

Efficient PageRank Tracking in Evolving Networks

KDD'15

21st ACM SIGKDD Conference on
Knowledge Discovery and Data Mining

大坂 直人 (東京大学 / プロジェクト RA)

前原 貴憲 (静岡大学)

河原林 健一 (NII)

はじめに

PageRankとPersonalized PageRank

■ PageRank [Brin-Page.'98]

Webページの**重要度**の指標

リンク構造だけから決まる

一般化

■ Personalized PageRank

[Jeh-Widom.'03]

バイアス付き ⇨ **関連度**

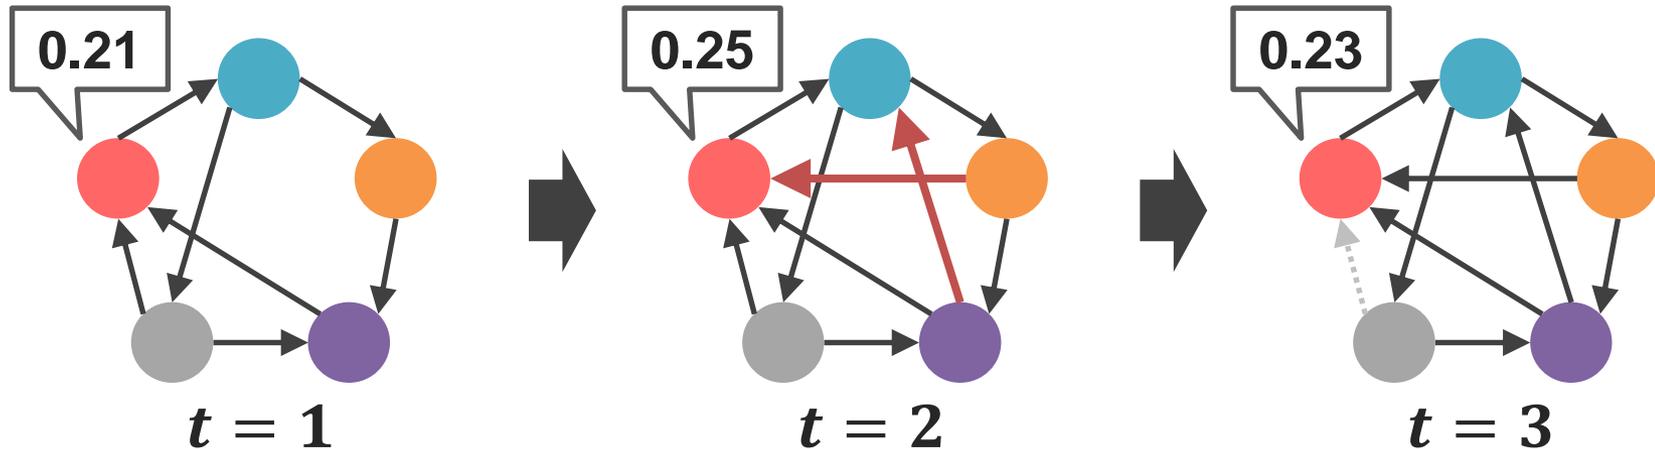


去年の感謝祭…静的グラフ上の高速計算

[Maehara-Akiba-Iwata-Kawarabayashi. PVLDB'14]

はじめに

Evolving Networks … 動的グラフ



- World Wide Web

新しいページ・リンク 60万ページ/秒

<http://www.internetlivestats.com/>

- ソーシャルネットワーク

新しい友人関係

- マイクロブログ

ユーザ同士のやりとり 5000ツイート/秒

<http://www.technologyreview.com/graphiti/522376/the-many-tongues-of-twitter/>

グラフ全体を見ずに更新したい

はじめに 関連度としての応用

スパム検知

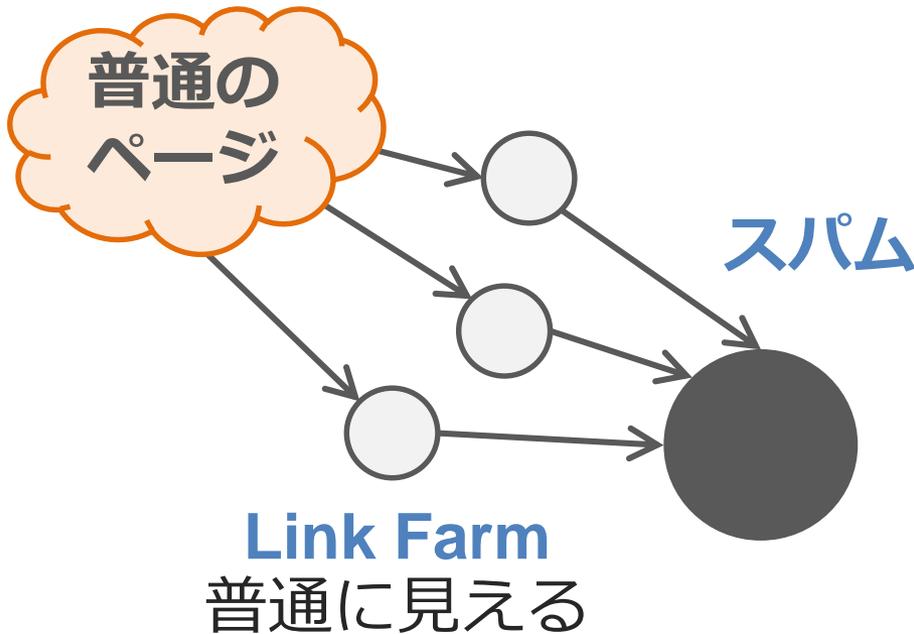
スコアの時間変化を利用

[Chung-Toyoda-Kitsuregawa. '09, '10]

ユーザ推薦

友達の候補生成

[Gupta-Goel-Lin-Sharma-Wang-Zadeh. WWW'13]



はじめに

Personalized PageRank追跡の既存手法

	m 辺の無作為挿入の時間	スケーラビリティ 0.1秒以下 / 辺 誤差約 10^{-9}
Aggregation/Disaggregation [Chien et al. '04]	$O(m S \log 1/\epsilon)$	68M 辺
Monte-Carlo [Bahmani et al. '10]	$O(m + \log m / \epsilon^2)$	68M 辺
Power method ナイーブな手法	$O(m^2 \log 1/\epsilon)$	11M 辺

本研究の貢献

成長するグラフにおける

Personalized PageRank 追跡のための

高速 & 高精度 な手法を提案

	m辺の無作為挿入の時間	スケーラビリティ 0.1秒以下 / 辺 誤差約 10^{-9}
提案手法	平均 \downarrow 最大出次数 $O(m + \Delta \log m / \epsilon)$	3,700M 辺
Aggregation/Disaggregation [Chien et al. '04]	$O(m S \log 1/\epsilon)$	68M 辺
Monte-Carlo [Bahmani et al. '10]	$O(m + \log m / \epsilon^2)$	68M 辺
Power method ナイーブな手法	$O(m^2 \log 1/\epsilon)$	11M 辺

予備知識

Personalized PageRank の定義

[Brin-Page. Comput. Networks ISDN Syst.'98] [Jeh-Widom. WWW'03]

■ 線形方程式

次の解

$$x = \alpha P x + (1 - \alpha) b$$

バイアス

確率遷移行列

非ジャンプ確率 = 0.85

Random walk
による解釈



定常分布

■ Random walkによるWeb閲覧のモデル化

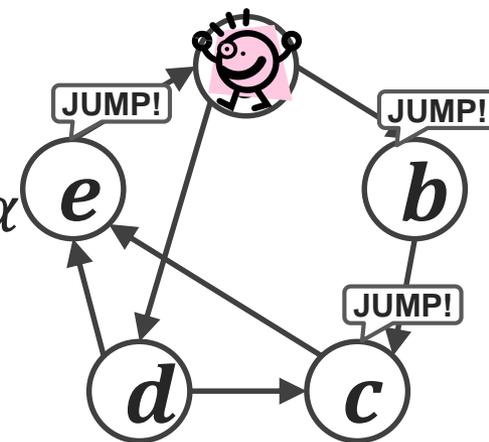
無作為に隣接頂点に移動

w.p. α

無作為に任意頂点にジャンプ
分布 $b \in \mathbb{R}^n$

w.p. $1 - \alpha$

$x_v = v$ を訪れる確率



静的グラフ上のPageRankの計算

- 線形方程式 $x = \alpha Px + (1 - \alpha)b$ を解く

Power method $x^{(v)} = \alpha Px^{(v-1)} + (1 - \alpha)b$

- v を訪れる割合 x_v を見積もる

Monte-Carlo シミュレーション

動的グラフ上のPageRankの追跡

- Aggregation/disaggregation

[Chien-Dwork-Kumar-Simon-Sivakumar. Internet Math.'04]

変化のあった近傍にPower methodを適用

↑ 大きい☹

- Monte-Carlo ベース

[Bahmani-Chowdhury. VLDB'10]

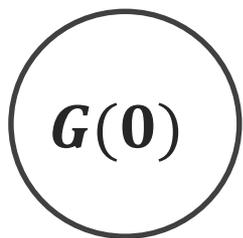
Random walkの軌跡を保持・更新

↑ 沢山必要☹

提案手法

問題設定

時刻0の入力 : $G(0)$

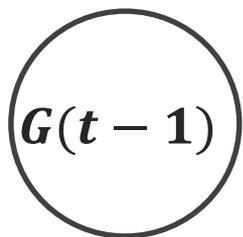


時刻0の問題 :

$G(0)$ の PageRank $x(0)$ の近似計算

$$\|x(0) - x^*(0)\|_{\infty} < \epsilon$$

⋮

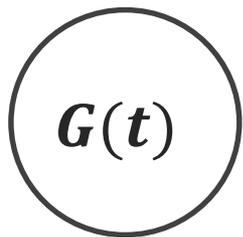


時刻 $t - 1$ の問題 :

$G(t - 1)$ の PageRank $x(t - 1)$ の近似計算

時刻 t の入力 :

追加 / 削除 される辺集合



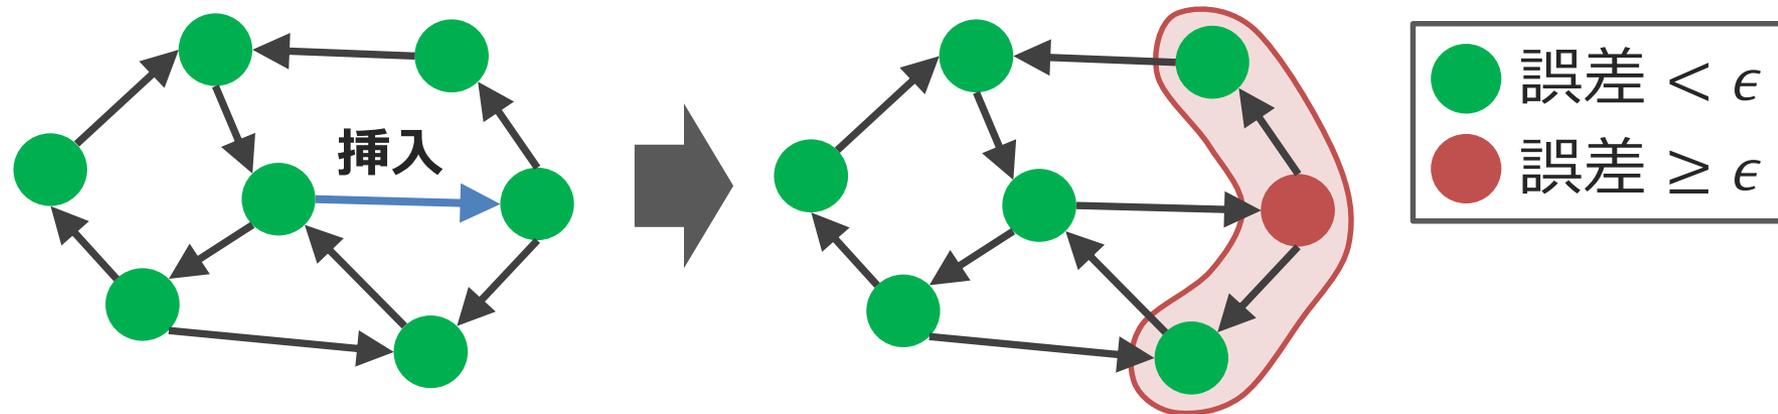
時刻 t の問題 :

$G(t)$ の PageRank $x(t)$ の近似計算

そのアイデア

$$x(t) = \alpha P(t)x(t) + (1 - \alpha)b \text{ を解く}$$

1. $x(t - 1)$ は $x(t)$ の **良い** 初期近似解
2. 近似解を **局所的** に改善できないか？



- **Gauss-Southwell** 法 を採用 😊 [Southwell. '40, '46]

別名 *Local algorithm*

[Spielman-Teng. SIAM J. Comput.'13]

Bookmark coloring algorithm

[Berkhin. Internet Math.'06]

Gauss-Southwell 法 [Southwell. '40, '46]

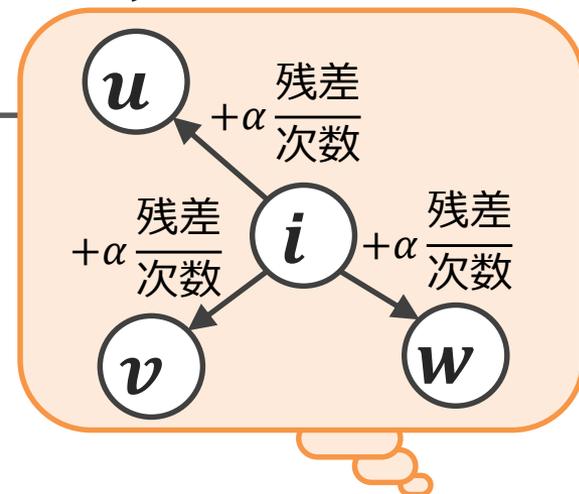
- ν^{th} 近似解 $x^{(\nu)}$
- ν^{th} 残差 $r^{(\nu)} = (1 - \alpha)b - (I - \alpha P)x^{(\nu)}$
できるだけ0に近づける

$\nu = 1, 2, 3, \dots$

$i \leftarrow |r_i^{(\nu-1)}|$ が最大の頂点

If $|r_i^{(\nu-1)}| < \epsilon$ **terminate**

$r_i^{(\nu)} = 0$ となるよう $x^{(\nu-1)}$ と $r^{(\nu-1)}$ を局所的に更新



近似保証: $\|x^* - x^{(\nu)}\|_{\infty} \leq \frac{\epsilon}{1-\alpha}$

Gauss-Southwell 法 [Southwell. '40, '46]

- ν^{th} 近似解 $x^{(\nu)}$
- ν^{th} 残差 $r^{(\nu)} = (1 - \alpha)b - (I - \alpha P)x^{(\nu)}$
できるだけ0に近づける

$\nu = 1, 2, 3, \dots$

$i \leftarrow |r_i^{(\nu-1)}|$ が最大の頂点

If $|r_i^{(\nu-1)}| < \epsilon$ **terminate**

$$x^{(\nu)} = x^{(\nu-1)} + r_i^{(\nu-1)} e_i$$

$$r^{(\nu)} = r^{(\nu-1)} - r_i^{(\nu-1)} e_i + \alpha r_i^{(\nu-1)} P e_i$$

$$\leq \frac{\|r^{(0)}\|}{(1-\alpha)\epsilon} \quad \square$$

\square は $\|r^{(\nu-1)}\|_1$ を $(1 - \alpha)\epsilon$ 以上減らす

その概観

時刻 t :

$$x(t)^{(0)} = x(t - 1)$$

$$r(t)^{(0)} = r(t - 1) + \alpha(P(t) - P(t - 1))x(t - 1)$$

Gauss-Southwell 法を適用

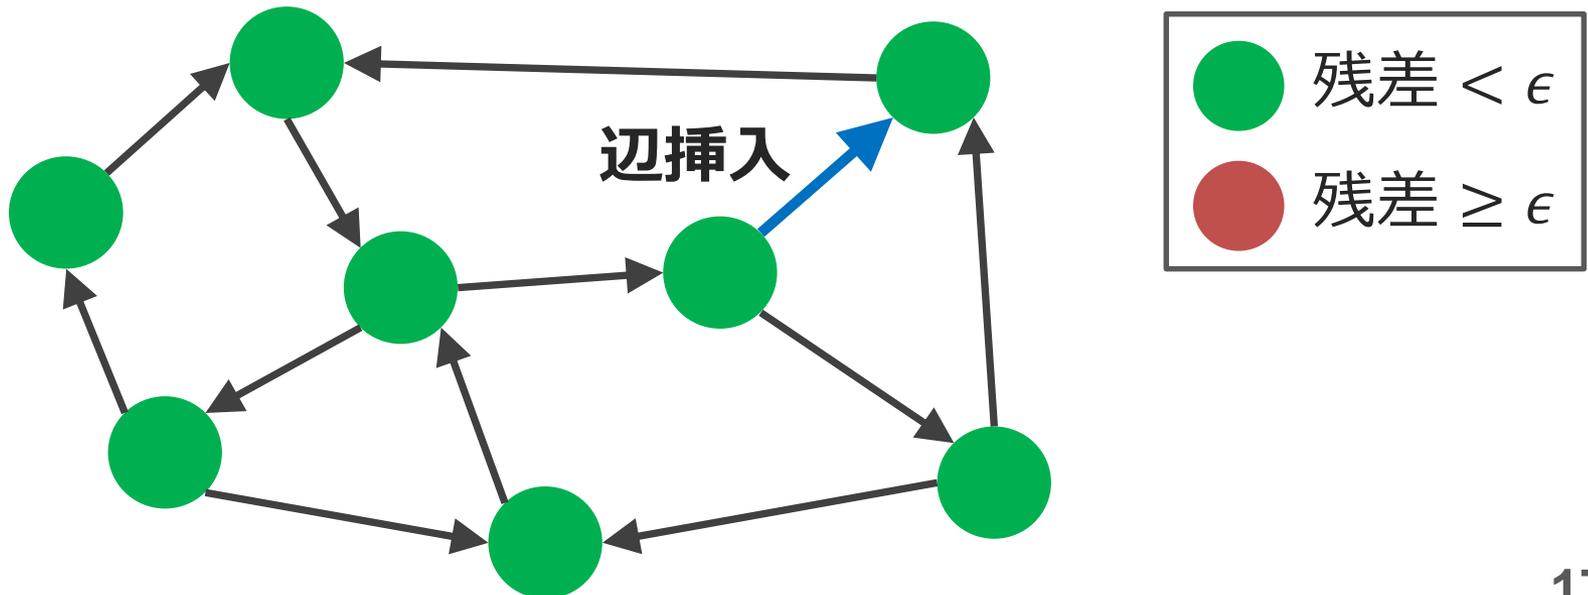
提案手法 挙動

時刻 t :

$$x(t)^{(0)} = x(t - 1)$$

$$r(t)^{(0)} = r(t - 1) + \alpha(P(t) - P(t - 1))x(t - 1)$$

Gauss-Southwell 法を適用



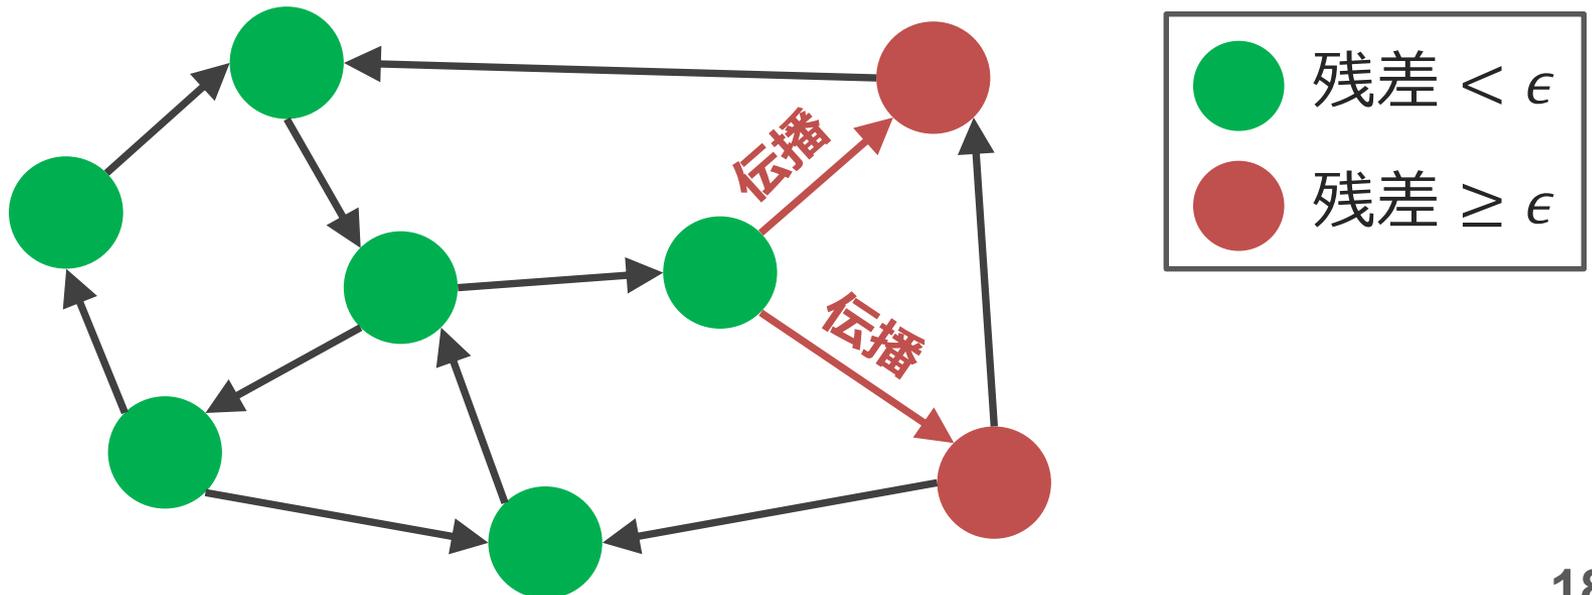
提案手法 挙動

時刻 t :

$$x(t)^{(0)} = x(t - 1)$$

$$\rightarrow r(t)^{(0)} = r(t - 1) + \alpha(P(t) - P(t - 1))x(t - 1)$$

Gauss-Southwell 法を適用



提案手法 挙動

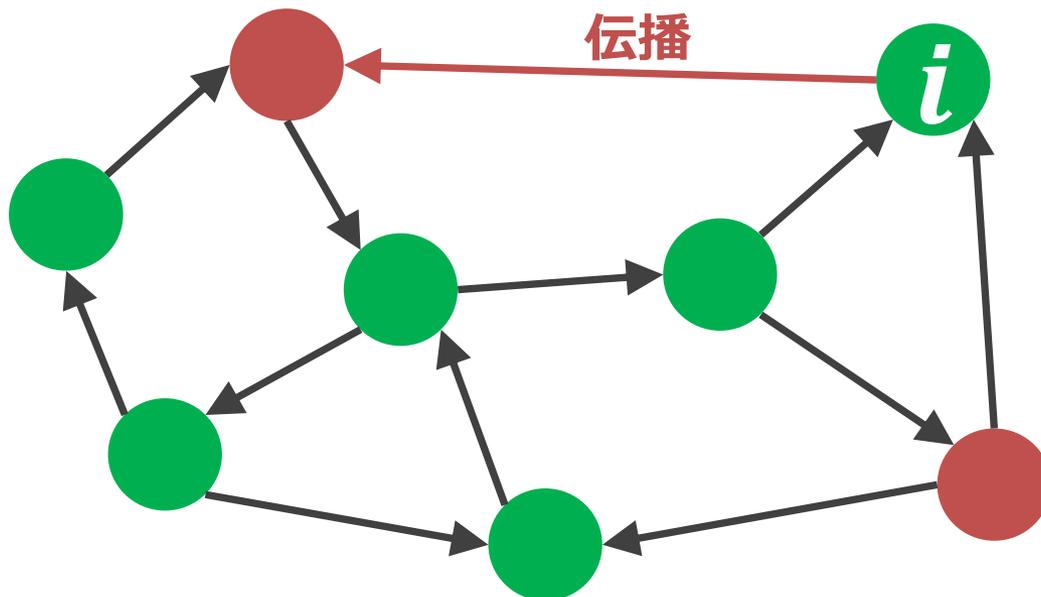
時刻 t :

$$x(t)^{(0)} = x(t - 1)$$

$$r(t)^{(0)} = r(t - 1) + \alpha(P(t) - P(t - 1))x(t - 1)$$

➡ Gauss-Southwell 法を適用

$\nu = 1$



提案手法 挙動

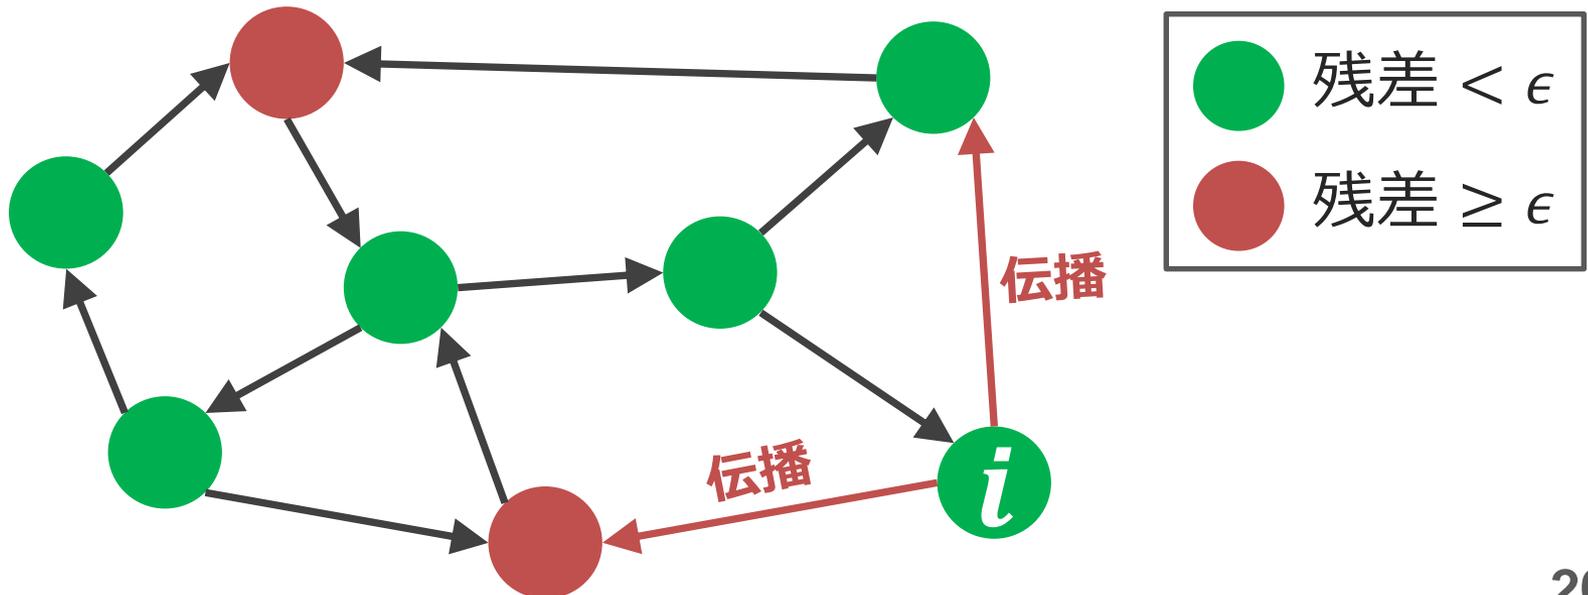
時刻 t :

$$x(t)^{(0)} = x(t - 1)$$

$$r(t)^{(0)} = r(t - 1) + \alpha(P(t) - P(t - 1))x(t - 1)$$

➡ Gauss-Southwell 法を適用

$\nu = 2$



性能解析

時刻 t :

$$x(t)^{(0)} = x(t - 1)$$

$$r(t)^{(0)} = r(t - 1) + \alpha(P(t) - P(t - 1))x(t - 1)$$

Gauss-Southwell 法を適用

は**効率的**に計算可

辺 vw の追加／削除は $\mathcal{O}(d_v)$ 時間

$$\begin{bmatrix} 0 & 0 & 0 & 0 & 1 \\ 1/2 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 1/2 & 0 \\ 1/2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1/2 & 0 \end{bmatrix}$$

$P(t - 1)$



$$\begin{bmatrix} 0 & 0 & 0 & 0 & 1 \\ 1/2 & 0 & 0 & 1/3 & 0 \\ 0 & 1 & 0 & 1/3 & 0 \\ 1/2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1/3 & 0 \end{bmatrix}$$

$P(t)$

$$\begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1/3 & 0 \\ 0 & 0 & 0 & -1/6 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & -1/6 & 0 \end{bmatrix}$$

$P(t) - P(t - 1)$

性能解析

時刻 t :

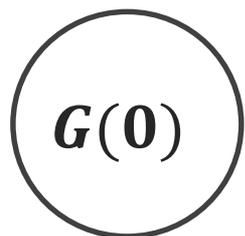
残差の増分 $\|\cdot\|_1$ はどの位？

$$x(t)^{(0)} = x(t-1)$$

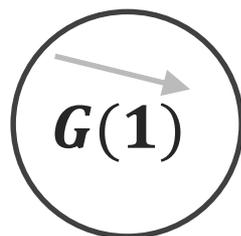
$$r(t)^{(0)} = r(t-1) + \alpha(P(t) - P(t-1))x(t-1)$$

Gauss-Southwell 法を適用

- 各時刻で単一辺が**無作為**に挿入



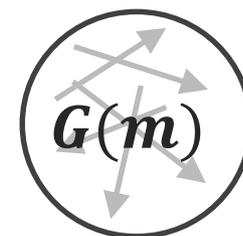
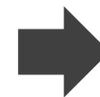
辺集合 = \emptyset



1辺足す



...



m 辺足し終えた

$$\mathbf{E}[\text{時刻 } t \text{ での残差の増分}] \leq 2\alpha/t$$

性能解析

Gauss-Southwell 法を適用

■ 定理 1.

任意の変更に対する反復回数 は ならし $\mathcal{O}(1/\epsilon)$

⇒ ならし時間は $\mathcal{O}(\Delta/\epsilon)$

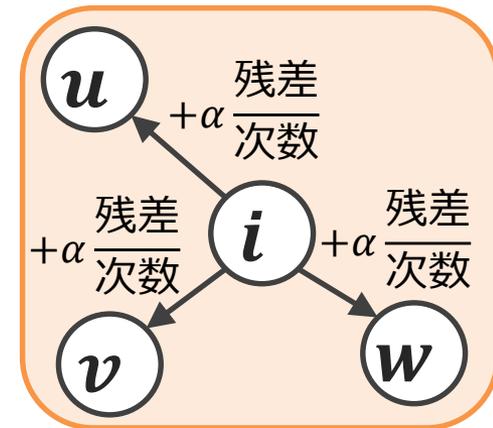
■ 定理 2.

m 辺を無作為・逐次的に挿入

期待総反復回数は $\mathcal{O}(\log m / \epsilon)$

⇒ 期待総時間は $\mathcal{O}(m + \Delta \log m / \epsilon)$

$\Delta =$ 最大出次数



実験

実験

設定: 単一辺挿入の性能評価



■ パラメータ設定

- $\alpha = 0.85$
- $b = 100$ 要素が非ゼロのベクトル
- $\epsilon = 10^{-9}$

実験

性能評価: 単一辺挿入の平均時間 & 反復回数

データセット [出典]	頂点数 $ V $	辺数 $ E $	最大 出次数 Δ	平均 時間	平均 反復回数
wiki-Talk [SNAP]	2M	5M	100,022	589.6 μ s	2.3
web-Google [SNAP]	1M	5M	3,444	7.2 μ s	22.6
as-Skitter [SNAP]	2M	11M	35,387	288.4 μ s	0.8
Flickr ^{時刻} [KONECT]	2M	33M	26,367	95.3 μ s	16.2
Wikipedia ^{時刻} [KONECT]	2M	40M	6,975	76.8 μ s	46.0
soc-LiveJournal1 [SNAP]	5M	68M	20,292	17.9 μ s	7.6
twitter-2010 [LAW]	42M	1,500M	2,997,469	29,382.8 μ s	0.7
uk-2007-05 [LAW]	105M	3,700M	15,402	2.3 μ s	0.0

[KONECT] The Koblenz Network Collection <http://konect.uni-koblenz.de/networks/>

[LAW] Laboratory for Web Algorithmics <http://law.di.unimi.it/datasets.php>

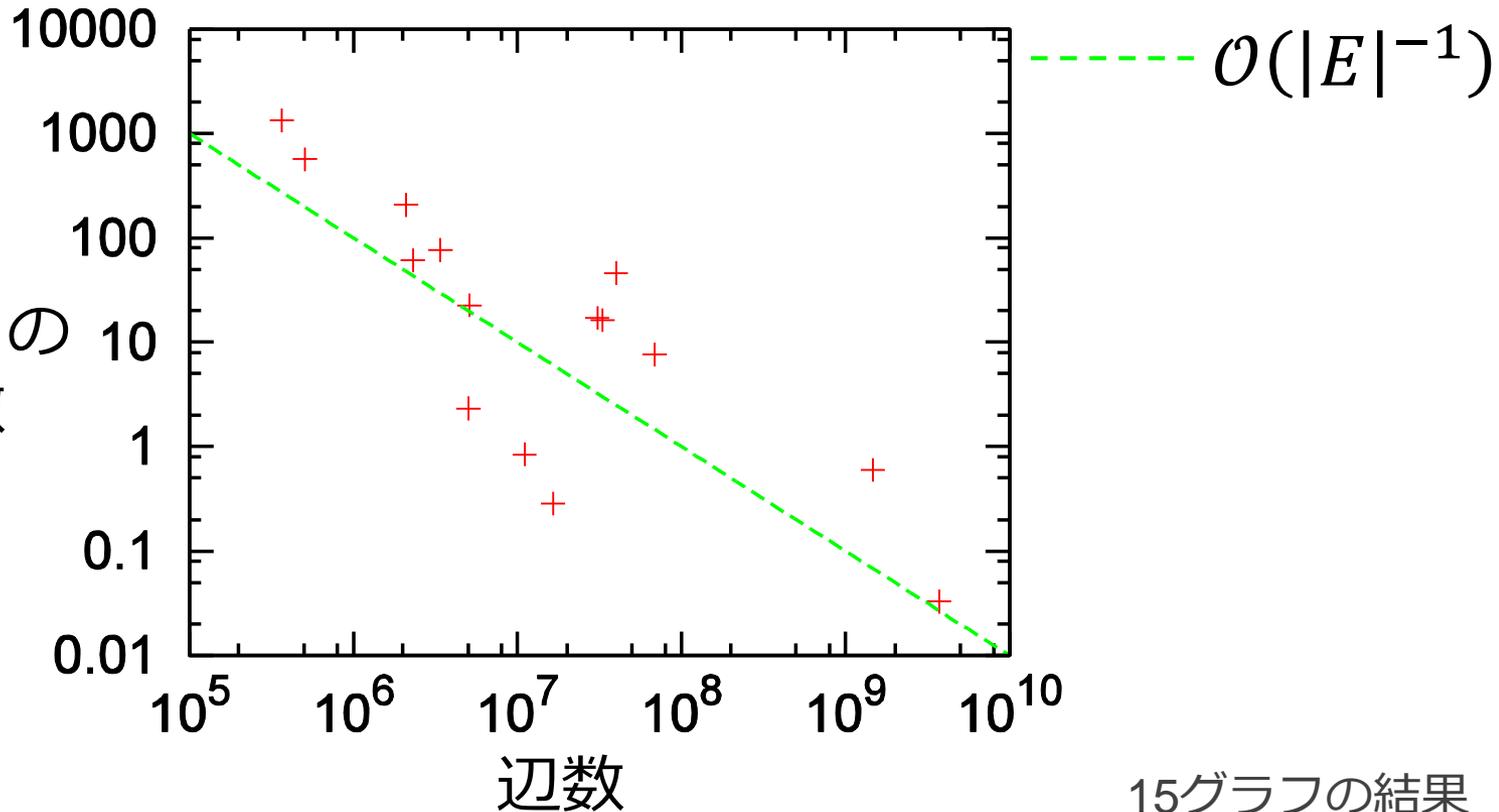
[SNAP] Stanford Large Network Dataset Collection <http://snap.stanford.edu/data/>

Environment: Intel Xeon E5-2690 2.90GHz CPU with 256GB memory

実験

性能評価: 辺数と反復回数の関係

辺挿入あたりの
平均反復回数



辺が**多い**ほど少ない

実験

性能評価: 単一辺挿入の平均時間 & 反復回数

データセット [出典]	頂点数 $ V $	辺数 $ E $	最大 出次数 Δ	平均 時間	平均 反復回数
wiki-Talk [SNAP]	2M	5M	100,022	589.6 μ s	2.3
web-Google [SNAP]	1M	5M	3,444	7.2 μ s	22.6
as-Skitter [SNAP]	2M	11M	35,387	288.4 μ s	0.8
Flickr時刻 [KONECT]	2M	33M	26,367	95.3 μ s	16.2
Wikipedia時刻 [KONECT]	2M	40M	6,975	76.8 μ s	46.0
soc-LiveJournal1 [SNAP]	5M	68M	20,292	17.9 μ s	7.6
twitter-2010 [LAW]	42M	1,500M	2,997,469	29,382.8 μ s	0.7
uk-2007-05 [LAW]	105M	3,700M	15,402	2.3 μ s	0.0

[KONECT] The Koblenz Network Collection <http://konect.uni-koblenz.de/networks/>

[LAW] Laboratory for Web Algorithmics <http://law.di.unimi.it/datasets.php>

[SNAP] Stanford Large Network Dataset Collection <http://snap.stanford.edu/data/>

Environment: Intel Xeon E5-2690 2.90GHz CPU with 256GB memory

実験

性能評価: 単一辺挿入の平均時間 & 反復回数

データセット [出典]	頂点数 $ V $	辺数 $ E $	最大 出次数 Δ	平均 時間	平均 反復回数
wiki-Talk [SNAP]	2M	5M	100,022	589.6 μ s	2.3
web-Google [SNAP]	1M	5M	3,444	7.2 μ s	22.6
as-Skitter [SNAP]	2M	11M	35,387	288.4 μ s	0.8
Flickr ^{時刻} [KONECT]	2M	33M	26,367	95.3 μ s	16.2
Wikipedia ^{時刻} [KONECT]	2M	40M	6,975	76.8 μ s	46.0
soc-LiveJournal1 [SNAP]	5M	68M	20,292	17.9 μ s	7.6
twitter-2010 [LAW]	42M	1,500M	2,997,469	29,382.8 μ s	0.7
uk-2007-05 [LAW]	105M	3,700M	15,402	2.3 μ s	0.0

[KONECT] The Koblenz Network Collection <http://konect.uni-koblenz.de/networks/>

[LAW] Laboratory for Web Algorithmics <http://law.di.unimi.it/datasets.php>

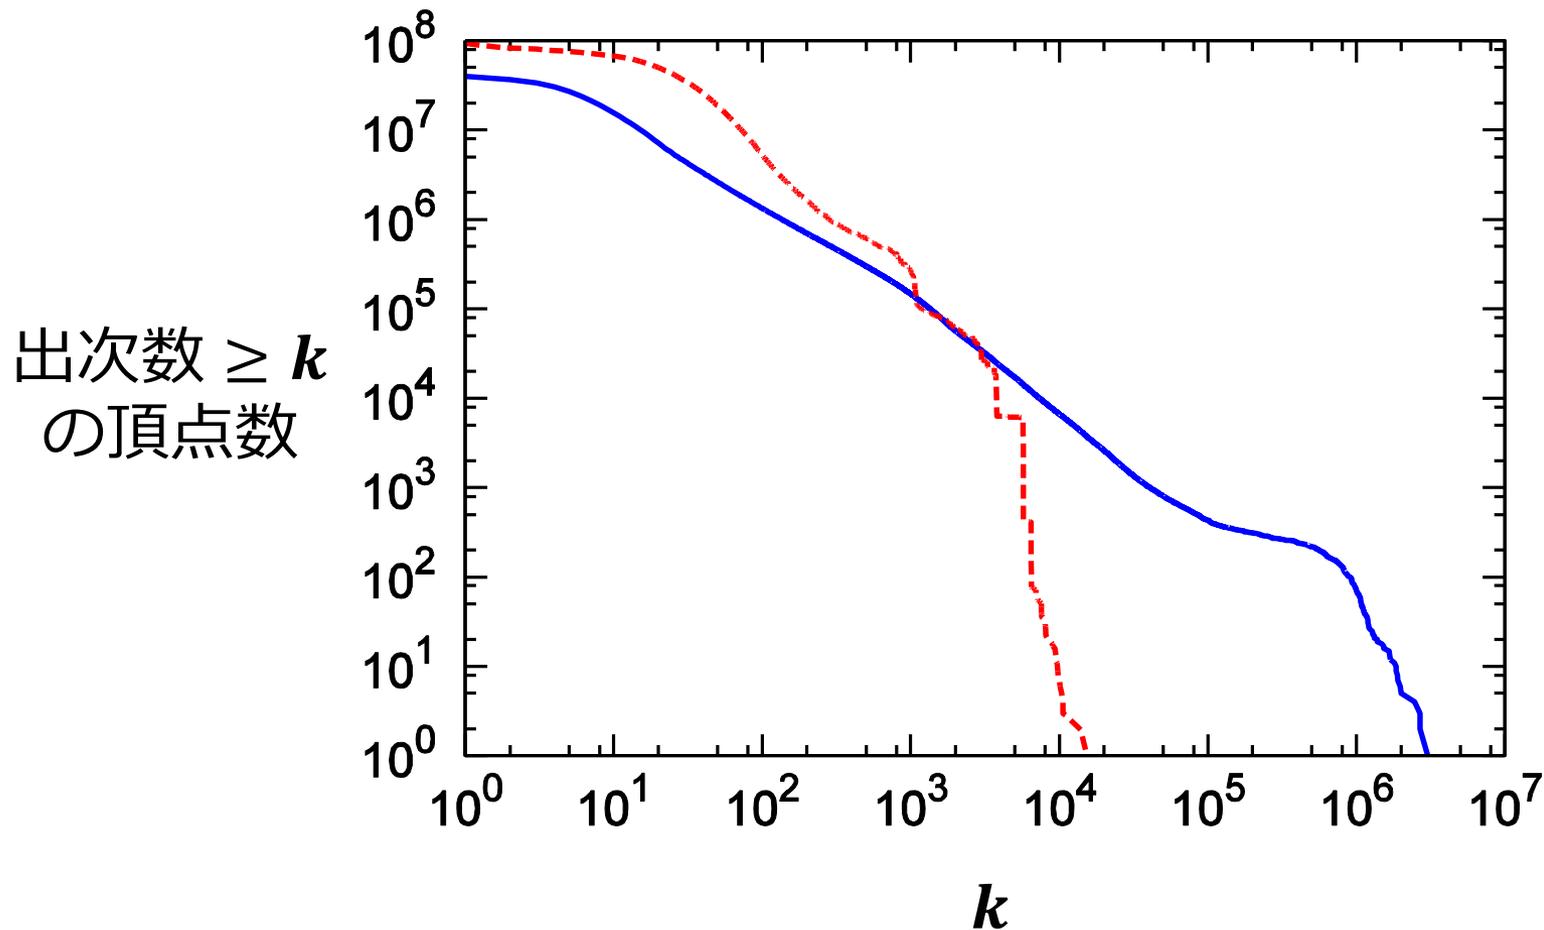
[SNAP] Stanford Large Network Dataset Collection <http://snap.stanford.edu/data/>

Environment: Intel Xeon E5-2690 2.90GHz CPU with 256GB memory

実験

次数分布の違い

- twitter-2010 (u, v) v が u をフォロー
- - - uk-2007-05 (u, v) ページ u から v へリンク



実験

既存手法との比較: 単一辺挿入の平均時間

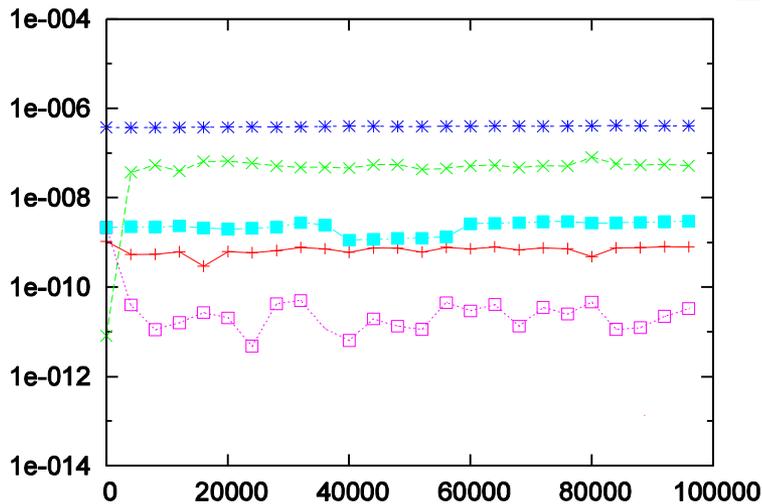
	web-Google [SNAP] $ V =1M$ $ E =5M$	Wikipedia [KONECT] $ V =2M$ $ E =40M$	uk-2007-05 [LAW] $ V =105M$ $ E =3,700M$
提案手法	7 μ s	77 μ s	2.3 μ s
Aggregation/Disaggregation [Chien et al. '04]	320 μ s	40,336 μ s	>100,000 μ s
Monte-Carlo [Bahmani et al. '10]	444 μ s	9,196 μ s	>100,000 μ s
Warm start power method	80,994 μ s	>100,000 μ s	>100,000 μ s
From scratch power method	>100,000 μ s	>100,000 μ s	>100,000 μ s

実験

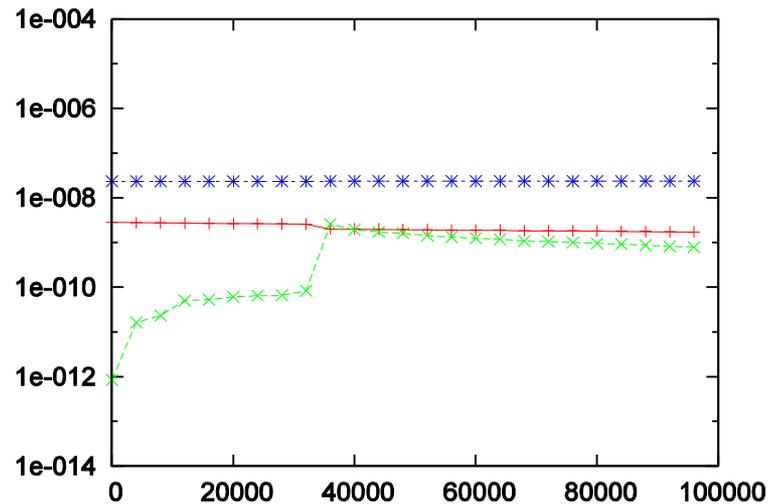
既存手法との比較: 精度

- +— 提案手法
- -x- - Aggregation/Disaggregation [Chien et al.'04]
- -* - Monte-Carlo [Bahmani et al.'10]
- ...□... Warm start (power method)
- -■ - From scratch (power method)

平均 L_1 誤差の遷移



soc-Epinions1 [SNAP] $|V|=76K$ $|E|=509K$



Wikipedia [KONECT] $|V|=2M$ $|E|=40M$

愚直な手法に匹敵($\sim 10^{-9}$)

まとめ

成長するネットワークにおける
Personalized PageRank追跡のための
高速 & **高精度**な手法を提案

理論的

任意の変更にならし $\mathcal{O}(\Delta/\epsilon)$ 時間

m 辺の無作為挿入に期待 $\mathcal{O}(m + \Delta \log m / \epsilon)$ 時間

$$\|x - x^*\|_{\infty} \leq \epsilon$$

実験的

37億辺をもつグラフへの単一辺挿入に**3 μ s**

10⁻⁹ L_1 誤差

KDD'15は来週シドニー

KDD2015

CALL FOR

ATTENDING

PROGRAM

WORKSHOPS

TUTORIALS

KDD CUP

SPONSORSHIP

ORGANISERS

Research Session RT17: Social and Graphs 3

Wednesday 1:00 pm–3:00 pm | Level 3 – Ballroom B

Chair: Tina Eliassi-Rad

Edge-Weighted Personalized **PageRank**: Breaking A Decade-Old Performance Barrier

Wenlei Xie,Cornell University; David Bindel,Cornell University; Alan Demers,Cornell University; Johannes Gehrke,Cornell University
(Paper ID:117)

SEISMIC: A Self-Exciting Point Process Model for Predicting Tweet Popularity

Qingyuan Zhao,Stanford University; Murat A.,Erdogdu; Stanford University Hera,Y.; He Stanford University,Anand; Rajaraman Stanford University,Jure; Leskovec
Stanford Universit
(Paper ID:819)

Beyond Triangles: A Distributed Framework for Estimating 3-profiles of Large Graphs

Ethan R.,Elenberg; The University of Texas Karthikeyan,Shanmugam; The University of Texas Michael,Borokhovich; The University of Texas Alexandros,G.; Dimakis The
University of Texa
(Paper ID:896)

Scalable Large Near-Clique Detection in Large-Scale Networks via Sampling

Michael Mitzenmacher,Harvard University; Jakub Pachocki,Carnegie Mellon University; Richard Peng,MIT; Charalampos Tsourakakis,Harvard University; Shen Chen
Xu,Carnegie Mellon University
(Paper ID:720)

Efficient **PageRank** Tracking in Evolving Networks

Naoto Ohsaka,The University of Tokyo; Takanori Maehara,Shizuoka University; Ken-ichi Kawarabayashi,National Institute of Informatics
(Paper ID:228)

MASCOT: Memory-efficient and Accurate Sampling for Counting Local Triangles in Graph Streams

Yongsub Lim,KAIST; U Kang,KAIST
(Paper ID:163)

