

Random-Radius Ball Method for Estimating Closeness Centrality

(appeared in *AAAI'17*)

稻荷場 涉 (東京大学)

秋葉 拓哉 (PFN)

吉田 悠一 (NII & PFI)

中心性 (Centrality)

複雑ネットワークの解析でしばしば気になるのが:

Q. どの頂点がより中心的(重要)な役割を持っているか?

Q. ある頂点の影響力は?

→ 頂点の重要性を測る指標を**中心性**と呼ぶ

ツイート	フォロー	フォロワー	いいね
8,609	205	101,658,554	5,644

KATY PERRY ✓
@katyperry

ツイート ツイートと返信 メディア

📌 固定されたツイート

[<https://twitter.com/katyperry>]

中心性 (Centrality)

複雑ネットワークの解析でしばしば気になるのが:

Q. どの頂点がより中心的(重要)な役割を持っているか?

Q. ある頂点の影響力は?

→ 頂点の重要性を測る指標を**中心性**と呼ぶ

- ▶ Classic closeness centrality
[Bavelas J. *Acoust. Soc. Am.* '50]
- ▶ Kats centrality [Kats *Psychometrika* '54]
- ▶ Betweenness centrality
[Anthonisse '71] [Freeman *Sociometry* '77]
- ▶ PageRank
[Brin-Page *Comput. Networks ISDN* '98]
- ▶ Harmonic centrality
[Opsahl-Agneessens-Skvoretz *Soc. Networks* '10]
[Boldi-Vigna *Internet Math.* '14]



[<http://www.cise.ufl.edu/research/sparse/matrices/SNAP/soc-LiveJournal1.html>]

中心性 (Centrality)

複雑ネットワークの解析でしばしば気になるのが:

Q. どの頂点がより中心的(重要)な役割を持っているか?

Q. ある頂点の影響力は?

→ 頂点の重要性を測る指標を**中心性**と呼ぶ

▶ Classic closeness centrality

[Bavelas J. *Acoust. Soc. Am.* '50]

▶ Kats centrality [Kats *Psychometrika* '54]

▶ Betweenness centrality
[Anthonisse '71] [Freeman *Sociometry* '77]

▶ PageRank
[Brin-Page *Comput. Networks ISDN* '98]

▶ Harmonic centrality
[Opsahl-Agneessens-Skvoretz *Soc. Networks* '10]
[Boldi-Vigna *Internet Math.* '14]

$$C_{cc}(v) := \frac{1}{\sum_u d(u, v)}$$

他のすべての頂点からの
距離の総和

(強)連結でない
グラフの扱い...?

$d(u, v) := u$ から v への距離

中心性 (Centrality)

複雑ネットワークの解析でしばしば気になるのが:

Q. どの頂点がより中心的(重要)な役割を持っているか?

Q. ある頂点の影響力は?

→ 頂点の重要性を測る指標を**中心性**と呼ぶ

▶ Classic closeness centrality

[Bavelas *J. Acoust. Soc. Am.* '50]

▶ Kats centrality [Kats *Psychometrika* '54]

▶ Betweenness centrality
[Anthonisse '71] [Freeman *Sociometry* '77]

▶ PageRank
[Brin-Page *Comput. Networks ISDN* '98]

▶ **Harmonic centrality**

[Opsahl-Agneessens-Skvoretz *Soc. Networks* '10]

[Boldi-Vigna *Internet Math.* '14]

$$C_{cc}(v) := \frac{1}{\sum_u d(u, v)}$$



より洗練された定義

$$C(v) := \sum_u \frac{1}{d(u, v)}$$

$d(u, v) := u$ から v への距離

問題定義

$$\text{調和中心性 (Harmonic centrality): } C(v) := \sum_u \frac{1}{d(u, v)}$$

Goal: 全頂点の $C(v)$ の計算

全頂点の $C(v)$ が得られれば, 次は容易に計算可能

- ▶ 頂点ランキングの作成 (または top- k 頂点の検出)
- ▶ 各頂点に対する中心性クエリへの応答

ところが... ナイーブな実装は $O(nm)$ -時間を要する

- ▶ 今日の巨大ネットワークでは動作しない n: 頂点数, m: 辺数

➡ **高速な近似アルゴリズムが求められる**

貢献

Random-Radius Ball (RRB) 法

- ▶ 調和中心性に対する新たな近似アルゴリズムを提案

RRB法の基本部

精度パラメータを
明示的に指定できない

ブートストラップ

指定の精度を満たすまで
RRB法の基本部を繰り返す



- ▶ 理論的解析: 計算量および近似に関する誤差保証
- ▶ 実データを用いた実験

$$C_\alpha(v) := \sum_u \alpha(d(u, v))$$

$\alpha(x) \geq 0$ かつ $\alpha(\infty) = 0$ を
満たす単調減少関数

調和中心性以外の指標にも適用可能:

- ▶ $\alpha(x) = 1/x$: 調和中心性
- ▶ $\alpha(1) = 1, \alpha(2) = 0$: 頂点の次数

既存手法との比較

調和中心性の推定が行える既存手法は2つ:

HyperBall [Boldi-Vigna *ICDMW '13*]

- ▶ 実験的に高速 / HyperLogLog データ構造を利用
[Flajolet et al. *AofA '07*]

All-Distances Sketches (ADS) [Cohen *TKDE '15*]

- ▶ さまざまな指標を理論保証付きで推定可能

	低い メモリ使用量	誤差に関する 理論保証	実装の容易さ
RRB法 (提案手法)	✓	✓	✓
HyperBall	✓	-	-
All-Distances Sketches	-	✓	✓


Random-Radius Ball (RRB) 法

入力: グラフ $G = (V, E)$, パラメータ $0 < t \leq 1$.

foreach vertex $u \in V$ do

$\tau \leftarrow \left\lfloor \frac{t}{\text{rand}()} \right\rfloor$. (rand() は $(0, 1]$ の一様な乱数を返すものとする)

頂点 u から 深さ τ の BFS を行い, 訪れた頂点をマーク.



u からの BFS が v を訪れる確率が $\frac{t}{d(u,v)}$ となるように設定

▶ $\text{rand}() \in (0, \frac{t}{d(u,v)}]$ のとき $\tau \geq d(u,v)$.

なぜ BFS を途中で打ち切るのか?

近い頂点の個数を正確に推定したい
遠い頂点の個数の見積もりは雑でも良い

Random-Radius Ball (RRB) 法

入力: グラフ $G = (V, E)$, パラメータ $0 < t \leq 1$.

foreach vertex $u \in V$ **do**

$\tau \leftarrow \lfloor \frac{t}{\text{rand}()} \rfloor$. (rand() は $(0, 1]$ の一様な乱数を返すものとする)


頂点 u から 深さ τ の BFS を行い, 訪れた頂点をマーク.

u からの BFS が v を訪れる確率が
 $\frac{t}{d(u,v)}$ となるように設定

例:

左下の赤い頂点からの BFS は

- ▶ 確率 t で青色の領域に到達
- ▶ 確率 $t/2$ で橙色の領域に到達
- ▶ 確率 $t/3$ で黄色の領域に到達



Random-Radius Ball (RRB) 法

入力: グラフ $G = (V, E)$, パラメータ $0 < t \leq 1$.

foreach vertex $u \in V$ do

$\tau \leftarrow \left\lfloor \frac{t}{\text{rand}()} \right\rfloor$. (rand() は $(0, 1]$ の一様な乱数を返すものとする)

頂点 u から深さ τ の BFS を行い, 訪れた頂点をマーク.

最終的に, ある頂点 v がマークされた回数は?

$$E[v \text{ のマーク回数}] = \sum_u \frac{t}{d(u, v)} = t \cdot C(v)$$

▶ $\hat{C}(v) := \frac{\text{(v のマーク回数)}}{t}$ が $C(v)$ の不偏推定量となる!

RRB法の基本部: 解析

C_{avg} を中心性の平均値, また $k_t := t \cdot C_{avg}$ と定める.

計算量:

▶ RRB法は $O(n)$ の (追加の) 空間計算量を要する.

▶ 時間計算量は $O(\boxed{R}k_t m)$, ただし $R = \frac{\max C(v)}{C_{avg}}$.

グラフがスモールワールドなら

R は定数

誤差保証:

▶ 頂点 v が $C(v) \geq C_{avg}$ を満たすものとする. このとき,

$$\begin{array}{l} \text{相対誤差の標準偏差} \\ \text{(変動係数; CV)} \end{array} = \frac{\sigma(\hat{C}(v))}{C(v)} \leq \frac{1}{\sqrt{k_t}}.$$

RRB法の基本部: 解析

C_{avg} を中心性の平均値, また $k_t := t \cdot C_{avg}$ と定める.

値は一般に分からない \longrightarrow

k_t が指定できない!

計算量:

▶ RRB法は $O(n)$ の (追加の) 空間計算量を要する.

▶ 時間計算量は $O(Rk_t m)$, ただし $R = \frac{\max C(v)}{C_{avg}}$.

誤差保証:

▶ 頂点 v が $C(v) \geq C_{avg}$ を満たすものとする. このとき,

$$\text{相対誤差の標準偏差 (変動係数; CV)} = \frac{\sigma(\hat{C}(v))}{C(v)} \leq \frac{1}{\sqrt{k_t}}.$$

パラメータ k_t が
計算量と精度の両方を定める

“ブートストラップ” 法

問題: パラメータ k_t を制御する方法はあるか?

解決策: RRB法を実行した結果を基に k_t を“推定”する

“ブートストラップ” の枠組み

精度パラメータ k^* を選択
 t を十分小さな値で初期化

RRB法の基本部を実行

C_{avg} と k_t を推定

k_t が k^* より十分大きそうか?


$t \leftarrow 2t$

No

Yes

終了

どう
判定する?



“ブートストラップ” 法: 解析

k_t の推定値

基準: $\hat{k}_t \geq k^* + s\sqrt{k^*}$ のとき, k_t が k^* より大きそうと判断
ブートストラップ法のパラメータ

時間計算量:

▶ $O(R(k^* + (2 + s)\sqrt{k^*})m)$ -時間で動作. (Thm. 10)

時間計算量は

誤差保証:

ほぼ増加しない

▶ 頂点 v が $C(v) \geq C_{avg}$ を満たすものとする. このとき,

$$\frac{\sigma(\hat{C}(v))}{C(v)} \leq \frac{1}{\sqrt{k^*}}$$


が **確率 $1 - 4/k^* - 1/s^2$ 以上** で成り立つ. (Thm. 9)

わずかなオーバーヘッドで精度の制御が可能に


実験: 既存手法との比較

計算時間と精度のトレードオフ

soc-Slashdot0902 (Social)
 $n = 82,168$ $m = 948,464$



web-NotreDame (Web)
 $n = 325,729$ $m = 1,497,134$



- ▶ RRB法は既存手法より優れた性能
- ▶ Permutation-rank 法 (PR) を用いると実験的な精度は改善 (理論保証は無し)

(Intel Xeon E5540 processors (2.53GHz), 48GiB RAM, single-threaded)

実験: スケーラビリティ

ブートストラップ法 ($k^* = 100, s = 3$)

データセット	種別	頂点数	辺数	時間 (秒)	誤差
web-Google	Web	876 K	5.1 M	24.69	3.90%
com-youtube	Social	1.1 M	6.0 M	20.99	2.38%
dblp-2001	Social	933 K	6.7 M	29.65	2.92%
ego-Gplus	Social	108 K	14 M	10.10	4.83%
in-2004	Web	1.4 M	17 M	27.49	5.84%
soc-Pokec	Social	1.6 M	31 M	107.93	3.67%
soc-LiveJournal1	Social	4.8 M	69 M	278.03	2.54%
enwiki-2013	Social	4.2 M	101 M	223.64	1.72%

- ▶ 1億辺規模のネットワークも取り扱える
- ▶ 理論保証の 10% ($= 1/\sqrt{100}$) よりも実際の誤差は小さい

(Intel Xeon E5540 processors (2.53GHz), 48GiB RAM, single-threaded)

実験: スケーラビリティ

ブートストラップ法 ($k^* = 100, s = 3$)

データセット	種別	頂点数	辺数	時間 (秒)	誤差
web-Google	Web	876 K	5.1 M	24.69	3.90%
com-youtube	Social	1.1 M	6.0 M	20.99	2.38%
dblp-2001	Social	933 K	6.7 M	29.65	2.92%
ego-Gplus	Social	108 K	14 M	10.10	4.83%
in-2004	Web	1.4 M	17 M	27.49	5.84%
soc-Pokec	Social	1.6 M	31 M	107.93	3.67%
soc-LiveJournal1	Social	4.8 M	69 M	278.03	2.54%
enwiki-2013	Social	4.2 M	101 M	223.64	1.72%

- ▶ 1億辺規模のネットワークも取り扱える
- ▶ 理論保証の 10% ($= 1/\sqrt{100}$) よりも実際の誤差は小さい

(Intel Xeon E5540 processors (2.53GHz), 48GiB RAM, single-threaded)

厳密な計算には
24スレッド×2日半を
要した

まとめ

距離に基づく中心性の推定が高速に行える
random-radius ball (RRB) 法を提案

- ▶ 特に頂点ランキングの上位を求めるような応用に適する

今後の可能性

- ▶ RRB法の応用範囲は中心性に限らない:
少しの変更で *closeness similarity* (近接類似性) も推定可能
[\[Cohen et al. COSN '13\]](#)

詳細な比較 k, s : 計算量と精度のトレードオフパラメータ

	時間計算量	空間	誤差保証 (CV)
RRB法	$O\left((k + (2 + s)\sqrt{k})m \cdot \frac{\max C(v)}{C_{avg}}\right)$	$O(n)$	$\leq 1/\sqrt{k} \ \forall v \text{ s.t. } C(v) \geq C_{avg}$ with prob. $1 - 4/k - 1/s^2$
HyperBall	$O(km \cdot \text{diam}(G))$	$O(kn)$	$\leq O(1/\sqrt{k})$ ただし実験的にのみ
ADS	$O(k(m + n \log k) \log n)$	$O(kn)$	$\leq 1/\sqrt{2(k-1)}$