X(y)) \\ &\geq 1 - \frac{1}{q-d} \geq 1 - \frac{1}{2d^2 - d} \\ &= 1 - \frac{1}{(2d-1)d} \geq \frac{1}{2}. \end{aligned}$$

□

**Lemma 9.7:**  $n \in \mathbb{N}$ ,  $p \in [0, 1]$  fest und  $H_j \sim B(n, p)$ .

$$\Rightarrow \forall a > 0 \text{ gilt } \mathbb{P}(|H_j - np|) \leq \frac{n}{4a^2}.$$

**Beweis:** Wir wissen, dass  $\mathbb{E}[H] = np$  und  $\mathbb{V}(H) = np(1-p)$  ist. Mit der Chebyshev-Ungleichung gilt dann:

$$\mathbb{P}(|H - np| \geq a) \leq \frac{np(1-p)}{a^2} \leq \frac{n}{4a^2},$$

da  $p(1-p) \leq \frac{1}{4}$  ist  $\forall p \in [0, 1]$ . □

## 2. Teil des Beweises von Theorem 9.4:

Sei  $Y_j$  Algorithmus von  $\frac{Z_j}{Z_{j-1}}$  und  $Y = \prod_{i=1}^k Y_i$ . Dann ist  $Y^* = Y Z_0$  der gesuchte Algorithmus von  $Z_{\tilde{k}}$ .

Wir möchten nun, dass unser Algorithmus  $Y^*$  der Definition 9.3 genügt, aber nicht direkt mit diesem arbeiten, sondern mit den Faktoren  $Y_j$ . Deshalb müssen wir uns zum Beispiel fragen, welchen Fehler jeder Algorithmus  $Y_j$  für  $j = 1, \dots, \tilde{k}$  einhalten muss, damit unser  $Y^*$  den festgelegten Fehler  $\epsilon$  einhält. Das zeigen wir nun durch folgende Annahme:

Annahme: Falls

$$\left(1 - \frac{\epsilon}{2\tilde{k}}\right) \frac{Z_j}{Z_{j-1}} \leq Y_j \leq \left(1 + \frac{\epsilon}{2\tilde{k}}\right) \frac{Z_j}{Z_{j-1}} \quad \forall j = 1, \dots, \tilde{k} \quad (3)$$

gilt, dann ist auch

$$(1 - \epsilon) Z_{\tilde{k}} \leq Y^* \leq (1 + \epsilon) Z_{\tilde{k}}.$$

Beweis:

$$\begin{aligned} & \left(1 - \frac{\epsilon}{2\tilde{k}}\right) \frac{Z_j}{Z_{j-1}} \leq Y_j \leq \left(1 + \frac{\epsilon}{2\tilde{k}}\right) \frac{Z_j}{Z_{j-1}} \\ \Leftrightarrow & \left(1 - \frac{\epsilon}{2\tilde{k}}\right) \leq \frac{Y_j}{Z_j/Z_{j-1}} \leq \left(1 + \frac{\epsilon}{2\tilde{k}}\right) \end{aligned}$$

Mit Lemma 9.5 folgt dann

$$\begin{aligned} \Leftrightarrow & (1 - \epsilon) \leq \frac{Y}{\prod_{j=1}^{\tilde{k}} \frac{Z_j}{Z_{j-1}}} \leq (1 + \epsilon) \\ \Leftrightarrow & (1 - \epsilon) \leq \frac{Y Z_0}{Z_{\tilde{k}}} \leq (1 + \epsilon) \\ \Leftrightarrow & (1 - \epsilon) Z_{\tilde{k}} \leq Y^* \leq (1 + \epsilon) Z_{\tilde{k}}. \end{aligned}$$

Also haben wir jetzt eine Schranke an unser  $Y_j$ , welche wir noch etwas umschreiben und verschärfen wollen. Aus (3) ergibt sich

$$-\frac{\epsilon}{2\tilde{k}} \frac{Z_j}{Z_{j-1}} \leq Y_j - \frac{Z_j}{Z_{j-1}} \leq \frac{\epsilon}{2\tilde{k}} \frac{Z_j}{Z_{j-1}}.$$

Aus (2) und Lemma 9.6 folgt

$$\begin{aligned} \frac{Z_j}{Z_{j-1}} &= p_{G_{j-1}, q}(X(x_j) \neq X(y_j)) \geq \frac{1}{2} \\ \Rightarrow & \frac{\epsilon}{4\tilde{k}} \leq \frac{\epsilon}{2\tilde{k}} \frac{Z_j}{Z_{j-1}}. \end{aligned}$$

Falls also

$$\left| Y_j - \frac{Z_j}{Z_{j-1}} \right| \leq \frac{\epsilon}{4\tilde{k}} \quad \forall j = 1, \dots, \tilde{k} \quad (4)$$

gilt, dann erfüllt  $Y_j$  für alle  $j$  auch die Schranke aus (3).

Betrachten wir jetzt nochmal den Vorgang unseres Algorithmus für  $Y_j$ , dann stoßen wir auf folgende 2 Fehlerquellen:

1. Wir lassen den Gibbs sampler endlich viele Schritte  $n$  laufen, sodass die Verteilung  $\mu^{(n)}$ , die die Färbung im  $n$ -ten Schritt erzeugt, sich von der stationären Verteilung  $p_{G_{j-1}, q}$  unterscheiden kann.



2. Wir führen nur endlich viele Simulationen durch, sodass sich der Anteil der q-Färbungen  $Y_j$  von dem zu erwartenden Wert  $\mu^{(n)}(X(x_j) \neq X(y_j))$  unterscheiden kann. Dies lässt sich gut mit einem Münzwurf vergleichen: Wenn wir eine faire Münze 100-mal werfen, dann werden wir auch nicht immer 50-mal Kopf sehen.

Um (4) weiterhin einzuhalten, teilen wir den Fehler gleichmäßig auf:

$$\Rightarrow |\mu^{(n)}(X(x_j) \neq X(y_j)) - p_{G_{j-1},q}(X(x_j) \neq X(y_j))| \leq \frac{\epsilon}{8\tilde{k}} \quad (5)$$

$$|Y_j - \mu^{(n)}(X(x_j) \neq X(y_j))| \leq \frac{\epsilon}{8\tilde{k}} \quad (6)$$

(I) *Wieviele Schritte  $n$  benötigt der Gibbs sampler, damit (5) erfüllt ist?*

Als erstes betrachten wir den Zusammenhang zur *Total-Variation*:

$$\begin{aligned} & |\mu^{(n)}(X(x_j) \neq X(y_j)) - p_{G_{j-1},q}(X(x_j) \neq X(y_j))| \\ & \leq \max_{A \subseteq \{1, \dots, q\}^V} |\mu^{(n)}(A) - p_{G_{j-1},q}(A)| \\ & = d_{TV}(\mu^{(n)}, p_{G_{j-1},q}). \end{aligned}$$

Es genügt also ein  $n \in \mathbb{N}$  zu finden, sodass  $\forall m \geq n$  gilt:

$$d_{TV}(\mu^{(m)}, p_{G_{j-1},q}) \leq \frac{\epsilon}{8\tilde{k}}.$$

Dieses  $n$  liefert uns das Theorem 8.1 aus dem letzten Vortrag:

$$n = k \left( \frac{\log k + \log \frac{8\tilde{k}}{\epsilon} - \log d}{\log \frac{q}{2d^2}} + 1 \right),$$

mit  $\tilde{k} \leq dk$  folgt

$$\begin{aligned} n & \leq k \left( \frac{\log k + \log \frac{8dk}{\epsilon} - \log d}{\log \frac{q}{2d^2}} + 1 \right) \\ & = k \left( \frac{2 \log k + \log \frac{1}{\epsilon} + \log 8}{\log \frac{q}{2d^2}} + 1 \right). \end{aligned}$$

(II) *Wieviele Simulationen  $m$  benötigen wir, um (6) zu erfüllen?*

Denken wir nochmal an die Definition 9.3 zurück. Dort wird gefordert, dass der Algorithmus mit mindestens  $\frac{2}{3}$  W'keit unseren festgelegten Fehler  $\epsilon$  einhält. Über den erlaubten Fehler  $\epsilon$  von  $Y^*$  sind wir schon an die Schranke (3)

für jedes  $Y_j$  gekommen. Wir benötigen nun noch die W'keit mit der jedes  $Y_j$  ihre Schranke einhält.

Damit unser  $Y^*$  mit höchstens  $\frac{1}{3}$  W'keit außerhalb des multiplikativen Fehlerbereichs  $(1 - \epsilon, 1 + \epsilon)$  liegt, darf jedes  $Y_j$  höchstens mit  $\frac{1}{3\tilde{k}}$  W'keit ihre Schranke nicht einhalten, denn  $Y^*$  besteht, wie wir wissen, aus den  $\tilde{k}$  Faktoren  $Y_j$  für  $j = 1, \dots, \tilde{k}$ . Das werden wir gleich noch ausnutzen:

Weiterhin soll  $H_j$  die Anzahl der Endkonfigurationen angeben, die q-Färbungen sind  $\rightarrow Y_j = \frac{H_j}{m}$ .

Außerdem ist  $p = \mu^{(n)}(X(x_j) \neq X(y_j))$  die zu erwartende W'keit, dass eine zufällige Konfiguration  $X$  eine q-Färbung ist. Wenn man sich die Analogie zum Münzwurf ins Gedächtnis ruft, dann sieht man, dass  $H_j \sim B(m, p)$ . Aus (6) folgt schließlich:

$$\begin{aligned} \left| \frac{H_j}{m} - p \right| &\leq \frac{\epsilon}{8\tilde{k}} \\ \Leftrightarrow |H_j - mp| &\leq \frac{m\epsilon}{8\tilde{k}}. \end{aligned}$$

Wir betrachten jetzt die W'keit, dass diese Schranke nicht eingehalten wird, und benutzen unser Lemma 9.7:

$$\Rightarrow \mathbb{P} \left( |H_j - mp| > \frac{m\epsilon}{8\tilde{k}} \right) \leq \frac{m}{4 \left( \frac{m\epsilon}{8\tilde{k}} \right)^2} = \frac{16\tilde{k}^2}{\epsilon^2 m}.$$

Nun verwenden wir noch, was wir uns anfangs überlegt haben: Die W'keit, dass unser  $Y_j$  nicht die Schranke einhält, darf höchstens  $\frac{1}{3\tilde{k}}$  betragen:

$$\Rightarrow \frac{16\tilde{k}^2}{\epsilon^2 m} = \frac{1}{3\tilde{k}}$$

und Umstellen nach  $m$  und Einsetzen von  $\tilde{k} \leq dk$  liefert

$$m = \frac{48\tilde{k}^3}{\epsilon^2} \leq \frac{48d^3k^3}{\epsilon^2}.$$

Zum Schluss müssen wir noch unsere Ergebnisse zusammentragen und schauen, ob der Algorithmus  $Y^*$ , sowie wir ihn im ersten Teil des Beweises beschrieben haben, auch wirklich ein *randomisiertes polynomielle-Zeit Approximations Schema* ist. Wir haben herausgefunden, dass unsere Simulationslaufzeit  $n$  und die Anzahl der Simulationen  $m$  von  $k$  und  $\epsilon$  abhängen. Außerdem ist die Anzahl der Algorithmen  $Y_j$  nur von  $k$  abhängig, denn wir

wissen, dass  $\tilde{k} \leq dk$ . Die Gesamtanzahl der Schritte für den Algorithmus  $Y^*$  ist daher höchstens

$$dk \cdot \frac{48d^3 k^3}{\epsilon^2} \cdot k \left( \frac{2 \log k + \log \frac{1}{\epsilon} + \log 8}{\log \frac{q}{2d^2}} + 1 \right).$$

Dies ist von der Ordnung  $Ck^5 \log k$  für  $k \rightarrow \infty$  und eine von  $k$  unabhängige Konstante  $C$ . Da der  $\log k \leq k$  ist, ist die Ordnung sogar geringer als  $Ck^6$ . Folglich haben wir ein Polynom  $p_\epsilon(k)$  gefunden, das die Laufzeit des Algorithmus  $Y^*$  begrenzt. Also ist unser Algorithmus aus dem ersten Teil des Beweises ein *randomisiertes polynomielle-Zeit Approximations Schema*.  $\square$