

Big Data Analytics in Theorie und Praxis

Prof. Johann-Christoph Freytag, Ph.D. und Prof. Dr. Nicole Schweikardt
Sommersemester 2015

Theorie-Übungsblatt 2

Zu bearbeiten bis 25. Juni 2015

Aufgabe 1:

(4 + 6 + 10 + 5 = 25 Punkte)

Seien G_n und G'_k zwei vollständige gerichtete Graphen mit je n bzw. k Knoten, deren Knotenmengen disjunkt sind. D.h.

- $G_n = (V_n, E_n)$ mit $V_n = \{x_1, x_2, \dots, x_n\}$ und $E_n = \{(x_i, x_j) : i, j \in \{1, \dots, n\}\}$,
- $G'_k = (V'_k, E'_k)$ mit $V'_k = \{y_1, y_2, \dots, y_k\}$ und $E'_k = \{(y_i, y_j) : i, j \in \{1, \dots, k\}\}$,
- $V_n \cap V'_k = \emptyset$, $|V_n| = n$ und $|V'_k| = k$.

Sei nun G die Vereinigung der beiden vollständigen Graphen G_n und G'_k mit einer zusätzlichen Kante von x_1 nach y_1 , d.h.

- $G = (V, E)$ mit $V = V_n \cup V'_k$ und $E = E_n \cup E'_k \cup \{(x_1, y_1)\}$.

- (a) Bestimmen Sie für alle Knoten aus G die Page-Ranks für den Dämpfungsfaktor $d = 0$.
- (b) Bestimmen Sie für alle Knoten aus G die Page-Ranks für den Dämpfungsfaktor $d = 1$.
- (c) Sei nun d ein beliebiger Dämpfungsfaktor mit $0 < d < 1$. Geben Sie die Knoten von G sortiert nach der Größe ihrer Page-Ranks an (je höher der Page-Rank ist, desto weiter vorn soll der Knoten in Ihrer Sortierung stehen). Begründen Sie Ihre Antwort.
- (d) Betrachten Sie nun den etwas allgemeineren Fall, dass G_n und G'_k beliebige *stark zusammenhängende* gerichtete Graphen auf den Knotenmenge $V_n = \{x_1, \dots, x_n\}$ und $V'_k = \{y_1, \dots, y_k\}$ sind. Der Graph G sei wie oben als die Vereinigung der beiden Graphen G_n und G'_k mit einer zusätzlichen Kante von x_1 nach y_1 definiert.

Welche Aussage können Sie für diesen Graphen G und einen beliebigen Dämpfungsfaktor d mit $0 < d < 1$ über den durchschnittlichen Page-Rank der Knoten aus V_n im Vergleich zu dem durchschnittlichen Page-Rank der Knoten aus V'_k treffen? Begründen Sie Ihre Aussage.

Aufgabe 2:**(13 + 12 = 25 Punkte)**

Ein Anbieter einer Internetseite w möchte seiner Webseite zu einem höheren Page-Rank verhelfen. Sei $0 < d < 1$ der Dämpfungsfaktor und sei n die Gesamtzahl der Internetseiten inklusive w . Wir gehen in dieser Aufgabe davon aus, dass w nur auf sich selbst verlinkt.

- (a) In einem ersten Versuch legt der Anbieter $c \geq 1$ neue Seiten an, die alle ausschließlich auf die Seite w verweisen. Zeigen Sie, dass sich der Page-Rank der Seite w dadurch um maximal $(d - \frac{1}{n}) \cdot \frac{c}{n+c}$ erhöht, d.h.: wenn die Webseite w vorher den Page-Rank p_w hatte, so hat sie nach dem Hinzufügen der c Seiten einen Page-Rank von höchstens $p_w + (d - \frac{1}{n}) \cdot \frac{c}{n+c}$. Gehen Sie dabei der Einfachheit halber von der Annahme aus, dass sich bei jeder der $n - 1$ ursprünglich außer w vorhandenen Webseiten der Page-Rank nicht erhöht (diese Annahme müssen Sie nicht beweisen).
- (b) Als Alternative überlegt der Anbieter, zusätzlich noch Links zwischen den c neu angelegten Seiten einzufügen, so dass die c neuen Seiten einen vollständigen gerichteten Graphen bilden (Definition siehe Aufgabe 1). Ist dies eine gute Idee? Begründen Sie Ihre Antwort.

Aufgabe 3:**(25 Punkte)**

In der Vorlesung wurde die „Suche nach der fehlenden Zahl“ betrachtet, bei der man als Eingabe einen Datenstrom von $n - 1$ unterschiedlichen Zahlen aus der Menge $\{1, 2, \dots, n\}$ erhält, bei dem diese $n - 1$ Zahlen eine beliebige Reihenfolge haben können. Ziel ist, die fehlende Zahl aus der Menge $\{1, 2, \dots, n\}$ zu ermitteln. In der Vorlesung wurde ein Algorithmus vorgestellt, der höchstens $\lceil 2 \log n \rceil$ Speicherbits benötigt. Und es wurde gezeigt, dass *jeder* Algorithmus, der das Problem löst, mindestens $\lceil \log n \rceil$ Speicherbits benötigt. Schließen Sie die Lücke zwischen der unteren Schranke $\lceil \log n \rceil$ und der oberen Schranke $\lceil 2 \log n \rceil$ der zur Problemlösung benötigten Speicherbits. D.h.: Geben Sie für jede natürliche Zahl $n \geq 1$ eine geeignete natürliche Zahl $s(n)$ an und

- beschreiben Sie einen Datenstromalgorithmus, der bei Eingabe eines Stroms von $n - 1$ verschiedenen Zahlen aus $\{1, \dots, n\}$ die fehlende Zahl berechnet und dafür höchstens $s(n)$ Speicherbits benutzt,
- weisen Sie nach, dass Ihr Algorithmus tatsächlich die fehlende Zahl korrekt bestimmt und höchstens $s(n)$ Speicherbits benutzt, und
- beweisen Sie, dass es keinen Datenstromalgorithmus geben kann, der das Problem löst und dazu mit weniger als $s(n)$ Speicherbits auskommt.

Aufgabe 4:**(25 Punkte)**

Betrachten Sie nun die „Suche nach 2 fehlenden Zahlen“, bei der man als Eingabe einen Datenstrom von $n - 2$ unterschiedlichen Zahlen aus der Menge $\{1, 2, \dots, n\}$ erhält, bei dem diese $n - 2$ Zahlen eine beliebige Reihenfolge haben können. Ziel ist, die beiden fehlenden Zahlen aus der Menge $\{1, 2, \dots, n\}$ zu ermitteln.

- Beschreiben Sie einen Datenstromalgorithmus, der die beiden fehlenden Zahlen bestimmt und dabei möglichst wenig Speicher benutzt.
- Weisen Sie nach, dass Ihr Algorithmus die beiden fehlenden Zahlen korrekt bestimmt.
- Wie viele Speicherbits benötigt Ihr Algorithmus?
- Beweisen Sie, dass *jeder* Datenstromalgorithmus, der dieses Problem löst, mindestens $\lceil \log \binom{n}{2} \rceil$ Speicherbits benutzt.