JAIST Repository

https://dspace.jaist.ac.jp/

Title	スケールフリーグラフ上における局所情報を用いたラ ンダムウォーク	
Author(s)	平山,亮	
Citation		
Issue Date	2006-09	
Туре	Thesis or Dissertation	
Text version	author	
URL	http://hdl.handle.net/10119/2037	
Rights		
Description	Supervisor:上原 隆平, 情報科学研究科, 修士	



Japan Advanced Institute of Science and Technology

修士論文

スケールフリーグラフ上における 局所情報を用いたランダムウォーク

北陸先端科学技術大学院大学 情報科学研究科情報処理学専攻

平山 亮

2006年9月

修士論文

スケールフリーグラフ上における 局所情報を用いたランダムウォーク

指導教官 上原 隆平 助教授

審査委員主査	上原 隆平 助教授
審査委員	金子 峰雄 教授
審査委員	平石 邦彦 教授

北陸先端科学技術大学院大学 情報科学研究科情報処理学専攻

410204平山亮

提出年月: 2006年8月

Copyright \bigodot 2006 by Ryo Hirayama

概 要

近年,WWWやインターネットをモデル化できるものとしてスケールフリーグラフが 注目されている.また,局所情報を用いたランダムウォークは,既存のシンプルランダム ウォークよりもネットワークを効率よくカバーすることが知られている.本論文では,ス ケールフリーグラフ上で,局所情報を用いたランダムウォークの最適なパラメータを実験 的に求め,既存のシンプルランダムウォークに対する優位性を示した.

目 次

第 1章	はじめに	1
第2章	グラフモデル	3
2.1	グラフ	3
	2.1.1 無向グラフ	3
	2.1.2 有向グラフ	3
	2.1.3 疎なグラフ	3
	2.1.4 密なグラフ	4
	2.1.5 次数	4
	2.1.6 セルフループ	4
	2.1.7 多重辺	5
	2.1.8 ウォーク	5
	2.1.9 トレイル	5
	2.1.10 パス	5
	2.1.11 到達可能	5
	2.1.12 連結	6
	2.1.13 強連結	6
	2.1.14 弱連結	6
	2.1.15 距離	6
	2.1.16 直径	6
	2.1.17 半径	6
2.2	ランダムグラフ	6
	2.2.1 $\mathcal{G}(n,M)$ モデル	7
	2.2.2 $\mathcal{G}(n,p)$ モデル	7
2.3	スケールフリーグラフ	7
	2.3.1 スケールフリーネットワーク	7
	2.3.2 Barabási-Albert の Preferential attachment モデル	8
	2.3.3 有向スケールフリーグラフ	8
第3章	ランダムウォークモデル	10
3.1	マルコフチェーン	10
	3.1.1 マルコフチェーン	10

参考文献		
謝辞		47
第5章	おわりに	46
	4.3.1 逆辺をたどることを許した場合	35
4.3	有向スケールフリーグラフ上における実験結果	35
	4.2.2 次数の対数べき乗型を用いた場合	25
	4.2.1 次数べき乗型を用いた場合	17
4.2	無向スケールフリーグラフ上における実験結果...........	16
4.1	実装	16
第 4章	計算機実験	16
	$3.4.1 \sqrt{-\psi} = \frac{\psi}{2} + \frac{\psi}{2} $	15
3.4	その他のランダムウォーク	15
	3.3.3 有向スケールフリーグラフ上のランダムウォーク	15
	3.3.2 ポテンシャル関数の改良	14
	3.3.1 池田らのランダムウォーク	13
3.3	局所情報を用いたランダムウォーク	13
	3.2.5 Cooper-Frieze による理論的解析	13
	3.2.4 カバータイム	12
	3.2.3 ヒッティングタイム	12
	3.2.2 シンプルランダムウォークの定常分布	12
	3.2.1 シンプルランダムウォーク	11
3.2	ランダムウォーク	11
	3.1.4 定常分布	10
	3.1.3 非周期性	10
	3.1.2 既約性	10

第1章 はじめに

与えられたグラフ構造の上をランダムに移動するプロセスをランダムウォークと呼ぶ. ランダムウォークは, それ自身が, 興味深い研究の対象であるとともに, 乱択アルゴリズム の設計と解析など, 広範な応用を持つ要素技術として, 幅広く研究されている [13].

近年,池田らによって,新しいランダムウォークのモデル[15][16]が提案された.通常の ランダムウォークでは,それぞれの隣接点に同じ確率で遷移するのに対し,新しいモデル では,隣接点の近傍情報を利用する.比較的単純な拡張であるにも関わらず,従来のシン プルランダムウォークよりもずっと効率良くネットワーク全体をカバーすることが知られ ている.

より正確には、彼らの新しいランダムウォークモデルでは、近傍の情報を利用したポテ ンシャル関数によって決まる遷移確率 $p^{(\beta)}$ にしたがって、次に移動する先を決める.池田 らの結果は一般のグラフにおける最悪の場合を考えるため、グラフ構造には特別な仮定は 置いていない. β は隣接点を評価する割合を設定する定数であり、一般のグラフの場合は $\beta = 0.5$ のときに良い性能が得られることが知られている.

一方, WWW やインターネットをモデル化できるものとして, スケールフリーグラフ [3] が注目を集めている. これは従来の Erdős-Rényi[5] による一様な構造を持つランダムグラ フモデルとは違い, 非一様な構造を持っており, さまざまな現実の社会ネットワークをモ デル化していると考えられている. スケールフリーグラフでは power law と呼ばれる法則 が成立しており, この power law を実現できるいくつかの スケールフリーグラフ モデル がすでに知られている.

本研究では, こうした スケールフリーグラフの非一様性を積極的に利用することで, 池 田らの新しいランダムウォークをより効率化することを目標とした.

スケールフリーグラフモデルにはいくつかの異なるモデルが知られているが, 最も広く 受け入れられている preferential attachment グラフモデル [3][7] を採用する. このモデル では, 頂点の次数を制御するための整数パラメータ m を調節することで, 疎なグラフから 密なグラフまで生成することができる. また生成されるグラフは無向グラフとなる. まず, 池田らのランダムウォークモデルにおけるポテンシャル関数のパラメータ β, スケールフ リーグラフにおけるパラメータ m, 及びグラフのサイズ n との関係を実験的に評価する.

次に, ポテンシャル関数の改良を試みる.スケールフリーグラフでは, 頂点の次数の分 布は power law に従う. そのため, 次数の分布は指数関数的に極端に偏っている. この事 実から, 次数の分布を線形に補正することでより良い振舞をするポテンシャル関数が設計 できる, と予想される. この予想から, 池田らのランダムウォークにおけるポテンシャル 関数を次数の関数ではなく次数の対数の関数として実験を行う.

Preferential attachment グラフモデルでは、生成されるグラフは無向グラフとなる. こ れは、例えば Web グラフなどのネットワークのモデルとしては不適切である. Power law に従った有向グラフを生成するモデルとして preferential attachment グラフモデルの一 般化である Bollobás らのモデル [6] が知られている. しかしこうした power law に従っ た ランダムな有向グラフでは、強連結性が一般には保証できない. むしろ入次数を持た ない多数の頂点を含んでしまうので、到達性すら確保できない. これに対する ランダム ウォークモデルとして、"back button"を持ったランダムウォークモデル [11] が Fagin ら によって提案されている. また、代表的なサーチエンジン Google[1] では、Web ページ P から「そのページ P にリンクを張っているページ」を逆にたどることができる. 以上のこ とから、power law を満たす有向なスケールフリーグラフでは「有向辺を逆に辿ることが できるランダムウォーク」を考えることが応用上重要である、と考えられる. 本論文では Bollobás らの power law に従う有向グラフモデル上で、池田らのランダムウォークモデル におけるポテンシャル関数に、逆方向に対して確率 $\gamma(0 < \gamma \leq 1)$ で辿ることを許したラン ダムウォーク提案し、効率の良いパラメータを実験的に確かめる.

本論文において,以下各章は次のように構成される.第2章 (p.3)では,グラフモデル について説明する.特に,スケールフリーグラフについては,有向グラフを含むいくつかの モデルについて説明する.第3章 (p.10)では,ランダムウォークモデルについて説明する. 局所情報を用いたランダムウォークモデルについては,池田らのランダムウォークモデル について説明するとともに,それを改良したランダムウォークモデルについても提案する. 第4章 (p.16)では,各モデルにおける計算機実験の結果を示し,考察を行う.第5章 (p.46) では,まとめと今後の課題について述べる.

第2章 グラフモデル

2.1 グラフ

ここでは, グラフの基本的な定義, 性質について説明する [4][12][18].

2.1.1 無向グラフ

無向グラフ G(V, E) は, 頂点集合 V と辺集合 E からなる. 辺 $e \in E$ は, 頂点 $v_i, v_j \in V$ の非順序対で, (v_i, v_j) として表される. 頂点 $v_i \ge v_j$ の間に辺があるとき, $v_i \ge v_j$ は隣接していると言い, v_i との間に辺を持つ全ての頂点を v_i の隣接点と言う.



図 2.1: 無向グラフの例

2.1.2 有向グラフ

有向グラフG(V, E)は, 頂点集合Vと辺集合Eからなる. 辺 $e \in E$ は, 頂点 $v_i, v_j \in V$ の順序対で, (v_i, v_j) として表される. 頂点 v_i から v_j への辺があるとき, v_j は v_i に隣接していると言い, v_i からの辺を持つ全ての頂点を v_i の隣接点と言う.

2.1.3 疎なグラフ

グラフ*G*において,辺の数*m*が頂点の数*n*にくらべて小さいとき,(通常はm = O(n)のとき,)*G*は疎なグラフであると言う.



図 2.2: 有向グラフの例

2.1.4 密なグラフ

グラフ*G*において, 辺の数*m*が頂点の数*n*にくらべて大きいとき, (通常は $m = \Omega(n^2)$ のとき,) *G*は密なグラフであると言う.

2.1.5 次数

無向グラフにおいて, 頂点 v と接続する辺の数を頂点 v の次数と呼び, deg(v) と表す. 有向グラフにおいて, 頂点 v に入ってくる辺の数を頂点 v の入次数, 頂点 v から出て行く 辺の数を頂点 v の出次数と呼び, それぞれ $in_deg(v)$, $out_deg(v)$ と表す. また, deg(v) は, 頂点 v と接続する辺の数を頂点 v の次数を表し, $deg(v) = in_deg(v) + out_deg(v)$ となる.

2.1.6 セルフループ

同じ頂点vを結ぶ辺(v,v)をセルフループと呼ぶ.



図 2.3: セルフループの例

2.1.7 多重辺

頂点 *u* と頂点 *v* とを接続する複数の辺が存在するとき, それらを多重辺と呼び, それらの辺は平行であると言う.



図 2.4: 多重辺の例

2.1.8 ウォーク

ウォークは,頂点から始まり頂点で終わる,頂点と辺の連 $v_0, e_1, v_1, \cdots, v_{n-1}, e_n, v_n$ で, 各々の辺は,その両側の頂点を結ぶ辺である.

2.1.9 トレイル

トレイルは、全ての辺が別々であるウォークである.

2.1.10 パス

パスは,全ての頂点が別々であるウォークである.

2.1.11 到達可能

頂点 v_i から頂点 v_j へのパスがあるとき, v_i は v_i から到達可能であると言う.

2.1.12 連結

無向グラフGにおいて, どの頂点もそれ以外の各頂点から到達可能であるときGは連結であると言い, そのようなグラフを連結グラフと呼ぶ.

有向グラフGにおいては, Gに対応する無向グラフが連結ならば, Gは連結であると言う.

2.1.13 強連結

有向グラフにおいて, 頂点 v_i と頂点 v_j との間に, v_i から v_j への辺と v_j から v_i への辺が ともに存在するとき, v_i と v_j は強連結であると言う.

2.1.14 弱連結

無向グラフとみなしたときに $v_i \ge v_j$ との間に辺が存在し, $v_i \ge v_j$ が強連結でないとき, $v_i \ge v_j$ は弱連結であると言う.

2.1.15 距離

グラフ*G*において, 2 頂点 v_i, v_j の最短パスを $v_i v_j$ の距離と呼び, $d_G(v_i, v_j)$ と表す. ただし, そのようなパスが存在しないとき, $d_G(v_i, v_j) = \infty$ とする.

2.1.16 直径

グラフGにおける,任意の2頂点の距離の最大値をGの直径と呼び,diam(G)で表す.

2.1.17 半径

グラフGにおいて,そこから他の頂点までの距離の最大値が最も小さくなる頂点を,G の中心と呼ぶ.そのときの距離の最大値をGの半径と呼び,rad(G)で表す.

2.2 ランダムグラフ

ランダムグラフの理論 [4][5][12] は, Erdős と Rényi によってその基礎が築かれた. Erdős は, 頂点集合 $V = \{1, 2, ..., n\}$ の n 頂点のグラフ全体の集合を確率空間 G^n として定義し, グラフ理論の極値問題に取り組む上で, 確率論的手法が様々な場合において有効であり, 実際にグラフを構築することなく, 欲しい条件を満たすグラフの存在性を示した. この確

率的手法は, グラフ理論のみならず, 応用範囲の広い証明技法として, 離散数字の他の分野 においても広く用いられるようになった.

ここでは, 最もよく知られている $\mathcal{G}(n, M)$ モデルと $\mathcal{G}(n, p)$ モデルについて説明する.

2.2.1 $\mathcal{G}(n,M)$ モデル

 $\mathcal{G}(n, M)$ の全てのグラフは, n 個の頂点と M 本の辺を持つ. 完全グラフ K_n は, $N = \binom{n}{2}$ 本の辺を持つので $0 \le M \le N$ で, $\mathcal{G}(n, M)$ は $\binom{N}{M}$ 個の要素からなり, 全ての要素は等しい確率 $\binom{N}{M}^{-1}$ で生成される. $G_M = G_{n,M} \& \mathcal{G}(n, M)$ 空間から生成されるランダムグラフ, H をある固定された M 本の辺を持つ n 頂点のグラフであるとすると

$$\mathbf{Pr}(G_M = H) = \binom{N}{M}^{-1}.$$
(2.1)

2.2.2 $\mathcal{G}(n,p)$ モデル

 $\mathcal{G}(n,p)$ の全てのグラフは, n 個の頂点を持ち, 各々の頂点間には, 確率 p (0 < p < 1) で 辺が存在する. 完全グラフ K_n の部分グラフの数は, 2^N 個であるが, $\mathcal{G}(n,p)$ は, その 2^N 個 の部分グラフを全て要素に持つ. $G = G_{n,p} \in \mathcal{G}(n,p)$ 空間から生成されるランダムグラフ, Hをある固定された m本の辺を持つ n 頂点のグラフであるとすると

$$\mathbf{Pr}(G_p = H) = p^m (1-p)^{N-m}.$$
(2.2)

 $\mathcal{G}(n, \frac{1}{2})$ では、 \mathcal{G}^n 空間における任意の2つのグラフが生成される確率は等しい.また、 $M \sim pN$ のとき、 $\mathcal{G}(n, M)$ モデルと $\mathcal{G}(n, p)$ モデルは非常に似た振る舞いをする.

 $\mathcal{G}(n,p)$ モデルの次数分布 P(k)は、平均値 $\bar{k} = p(n-1)$ を持つ二項分布

$$P(k) = \binom{n-1}{k} p^k (1-p)^{n-1-k}$$
(2.3)

となる. さらに, $n \to \infty$ のとき, ポアソン分布

$$P(k) \sim e^{-\bar{k}} \frac{k}{k!} \tag{2.4}$$

になる.

2.3 スケールフリーグラフ

2.3.1 スケールフリーネットワーク

World Wide Web を始めとする多くの実在のネットワークは, その頂点の次数分布 P(k) が, ある定数 γ による, べき法則 (power law) 分布

$$P(k) \sim k^{-\gamma} \tag{2.5}$$

に従うという共通の性質を持つ. 次数 k はいくらでも大きなサイズをとりうることから, この性質を "スケールフリー" と呼ぶ. 実際に, WWW, インターネット, 神経細胞, 社会 ネットワークなどのネットワークは, スケールフリーネットワークであることが報告され ている.

従来の Erdős-Rényi のランダムグラフモデルではこれらのスケールフリーネットワーク を再現することが難しかった. 近年, このスケールフリーを実現するランダムグラフモデ ルが注目されるようになり, いくつかの異なるスケールフリーグラフモデル [3][17] が提案 されている.

2.3.2 Barabási-Albert \boldsymbol{O} Preferential attachment $\boldsymbol{\Xi}\boldsymbol{\mathcal{F}}\boldsymbol{\mathcal{V}}$

本論文では、いくつかの異なるスケールフリーグラフモデルの中で、最も広く受け入れ られている、Barabási と Albert による preferential attachment モデル [3] を採用する.

このグラフモデルは, グラフに新しい頂点を加えていき, 新しい頂点は次数の大きい頂 点との間に優先的に辺を張るということを繰り返しグラフを生成していく.

Preferential attachment モデルは, Bollobás らによって次のように一般化されている [7].

 各時刻 t で, 頂点 v_t を加え, v_t とある頂点 u の間に 1 つの辺を張る. u は次の確率分 布に従ってランダムに選択される.

$$\mathbf{Pr}(u = v_i) = \begin{cases} \frac{d_{t-1}(v_i)}{2t-1} & \text{if } v_i \neq v_t, \\ \frac{1}{2t-1} & \text{if } v_i = v_t. \end{cases}$$
(2.6)

ここで, $d_{t-1}(v)$ は時刻 t-1の終わりでの頂点 vの次数を表す.

*m*は任意の定数で、時刻 *t* ≡ 0 (mod *m*)のとき、*t*,*t* − 1,*t* − 2,···,*t* − *m* + 1 で加えられた *m* 頂点を 1 つの頂点にまとめる.

このグラフの次数分布は

$$P(k) = \frac{2m^3}{k^3}$$
(2.7)

となることが示されている.また,このモデルは非常に簡潔なモデルではあるが,セルフループや多重辺が存在する可能性があることには注意しなければならない.

2.3.3 有向スケールフリーグラフ

本研究では、Bollobás らよって提案された次の有向スケールフリーグラフモデル [6] を 採用する. このグラフモデルの基本的なアイデアは Barabási らの preferential attachment モデルと同じであるが、Web グラフなどが持つ、入次数と出次数で異なるべき乗の指数を とるという性質を満たした有向スケールフリーグラフを生成することができる. 各時刻 t で、次のルールにしたがって、グラフは成長していく.

- 確率 α で, 頂点 v を加え, v からある頂点 w へ 1 つ辺を張る. w は (2.8) の確率分布 に従ってランダムに選択される.
- 確率 β で,ある頂点 v からある頂点 w へ 1 つの辺を張る. w, v はそれぞれ (2.9), (2.8)
 の確率分布に従ってランダムに選択される.
- 確率 γ で, 頂点 w を加え, ある頂点 v から w へ1つの辺を張る. v は (2.9) の確率分 布に従ってランダムに選択される.

$$\mathbf{Pr}(w = v_i) = \frac{d_{in}(v_i) + \delta_{in}}{t + \delta_{in}n(t)}$$
(2.8)

$$\mathbf{Pr}(v = v_i) = \frac{d_{out}(v_i) + \delta_{out}}{t + \delta_{out}n(t)}$$
(2.9)

ここで, $d_{out}(v)$ は頂点 v の出次数, $d_{in}(v)$ は頂点 v の入次数, n(t) は時刻 t での頂点数を表 し, α , β , γ , δ_{in} , δ_{out} は非負の実数で, $\alpha + \beta + \gamma = 1$ である.

Web グラフは入次数と出次数で異なるべき乗の指数をとることが測定されていて, Broder らによると $\gamma_{IN} = 2.1, \gamma_{OUT} = 2.7$ である [8]. それを再現する各パラメータの値は, $\alpha = 0.41$, $\beta = 0.49, \gamma = 0.1, \delta_{in} = 0, \delta_{out} = 0$ または, $\alpha = 0.41, \beta = 0.59, \gamma = 0, \delta_{in} = 0.24, \delta_{out} = 0$ である.

第3章 ランダムウォークモデル

3.1 マルコフチェーン

3.1.1 マルコフチェーン

ランダムウォークについて考えるとき、しばしば、マルコフチェーンという概念が使われる [14][18]. マルコフチェーン *M*は、遷移確率行列 *P*で有限状態集合 *S*を表す散時間確率過程である.マルコフチェーンは、1つの状態から、離散時刻 t = 1, 2, ...で状態遷移していく.すなわち、全ての $i, j \in S$ に対して、 $0 \leq p_{ij} \leq 1$ かつ $\sum_{j} p_{ij=1}$ である.また、マルコフチェーンの未来の振る舞いは現在の状態にだけ依存し、どのようにして現在の状態になったかには依存しない (memoryless property) ので、遷移確率 p_{ij} は、現在の状態 i だけに依存することになる.

3.1.2 既約性

有限状態集合 $S = \{s_1, s_2, ..., s_k\}$, 状態遷移確率行列 P のマルコフチェーン M について, 全ての $s_i, s_j \in S$ に関して s_i から s_j への遷移, s_j から s_i への遷移が共に可能ならば, マルコフチェーン M は既約であると言う. マルコフチェーン M が既約であるならば, 任意の $s_i, s_j \in S$ に関して, $[\mathbf{P}^n]_{i,j} > 0$ となる n を見つけることができる.

3.1.3 非周期性

状態*i*の周期*d*(*i*)は,状態が*s_i*からスタートして,*s_i*に戻ってくるまでの数の最大公約数として定義される. *d*(*i*) > 1のとき,状態*s_i*は周期的であり,*d*(*i*) = 1のとき,状態*i*は非周期である. マルコフチェーン M の全ての*s_i* \in *S*に関して,状態*s_i*が非周期であるとき,マルコフチェーン Mは非周期的であると言う.

3.1.4 定常分布

時刻 *t* におけるマルコフチェーン \mathcal{M}_G の状態確率分布 $q^{(t)} = (q_1^{(t)}, q_2^{(t)}, \dots, q_k^{(t)})$ は, 列ベ クトルで, その *i* 成分 $q_i^{(t)}$ は時刻 *t* で状態が *i* である確率を表す. 時刻 *t* + 1 における確率 分布 q^{t+1} は, 遷移確率行列 P と時刻 t における確率分布 q^t によって次のように表される.

$$\boldsymbol{q}^{t+1} = \boldsymbol{q}^t \boldsymbol{P} \tag{3.1}$$

遷移確率行列 Pのマルコフチェーンの定常分布は、

$$\boldsymbol{\pi} = \boldsymbol{\pi} \boldsymbol{P} \tag{3.2}$$

を満たす確率分布 π である. 時刻 t における定常分布は, 時刻 t +1 においても変化しない ので, この定常分布は, マルコフチェーンの定常状態を表している.

マルコフチェーン M が既約, 非周期的であるとき, マルコフチェーン M は, ただ1つ の定常分布 π を持つ.

3.2 ランダムウォーク

3.2.1 シンプルランダムウォーク

ランダムウォークは,与えられたグラフ構造の上で確率的に選択された頂点に移動して いくプロセスである.

シンプルランダムウォークムは,最も標準的なランダムウォークで,単にランダムウォー クと呼ばれることもある.連結グラフ*G*(*V*,*E*)上のシンプルランダムウォークは以下のよ うな,連続する離散ステップである.

- 頂点 $v_0 \in V$ をスタートする.
- 頂点 v_0 から, v_0 の隣接点の中から同じ確率で選択された頂点 $v_1 \in N(v_0)$ へ移動する.

各々のステップにおいてどの頂点が選択されるかは,その前にどの頂点が選択されてい るか,ということとは完全に独立である.

無向連結グラフG = (V, E)上のシンプルランダムウォークをマルコフチェーン \mathcal{M}_G で モデル化すると, 状態集合 S は頂点集合 V, 遷移確率行列 \mathbf{P} は $P = (p_{uv})_{u,v \in V} \in [0, 1]^{V \times V}$ となり, 頂点 u から頂点 v への遷移確率 p_{uv} は

$$p_{uv} = \begin{cases} \frac{1}{deg(u)} & \text{if } v \in N(u) ,\\ 0 & \text{otherwise,} \end{cases}$$
(3.3)

によって定義される. ただし N(u) は頂点 u の隣接頂点集合で, deg(u) = |N(u)| である.

3.2.2 シンプルランダムウォークの定常分布

連続グラフで, 無向グラフかつ2部グラフでないグラフ*G*(*V*,*E*)上のシンプルランダム ウォークの定常分布について考える [14][18].

補題 3.1. グラフ*G*上のシンプルランダムウォークにおいて,全ての $v \in V$ における定常 分布 π_v は,

$$\pi_v = \frac{\deg(v)}{2m} \tag{3.4}$$

である. ただし, m = |E|.

証明. グラフGは, 連結グラフなので既約であり, 無向グラフありかつ2部グラフでない ので非周期的であるので, マルコフチェーン M_G は, ただ1つの定常分 π を持つ. したがっ て, $\pi_v = \frac{deg(v)}{2m}$ であれば, $\pi P = \pi$ が成り立つことを示せばよい. $\hat{\pi} = \pi P$ とすると,

$$\begin{split} \tilde{\pi}_v &= \sum_{u \in N(v)} \pi_u p_{uv} \\ &= \sum_{u \in N(v)} \frac{deg(u)}{2m} \times \frac{1}{deg(u)} \\ &= \sum_{u \in N(v)} \frac{1}{2m} \\ &= \frac{deg(v)}{2m}. \end{split}$$

3.2.3 ヒッティングタイム

ヒッティングタイム (hitting time) h_{uv} は, 連結グラフ上のランダムウォークで頂点 u をスタートとして, 最初に頂点 v に訪れるまでに必要なステップ数の期待値である. ここ で, 全ての $v \in V$ に対して h_{vv} は,

$$h_{vv} = \frac{1}{\pi_v} = \frac{2m}{deg(v)} \tag{3.5}$$

である.

3.2.4 カバータイム

頂点uにおけるカバータイム (cover time) C_u は,連結グラフG上のランダムウォーク で,uをスタートとして,全ての頂点を訪れるまでに必要なスッテプ数の期待である.(最大)カバータイム C_G は,

$$\mathcal{C}_G = \max_{u \in V} \mathcal{C}_u \tag{3.6}$$

である. また, 平均カバータイム \bar{C}_G は,

$$\bar{\mathcal{C}}_G = \sum_{u \in V} \frac{\mathcal{C}_u}{n} \tag{3.7}$$

である.本研究の計算機実験においては,この平均カバータイムをランダムウォークにお ける指標として用いることにする.

シンプルランダムウォークにおけるカバータイムの上界は, n = |V|, m = |E|を用いて $2m(n-1) = O(n^3)$ で表される.また下界は, n/2頂点のクリークと残りの頂点のパスか らなる lollipop グラフ L_n 上で $\Omega(n^3)$ で抑えられるので, シンプルランダムウォークのカ バータイムは $\Theta(n^3)$ である [15].



 \boxtimes 3.1: L_{15}

3.2.5 Cooper-Frieze による理論的解析

Cooper と Frieze は理論的解析により, n 頂点, m 本づつ辺が付け加えられる preferential attachment グラフ $G_m(n)$ におけるシンプルランダムウォークで, カバータイム $C_{G_m(n)}$ が, 高い確率で,

$$\mathcal{C}_{G_m(n)} \sim \frac{2m}{m-1} n \log n = O(n \log n)$$
(3.8)

となることを示している [9][10].

3.3 局所情報を用いたランダムウォーク

3.3.1 池田らのランダムウォーク

従来のシンプルランダムウォークは遷移確率がそれぞれの頂点 *u* における次数 *deg(u)* の みに依存しているが, 池田らはさらなる局所情報を利用することによって, ランダムウォー クのヒッティングタイムやカバータイムを改善できるのではないかと考え, 隣接点の次数

情報 $deg(v \in N(u))$ を利用した, 新しい局所情報を用いたランダムウォーク [16] を提案した. このモデルにおける遷移行列 $P^{(\beta)} = (p_{uv}^{(\beta)})_{u,v \in V}$ は

$$p_{uv}^{(\beta)} = \frac{\exp[-\beta U(u,v)]}{\sum_{\omega \in N(u)} \exp[-\beta U(u,\omega)]} \text{ for } v \in N(u)$$
(3.9)

によって定義される.この遷移確率は $\beta = 0$ のとき,従来のシンプルランダムウォークの 遷移確率と一致し、このモデルが従来のモデルの自然な拡張であることがわかる.また、こ の分布関数は、統計力学においてギブス分布として知られている.

池田らは, 最初にポテンシャル関数 U(u, v) を

$$U(u,v) = \log(\max\{deg(u), deg(v)\})$$
(3.10)

と定義したが, 次のポテンシャル関数U(u,v)の方がより (定数倍程度ではあるが) より良い結果を与えることを示している.

$$U(u,v) = U(v) = \log(\deg(v)) \tag{3.11}$$

式 (3.9) に式 (3.11) を代入すると,

$$p_{uv}^{(\beta)} = \frac{\deg(v)^{-\beta}}{\sum_{\omega \in N(u)} \deg(\omega)^{-\beta}} \text{ for } v \in N(u)$$
(3.12)

となり, 遷移確率は各頂点の次数のべき乗型分布関数に従うことがわかる.

一般のグラフに対しては $\beta = 1/2$ のときカバータイム $C^{1/2}$ が

$$\mathcal{C}^{1/2} = O(n^2 \log n) \tag{3.13}$$

であることを示している [15][16].

3.3.2 ポテンシャル関数の改良

本研究では,スケールフリーグラフ上における局所情報を用いたランダムウォークのさ らなる効率化を目指して,ポテンシャル関数の改善を試みた.スケールフリーグラフでは, 頂点の次数分布はベキ則にしたがう.そのため,次数分布は指数関数的に極端に偏ってい る. この事実から,次数分布を線形に補正することでより良い振る舞いをするランダム ウォークのポテンシャル関数を設計できると予想した.そこで,ポテンシャル関数 U(u,v) を

$$U(u,v) = U(v) = \log \log(\deg(v))$$
(3.14)

と定義した. このとき,

$$p_{uv}^{(\beta)} = \frac{(\log \deg(v))^{-\beta}}{\sum_{\omega \in N(u)} (\log \deg(\omega))^{-\beta}} \text{ for } v \in N(u)$$
(3.15)

となり, 遷移確率は各頂点の次数の対数のべき乗型分布関数に従うことがわかる.

3.3.3 有向スケールフリーグラフ上のランダムウォーク

本論文では池田らのランダムウォークモデルで, 逆方向に対して確率 $\gamma(0 < \gamma \le 1)$ で辿ることを許したランダムウォークを提案する.

ここでは, 有向グラフ上の次数を (3.16) で定義し, 遷移確率は, 順辺に対しては (3.17), 逆辺に対しては (3.18) とした.

$$deg(v) = in_deg(v) + \gamma \cdot out_deg(v)$$
(3.16)

$$p_{OUTuv}^{(\beta,\gamma)} = \frac{\deg(v)^{-\beta}}{\sum_{\omega \in OUT(u)} \deg(\omega)^{-\beta} + \sum_{\omega \in IN(u)} \gamma \cdot \deg(\omega)^{-\beta}}$$
(3.17)

$$p_{INuv}^{(\beta,\gamma)} = \frac{\gamma \cdot deg(v)^{-\beta}}{\sum_{\omega \in OUT(u)} deg(\omega)^{-\beta} + \sum_{\omega \in IN(u)} \gamma \cdot deg(\omega)^{-\beta}}$$
(3.18)

3.4 その他のランダムウォーク

3.4.1 ページランク

最も人気の高い検索エンジンの1つである google では, ページランクと呼ばれる Web ページの価値を評価するアルゴリズムにおいて, ランダムウォーク (マルコフチェーン) の 理論を利用している.

uをある Web ページすると, ページuの (シンプルな) ページランク R_u は次のように 定義される.

$$R_u = c \sum_{v \in IN(u)} \frac{R(v)}{out_deg(v)}$$
(3.19)

このページランクは理論的には,シンプルランダムウォークの定常分布と一致することが 示されている [19].

第4章 計算機実験

4.1 実装

実装には、C++言語を使用した. C++クラスライブラリーである boost Libralies[2] を 用いて、乱数発生アルゴリズムには mt19937 を使用した. グラフライブラリーとしては、 boost graph Libralies を利用した. 計算機は、主に情報科学センターの SGI Altix3700 (Intel® Itanium® 2 プロセッサ ×128) を使用した.

4.2 無向スケールフリーグラフ上における実験結果



図 4.1: 無向スケールフリーグラフの次数分布 (n = 1000)

図 4.1 は, preferential attachment グラフモデルの次数分布をパラメータmごとに理論 値及び実験値 (ex.) を表したものである.

4.2.1 次数べき乗型を用いた場合



図 4.2: 次数べき乗型 β vs. \overline{C} (n = 1000)

図 4.2,4.3 は, n = 1000 のときの各 m の局所情報を用いたランダムウォークのパラメー タ β に対するカバータイムである. m によって, カバータイムの最低値を与える β が異る ことがわかる. $\beta = 0$ のときの従来のシンプルランダムウォークよりも, 最適な β のとき はカバータイムが改善されていることがわかる.

図 4.4 は, 図 4.2 の最小値を与える β を最小自乗法により求め, 頂点数 n, グラフパラメー タ m の関数として表示したものである. その最適値は, グラフのサイズ n にはほとんど依 存せず, m の関数とみなすことができることがわかった.

図 4.7 は, n = 1000 のときの各 m に対する最適な β を表したものである. m = 2から m = 10 にかけて, 最適な β の値は, 線形に単調増加していき, m = 10 以降では, 最適な β の値は 1 程度にに収束していることがわかる. 図 4.5, 4.6 は, その最適な β に対するカバー タイムをグラフパラメータ m の関数として表示したものである.

図 4.8 は, n = 1000 のときに, シンプルランダムウォークに対する局所情報を用いたラ ンダムウォークの改善率を, $m \ge \beta$ の関数として表したものである.また, 図 4.9 は, 各 mのときのシンプルランダムウォークに対する局所情報を用いたランダムウォークの改善率 を表している.2つの図から, m = 10 にかけては, mが大きくなるに従って改善の割合は 良くなり, m = 10 以降では, 最適な β の値が収束すると同時に, 改善率も 0.35 程度に収束 していくことがわかる.



図 4.3: 次数べき乗型 m vs. β vs. $\bar{\mathcal{C}}$ (n = 1000)



図 4.4: 次数べき乗型 n vs. m vs. 最適な β



図 4.5: 次数べき乗型と次数の対数べき乗型 m vs. 最適な $\beta \sigma \overline{C}$ (n = 1000)



図 4.6: 次数べき乗型, 次数の対数べき乗型, シンプルランダムウォーク ($\beta = 0$) 及び Cooper et al. のシンプルランダムウォークに対する理論的上界 m vs. 最適な β の \bar{C} (n = 1000)



図 4.7: 次数べき乗型と次数の対数べき乗型 m vs. 最適な β (n = 1000)



図 4.8: 次数べき乗型 m vs. β vs. シンプルランダムウォーク ($\beta = 0$) に対する改善率 (n = 1000)



図 4.9: 次数べき乗型と次数の対数べき乗型 m vs. シンプルランダムウォーク ($\beta=0)$ に 対する改善率 (n=1000)

表 4.1: 次数べき乗型 各mに対する最適な β

\boldsymbol{m}	最適な eta
2	0.1983
4	0.3103
8	0.9388
20	1.026

図 4.10 は, 頂点数 n = 1000, グラフパラメータ m = 2のときの, 各次数の頂点に対する 訪問数の平均を表したものである. 表 4.1 より, m = 2のときの最適な β は, $\beta = 0.1983$ で ある. これは, 最小自乗法より求められた値であるので, その値に近い $\beta = 0.20$ のときと, それ以外のいくつかの β の値で比較している. 最適値に近い $\beta = 0.20$ では, $\beta = 0$ のシン プルランダムウォークに対して, ほぼ全ての次数での訪問数が下回っていることが確認で きる. 特に, 次数の高い頂点での訪問数が, 目立って改善されている. $\beta = 1.00, 1.60$ のと きは, 均一化していてより良い結果を与えるように思われるが, 小さな次数での訪問数が, シンプルランダムウォークに比べて多くなってしまっていることが, 全体としてカバータ イムを悪化させている. 図 4.1 からもわかるように, 次数が小さくなるにしたがって頂点 数は指数関数的に増加するので, 小さな次数への訪問数の増加は, カバータイムに対して 大きな影響を与える.

図 4.11 は, スケールフリーグラフのパラメータ m = 4のときの, 各次数の頂点に対する 訪問数の平均を表したものである.表4.1 より, m = 4のときの最適な β は, $\beta = 0.3103$ であり, その値に近い $\beta = 0.31$ のときと, それ以外のいくつかの β の値で比較している. m = 2ときと同じく, 最適値に近い $\beta = 0.31$ では, $\beta = 0$ のシンプルランダムウォークに 対して, ほぼ全ての次数での訪問数が下回り, $\beta = 1.00, 1.60$ のときは, 小さな次数での訪 問数が, シンプルランダムウォークに比べて増加している.

図 4.12,4.13 は, m = 8,20のときの,各次数の頂点に対する訪問数の平均を表したもの である.表 4.1 より, m = 8のときの β の最適値は $\beta = 0.9388$, m = 20のときの最適値は $\beta = 1.026$ である.それぞれの最適値に近い $\beta = 0.94, 1.03$ のときの訪問数は共に,小さな 次数で,わずかにシンプルランダムウォーク ($\beta = 0$)の訪問数を越えているが,全体的に は均一な分布で,シンプルランダムウォークの訪問数を下回っている.

m = 2,4の小さなmのときに比べて,m = 8,20の大きなmのときは,カバータイム及 びその改善率が良い結果を与えている.小さなmのとき,スケールフリーグラフは疎なグ ラフとなり,直径が大きいためにカバータイムは悪化する.また,このとき,次数の高い頂 点はハブとなっていて,次数の低い頂点の多くは,そのハブのどれかと接しているため,全 ての頂点を訪れるために,次数の高い頂点への訪問数を大きく下げることは難しい.その ため,最適な β に対しても図 4.10, 4.11 のような分布になる.

大きな m のとき, スケールフリーグラフは密なグラフで直径は比較的小さく, カバータ イムは小さな m と比べて改善する.同時に, 小さな次数の頂点は, いくつかのハブと接し ていたり, 小さい次数同士が接している確率がより高くなるので, 必ずしも高い次数の頂 点を多く訪問しなくても, グラフ全体をカバーできる.その結果, 図 4.12, 4.13 のように, 最適な β のとき, シンプルランダムウォークの偏った分布から, 訪問数を均一化すること が可能であると考えることができる.



図 4.10: 次数べき乗型 各次数の頂点に対する訪問数 (n = 1000, m = 2)



図 4.11: 次数べき乗型 各次数の頂点に対する訪問数 (n = 1000, m = 4)



図 4.12: 次数べき乗型 各次数の頂点に対する訪問数 (n = 1000, m = 8)



図 4.13: 次数べき乗型 各次数の頂点に対する訪問数 (n = 1000, m = 20)



4.2.2 次数の対数べき乗型を用いた場合

図 4.14: 次数の対数べき乗型 β vs. \overline{C} (n = 1000)

図 4.14,4.15 は, 次数の対数べき乗型の局所情報を用いたランダムウォークにおける, n = 1000, 各 $m \circ \beta$ に対するカバータイムを表したものである. 図 4.2,4.3 と比較して, 最 適な β の値が大きくなっていることがわかる. これは, 次数のべき乗が, 次数の対数のべ き乗に置き換わることによって, 重みが弱められているので, β を大きくすることでキャ ンセルしていると考えられる.

図 4.16 は、図 4.4 と同じく、最小値を与える β を最小自乗法により求め、頂点数 n、グラフパラメータ m の関数として表示したものである. 図 4.7、4.16 より、次数の対数べき乗型 の最適な β は、次数べき乗型に比べて大きな値をとる. また、m が増加していくときの、 β が収束する速さも、次数べき乗型に比べて遅く、m = 20のときでも、4 程度である.

図 4.17, 4.18, 4.19, 4.20 は, それぞれ *m* = 2, 4, 8, 20, *n* = 1000 のとき, 次数べき乗型と 次数の対数べき乗型の β に対するカバータイムを比較したものである.

図 4.21 は, n = 1000 のときに, シンプルランダムウォークに対する局所情報を用いた ランダムウォークの改善率を, $m \ge \beta$ の関数として表したものである. 図 4.9, 4.21 から, m = 2からm = 8にかけて, 次数べき乗型に対する改善の割合は良くなっていることがわ かる. 最も改善の効果が大きい, m = 4からm = 7では 0.05 程度の改善率を示している. mが増加するにしたがって, 次数べき乗型に対する改善率は減少し, 次数べき乗型と次数 の対数べき乗型のカバータイムは, ほぼ一致するものになる.



図 4.15: 次数の対数べき乗型 m vs. 最適な β vs. $\bar{\mathcal{C}}~(n=1000)$



図 4.16: 次数の対数べき乗型 n vs. m vs. 最適な β



図 4.17: 次数べき乗型と次数の対数べき乗型 (n = 1000, m = 2)



図 4.18: 次数べき乗型と次数の対数べき乗型 (n = 1000, m = 4)



図 4.19: 次数べき乗型と次数の対数べき乗型 (n = 1000, m = 8)



図 4.20: 次数べき乗型と次数の対数べき乗型 (n = 1000, m = 20)



図 4.21: 次数の対数べき乗型 m vs. β vs. シンプルランダムウォーク ($\beta = 0$) に対する改善率 (n = 1000)

表 4.2: 次数の対数型の各 m に対する最適な β

\boldsymbol{m}	最適な eta
2	0.4918
4	1.032
8	2.706
20	3.997

図 4.22 は, 頂点数 n = 1000, グラフパラメータ m = 2のときの, 各次数の頂点に対する 訪問数の平均を表したものである. 表 4.2 より, m = 2のときの最適な β は, $\beta = 0.4913$ で ある. これは, 最小自乗法より求められた値であるので, その値に近い $\beta = 0.50$ のときと, それ以外のいくつかの β の値で比較している. また, 図 4.23 は, このときの, 次数べき乗型 と次数の対数べき乗型の訪問数を比較したものである. 最適値に近い $\beta = 0.50$ では, 次数 べき乗型に対して, 特に小さな次数を除くほぼ全ての次数での訪問数がわずかであるが下 回っていることが確認できる.

図 4.24 は, スケールフリーグラフのパラメータ m = 4のときの, 各次数の頂点に対す る訪問数の平均を表したものである. 表 4.2 より, m = 4のときの最適な β は, $\beta = 1.032$ であり, その値に近い $\beta = 1.04$ のときと, それ以外のいくつかの β の値で比較している. また, 図 4.25 は, このときの, 次数べき乗型と次数の対数べき乗型の訪問数を比較したも のである. m = 2ときと同じく, 最適値に近い $\beta = 1.04$ では, $\beta = 0$ のシンプルランダム ウォークに対して, 特に小さな次数を除くほぼ全ての次数での訪問数が下回り, m = 2の ときよりもさらに改善の割合は増加している.

図 4.26,4.28 は, m = 8,20のときの, 各次数の頂点に対する訪問数の平均を表したもの である.表4.2 より, m = 8のときの β の最適値は $\beta = 2.706$, m = 20のときの最適値は $\beta = 3.997$ である. それぞれの最適値に近い $\beta = 2.70, 4.00$ のときの訪問数は共に, 小さな次 数で, わずかにシンプルランダムウォーク ($\beta = 0$)の訪問数を越えているが, 全体的には均 一な分布で, シンプルランダムウォークの訪問数を下回っている.また, 図 4.27,4.29 は, こ のときの, 次数べき乗型と次数の対数べき乗型の訪問数を比較したものである.m = 8,20のとき, 高い次数で次数の対数べき乗型の訪問数が上回っている. 図 4.9 から, m = 2のと きと, m = 8のときの改善率は同程度であることがわかるが, m = 8のときの訪問数の分 布図 4.27 は, m = 2のときの訪問数の分布図 4.23 とは大きく異なり, m = 20のときの訪 問数の分布 4.29 に近い分布となっていることがわかる. 図 4.5, 4.9 から, mの値が大きく なっていくにしたがい, 次数べき乗型と次数の対数べき乗型のカバータイムは, 同じ値に 近づいていくことがわかるが, 訪問数の分布から, そのランダムウォークの振る舞いは, 異 なっていると考えることができる.



図 4.22: 次数の対数べき乗型 各次数の頂点に対する訪問数 (n = 1000, m = 2)



図 4.23: 次数べき乗型と次数の対数べき乗型における最適な β での各次数の頂点に対する訪問数の比較 $(n=1000,\,m=2)$



図 4.24: 次数の対数べき乗型 各次数の頂点に対する訪問数 (n = 1000, m = 4)



図 4.25: 次数べき乗型と次数の対数べき乗型における最適な β での各次数の頂点に対する訪問数の比較 $(n=1000,\,m=4)$



図 4.26: 次数の対数べき乗型 各次数の頂点に対する訪問数 (n = 1000, m = 8)



図 4.27: 次数べき乗型と次数の対数べき乗型における最適な β での各次数の頂点に対する訪問数の比較 (n = 1000, m = 8)



図 4.28: 次数の対数べき乗型 各次数の頂点に対する訪問数 (n = 1000, m = 20)



図 4.29: 次数べき乗型と次数の対数べき乗型における最適な β での各次数の頂点に対する訪問数の比較 (n = 1000, m = 20)

4.3 有向スケールフリーグラフ上における実験結果



図 4.30: 有効スケールフリーグラフの次数分布 ($t = 1000, n \sim 410, \alpha = 0.41, \beta = 0.59, \gamma = 0, \delta_{in} = 0.24, \delta_{out} = 0$)

図 4.30 は, $t = 1000, \alpha = 0.41, \beta = 0.59, \gamma = 0, \delta_{in} = 0.24, \delta_{out} = 0$ のときの Bollobás ら の有向スケールフリーグラフ [6] の入次数分布, 出次数分布の理論値及び実験値 (ex.) を表 したものである.

4.3.1 逆辺をたどることを許した場合

Bollobás らの有向 スケールフリーグラフにおいて, 入次数, 出次数に関して Web グラ フを再現するとされたパラメータ $t = 1000, \alpha = 0.41, \beta = 0.59, \gamma = 0, \delta_{in} = 0.24, \delta_{out} = 0$ に対して, 各 γ における最適な β の値を求め, 隣接点の次数情報を使わない random walk ($\beta = 0$)の結果と比較した.

このとき, t = 1000 で生成されるグラフの頂点数nは, $n \sim 410$ と小さいことに注意する必要がある. t = 1000 程度としたのは, $\gamma = 0.01$ のときにおいてでさえ, カバータイムが最大で 1000^2 程度となるからである.

図 4.31 は, t = 1000 のときの各 γ の逆辺をたどることを許した局所情報を用いたランダ ムウォークのパラメータ β に対するカバータイムである.特に, $\gamma = 0.01$ のときの局所情



図 4.31: 逆辺をたどることを許した型 β vs. $\bar{\mathcal{C}}$ (t = 1000,n ~ 410, α = 0.41, β = 0.59, $\gamma = 0, \, \delta_{in} = 0.24, \, \delta_{out} = 0$)



図 4.32: 逆辺をたどることを許した型 γ vs. $\bar{\mathcal{C}}$ (t = 1000,n ~ 410)

報を用いないランダムウォーク ($\beta = 0$)のカバータイムが 1000² 程度と悪化していることがわかる. 図 4.32 は, その最適な β に対するカバータイムをグラフパラメータ γ の関数として表示したものである.



図 4.33: 逆辺をたどることを許した型 γ vs. β vs. $\beta = 0$ に対する改善率 ($t = 1000, n \sim 410, \alpha = 0.41, \beta = 0.59, \gamma = 0, \delta_{in} = 0.24, \delta_{out} = 0$)

図 4.33 は, t = 1000のときに, $\beta = 0$ のときのカバータイムに対するの改善率を, $\gamma \ge \beta$ の関数として表したものである.また, 図 4.34 は, 各 γ のときの, 最適な β のときの改善率を表している.図 4.31,4.32,4.33,4.34 より, γ の値が小さくなるにしたがって, $\beta = 0$ のときのカバータイムは,指数関数的に悪化していくが,最適な β のカバータイムはある程度低い値に抑えられており,その結果,改善率が向上していると考えられる.

図 4.35 は, t = 1000 のときの各 γ に対する最適な β を表したものである. 最適な β の値は, 指数関数的に増加していることがわかる.



図 4.34: 逆辺をたどることを許した型 γ vs. $\beta=0$ に対する改善率 $(t=1000,n\sim410)$



図 4.35: 逆辺をたどることを許した型 γ vs. 最適な $\beta~(t=1000,n\sim410)$

表 4.3: 逆辺をたどることを許した型 各 γ に対する最適な β

γ	最適な eta
0.01	0.5116
0.1	0.4060
0.5	0.2571
1.0	0.1740

図 4.36,4.37,4.38 は、頂点数 t = 1000, $\gamma = 0.01$ のときの、各次数、入次数、出次数の頂 点に対する訪問数の平均を表したものである.表 4.3 より、 $\gamma = 0.01$ のときの最適な β は、 $\beta = 0.5116$ である.その値に近い $\beta = 0.51$ のときと、それ以外のいくつかの β の値で比較 している、全ての次数、入次数、出次数での訪問数が $\beta = 0$ のときを大きく下回っている ことが確認できる.

図 4.39,4.40,4.41 は, 頂点数 t = 1000, $\gamma = 0.10$ のときの, 各次数, 入次数, 出次数の頂 点に対する訪問数の平均を表したものである.表 4.3 より, $\gamma = 0.10$ のときの最適な β は, $\beta = 0.4060$ である.その値に近い $\beta = 0.41$ のときと, それ以外のいくつかの β の値で比較 している. $\gamma = 0.01$ のときと同じく, 全ての次数, 入次数, 出次数での訪問数が $\beta = 0$ のと きを大きく下回っていることが確認できる.

図 4.42,4.43,4.44 は, $\gamma = 0.50$ のときの, 各次数, 入次数, 出次数の頂点に対する訪問数の 平均を表したものである.表4.3 より, $\gamma = 0.50$ のときの最適な β は, $\beta = 0.2571$ である. その値に近い $\beta = 0.26$ のときと, それ以外のいくつかの β の値で比較している.全ての次 数,入次数,出次数での訪問数が $\beta = 0$ のときを下回っているが,特に,大きな次数,入次 数,出次数での訪問数が $\beta = 0$ のときを大きく下回っていることがわかる.

図 4.45,4.46,4.47 は, $\gamma = 1.00$ のときの,各次数,入次数,出次数の頂点に対する訪問数 の平均を表したものである.表 4.3 より, $\gamma = 0.50$ のときの最適な β は, $\beta = 0.1740$ であ る.その値に近い $\beta = 0.17$ のときと,それ以外のいくつかの β の値で比較している.小さ い次数,入次数,出次数での訪問数は $\beta = 0$ のときと同程度であるが,特に大きな次数,入 次数,出次数での訪問数が $\beta = 0$ のときを下回っていることがわかる.

有効スケールフリーグラフ上で, 逆辺をたどることを許した型では, γ が減少するにしたがって, カバータイムが悪化し, 改善率は向上した. これは, m が増加するにしたがって, カバータイム, 改善率共に向上した, 無向スケールフリーグラフ上の場合と逆であることに注意したい.



図 4.36: 逆辺をたどることを許した型 各次数の頂点に対する訪問数 ($t = 1000, \gamma = 0.01$)



図 4.37: 逆辺をたどることを許した型 各入次数の頂点に対する訪問数 (t = 1000, γ = 0.01)



図 4.38: 逆辺をたどることを許した型 各出次数の頂点に対する訪問数 ($t = 1000, \gamma = 0.01$)



図 4.39: 逆辺をたどることを許した型 各次数の頂点に対する訪問数 (t = 1000, γ = 0.10)



図 4.40: 逆辺をたどることを許した型 各入次数の頂点に対する訪問数 (t = 1000, γ = 0.10)



図 4.41: 逆辺をたどることを許した型 各出次数の頂点に対する訪問数 (t = 1000, γ = 0.10)



図 4.42: 逆辺をたどることを許した型 各次数の頂点に対する訪問数 ($t = 1000, \gamma = 0.50$)



図 4.43: 逆辺をたどることを許した型 各入次数の頂点に対する訪問数 (t = 1000, γ = 0.50)



図 4.44: 逆辺をたどることを許した型 各出次数の頂点に対する訪問数 (t = 1000, $\gamma = 0.50)$



図 4.45: 逆辺をたどることを許した型 各次数の頂点に対する訪問数 (t = 1000, γ = 1.00)



図 4.46: 逆辺をたどることを許した型 各入次数の頂点に対する訪問数 (t = 1000, γ = 1.00)



図 4.47: 逆辺をたどることを許した型 各出次数の頂点に対する訪問数 (t = 1000, γ = 1.00)

第5章 おわりに

本論文では、スケールフリーグラフ上での効率の良い ランダムウォークを実験的に示した.

スケールフリーグラフ上の従来のシンプルランダムウォークに関して, Cooper, Frieze は カバータイムなどに対する理論的な解析を行なって, 正確な上界や下界を得ている [9][10]. 彼らの手法を拡張して, スケールフリーグラフ上の池田らの ランダムウォークの理論的な 解析を行うことが今後の課題である.

謝辞

本研究の遂行にあたり,上原隆平助教授には,常に熱心にご指導いただき,深く感謝いたします.浅野哲夫教授,元木光雄助手,寺本幸生氏をはじめとする情報基礎学講座の学生の皆様,九州大学大学院システム情報科学研究院山下雅史教授と,山下研究室の定兼邦彦助教授,小野廣隆助手,来見田裕一氏には,数多くの有益な助言やご支援をいただき,深く感謝します.また本研究は文部科学省科学研究費補助金(基盤研究(C)18244120)の支援を受けて行なった.最後に,研究生活を支援してくれた家族に感謝の意を記したいと思います.

参考文献

- [1] [online]Available from: http://www.google.com/.
- [2] [online]Available from: http://www.boost.org/.
- [3] A.-L. Barabási and R. Albert. Emergence of scaling in random networks. *Science*, 286(5439):509-512, 1999.
- [4] B. Bollobás. Modern Graph Theory. Number 184 in Graduate Texts in Mathematics. Springer, New York NY, 1998.
- [5] B. Bollobás. Random Graphs. Cambridge studies in advanced mathematics, 2001.
- [6] B. Bollobás. Directed scale-free graphs. In ACM Symposium on Discrete Algorithms (SODA), pages 132–139, 2003.
- [7] B. Bollobás, O. Rordan, J. Spencer, and G. Tusnady. The degree sequence of a scale-free random graph process. *Random Structures and Algorithms*, 18:279–290, 2001.
- [8] A. Broder, R. Kumar, F. Maghoul, P. Raghavan, R. Stata, A. Tomkins, and J. Wiener. Graph structure in the web. In *Proceedings of the 9th International World Wide Web Conference*, pages 247-256, 2000. Available from: http: //www.almaden.ibm.com/cs/k53/www9.final/.
- [9] C. Cooper and A. Frieze. The cover time of the preferential attachment graph, manuscript, 2005.
- [10] C. Cooper and A. Frieze. The Cover Time of Two Classes of Random Graphs. In ACM Symposium on Discrete Algorithms (SODA), pages 961–970, 2005.
- [11] R. Fagin, A. R. Karlin, J. Kleinberg, P. Raghavan, S. Rajagopalan, R. Rubinfeld, M. Sudan, and A. Tomkins. Random walks with "back buttons". In ACM Symposium on Theory of Computing (STOC), pages 484–493, 2000.
- [12] A. Gibbons. Algorithmic Graph Theory. Cambridge University Press, 1985.

- [13] G. Grimmett and D. Stirzaker. Probability and Random Processes. OXFORD UNI-VERSITY PRESS, third edition, 2001.
- [14] O. Haggstrom. Finite markov chains and algorithmic applications. In London Mathematical Society. 2002.
- [15] S. Ikeda, I. Kubo, N. Okumoto, and M. Yamashita. Impact of local topological information on random walks on finite graphs. In Annual International Colloquium on Automata, Languages and Programming (ICALP), pages 1054–1067, 2003.
- [16] S. Ikeda, I. Kubo, and M. Yamashita. Reducing the hitting and the cover times of random walks on finite graphs by local topological information. In *Proceedings of the International Conference on VLSI (VLSI)*, pages 203–207, 2003.
- [17] N. Masuda, H. Miwa, and N. Konno. Geographical threshold graphs with small-world and scale-free properties. *PHYSICAL REVIEW E*, 71:036108, 2005.
- [18] R. Motwani and P. Raghavan. Randomized Algorithms. Cambridge University Press, Cambridge, UK, 1995.
- [19] L. Page, S. Brin, R. Motwani, and T. Winograd. The pagerank citation ranking: Bringing order to the web. Technical report, Computer Science Department, Stanford University, 1998. Available from: http://dbpubs.stanford.edu/pub/1999-66.