

Fortgeschrittene Netzwerk- und Graph-Algorithmen

Prof. Dr. Hanjo Täubig

Lehrstuhl für Effiziente Algorithmen
(Prof. Dr. Ernst W. Mayr)
Institut für Informatik
Technische Universität München

Wintersemester 2010/11



Approximation von Zentralitätsindizes

- Obwohl die behandelten Zentralitätsindizes in polynomieller Zeit berechnet werden können, heißt das nicht unbedingt, dass die entsprechenden Algorithmen in der Praxis anwendbar sind.
 - Beispiel:
Betweenness-Zentralität für die Knoten des Web-Graphen lässt sich selbst mit dem Algorithmus von Brandes nicht in akzeptabler Zeit berechnen.
- ⇒ Möglichst wenige Traversierungen bzw. SSSP-Durchläufe auf dem Graphen
- ⇒ Näherungslösungen mit möglichst geringer Abweichung (mit hoher Wahrscheinlichkeit)

Approximation von Closeness

- Closeness:

$$c_C(v) = \frac{1}{\sum_{w \in V} d(v, w)}$$

- Approximation: wähle k andere Knoten $v_1, \dots, v_k \in V$

$$\hat{c}_C(v) = \frac{k}{n} \frac{1}{\sum_{i=1}^k d(v, v_i)}$$

- Vorgehen (Eppstein / Wang):

- 1 Wähle k Knoten v_1, \dots, v_k gleichverteilt zufällig
- 2 Löse für jeden Knoten v_i das SSSP mit diesem Knoten als Startknoten und
- 3 berechne für jeden Knoten $v \in V$ die Zentralität

$$\hat{c}_C(v) = \frac{k}{n \cdot \sum_{i=1}^k d(v, v_i)}$$

Hoeffdings Ungleichung

Satz (Hoeffdings Ungleichung)

Seien X_1, \dots, X_k unabhängige Zufallsvariablen mit $a_i \leq X_i \leq b_i$ und $\mu = \mathbb{E} \left[\sum_{i=1}^k X_i / k \right]$ der erwartete Durchschnitt. Dann gilt

$$\Pr \left\{ \left| \frac{\sum_{i=1}^k X_i}{k} - \mu \right| \geq \xi \right\} \leq 2 \cdot e^{-2k^2 \xi^2 / \sum_{i=1}^k (b_i - a_i)^2}$$

bzw. im Fall $a_i = a, b_i = b (\forall i)$

$$\Pr \left\{ \left| \frac{\sum_{i=1}^k X_i}{k} - \mu \right| \geq \xi \right\} \leq 2 \cdot e^{-2k \xi^2 / (b-a)^2}$$

Anwendung der Hoeffding-Ungleichung

Setze

$$X_i = n \cdot \frac{d(v_i, u)}{n-1}$$

$$\mu = \frac{1}{c_C(v)}$$

$$a_i = 0$$

$$b_i = \frac{n \cdot \text{diam}(G)}{n-1}$$

Anwendung der Hoeffding-Ungleichung

$$\begin{aligned}
 \Pr \left\{ \left| \frac{\sum_{i=1}^k X_i}{k} - \mu \right| \geq \xi \right\} &\leq 2 \cdot e^{-2k^2\xi^2 / \sum_{i=1}^k (b_i - a_i)^2} \\
 &= 2 \cdot e^{-2k^2\xi^2 / \left(k \left(\frac{n \cdot \text{diam}(G)}{n-1} \right)^2 \right)} \\
 &= 2 \cdot e^{-\Omega(k\xi^2 / \text{diam}(G)^2)}
 \end{aligned}$$

- Wähle $\xi = \epsilon \cdot \text{diam}(G)$
 - $k = \Theta\left(\frac{\log n}{\epsilon^2}\right)$ SSSP-Läufe
- ⇒ Wahrscheinlichkeit, einen Fehler größer als $\epsilon \cdot \text{diam}(G)$ zu machen ist höchstens $\frac{1}{n}$ für jeden Wert

Laufzeit der Closeness-Approximation

- Komplexität eines SSSP-Laufs
 - ▶ $\mathcal{O}(m + n)$ in ungewichteten Graphen
 - ▶ $\mathcal{O}(m + n \log n)$ in gewichteten Graphen
 - Komplexität von k SSSP-Läufen
 - ▶ $\mathcal{O}(k \cdot (m + n))$ in ungewichteten Graphen
 - ▶ $\mathcal{O}(k \cdot (m + n \log n))$ in gewichteten Graphen
- ⇒ Komplexität von $\Theta\left(\frac{\log n}{\epsilon^2}\right)$ SSSP-Läufen
- ▶ $\mathcal{O}\left(\frac{\log n}{\epsilon^2} \cdot (m + n)\right)$ in ungewichteten Graphen
 - ▶ $\mathcal{O}\left(\frac{\log n}{\epsilon^2} \cdot (m + n \log n)\right)$ in gewichteten Graphen

Approximation von Betweenness

- gewichtete gerichtete Graphen
- wähle wieder k Knoten zufällig (gleichverteilt) aus
- Berechne für jeden Startknoten v_i die totalen Abhängigkeiten $\delta_{v_i^*}(v)$ aller anderen Knoten v

- Berechne

$$\hat{c}_B(v) = \sum_{i=1}^k \frac{n}{k} \cdot \delta_{v_i^*}(v)$$

- $\mathbb{E}[\hat{c}_B(v)] = c_B(v)$ für alle k und v

Anwendung der Hoeffding-Ungleichung

Setze

$$X_i = n \cdot \delta_{v_i^*}$$

$$\mu = c_B(v)$$

$$a_i = 0$$

$$b_i = n(n-2)$$

$\delta_{v_i^*}$ kann höchstens $n-2$ sein, und zwar wenn alle kürzesten Pfade, die von v_i ausgehen, über v laufen. Also ist X_i durch $n(n-2)$ begrenzt.

Anwendung der Hoeffding-Ungleichung

$$\begin{aligned}\Pr \{|\hat{c}_B(v) - c_B(v)| \geq \xi\} &\leq 2 \cdot e^{-2k^2\xi^2 / \sum_{i=1}^k (b_i - a_i)^2} \\ &= 2 \cdot e^{-2k^2\xi^2 / (k(n(n-2)))^2} \\ &= 2 \cdot e^{-2k\xi^2 / (n(n-2))^2}\end{aligned}$$

- Wähle $\xi = \epsilon \cdot n(n-2)$
 - $k = \Theta\left(\frac{\log n}{\epsilon^2}\right)$ Startknoten / Läufe
- ⇒ Wahrscheinlichkeit, einen Fehler größer als $\epsilon \cdot n(n-2)$ zu machen ist höchstens $\frac{1}{n}$ für jeden Wert

Laufzeit der Betweenness-Approximation

- Komplexität eines Laufs (für $\delta_{v_i^*}(v)$)
 - ▶ $\mathcal{O}(m + n)$ in ungewichteten Graphen
 - ▶ $\mathcal{O}(m + n \log n)$ in gewichteten Graphen
 - Komplexität von k Läufen
 - ▶ $\mathcal{O}(k \cdot (m + n))$ in ungewichteten Graphen
 - ▶ $\mathcal{O}(k \cdot (m + n \log n))$ in gewichteten Graphen
- ⇒ Komplexität von $\Theta\left(\frac{\log n}{\epsilon^2}\right)$ Läufen
- ▶ $\mathcal{O}\left(\frac{\log n}{\epsilon^2} \cdot (m + n)\right)$ in ungewichteten Graphen
 - ▶ $\mathcal{O}\left(\frac{\log n}{\epsilon^2} \cdot (m + n \log n)\right)$ in gewichteten Graphen

Ergebnis

- Gewinn: k anstatt n SSSP-artige Läufe

- Verfahren des normalisierten Durchschnitts basierend auf zufälligem Knoten-Sampling läßt sich auf viele andere Zentralitäten übertragen