

SNS のネットワーク構造の分析とモデル推定

内 田 誠[†] 白 山 晋[†]

情報技術を基盤としたコミュニケーションネットワークの拡大は新たな社会現象をもたらしている。そのような現象は特に、SNS (Social Networking Service) やブログ (Weblog) に代表される Web 上のコミュニティの中でより顕著に見られる。これらは社会的なネットワークを形成することで、ユーザ同士の新しい情報基盤になるものとして注目されており、そこで生じる現象が情報社会全体に与える影響は大きいものと考えられている。したがって、そのような現象を理解するためには、そのネットワークの構造をはじめとする性質を分析することが有効であると考えられる。本稿では、実際の SNS のデータを用いて、そのネットワークを理論的なネットワークモデルとの比較を通じてその構造を分析する。そして、SNS ネットワークはこれまでに提案されたネットワークモデルでは表しえない特徴を持つことを示す。さらに、ネットワークの持つ機能に着目し、構造的な特徴と、構造に起因して生じる現象との関連から、SNS のネットワーク構造のモデルを推定する。

Analysis of Network Structure and Model Estimation for SNS

MAKOTO UCHIDA[†] and SUSUMU SHIRAYAMA[†]

Recent development of communication networks based on information technologies has been producing a lot of virtual communities. It is bringing a new kind of social phenomenon, especially on the communities on the world wide webs, such as SNS (Social Networking Service) and Weblog. It is considered that the SNS and the blogs are kinds of social networks of their users. From a viewpoint of the communication network, they become a new communication infrastructure and their influence become more profound. Because of this, the phenomena or functions observed in such networks are notable. In the latest studies on networks, some close relationships are pointed out between the structure and the function of networks. In this paper, we analyze a structure of a real SNS, comparing with several theoretical network models. We show that the SNS has a unique structure that conventional network models have not represented. Furthermore, taking notice of the function of the network, we estimate a model of the SNS network structure, based on the phenomena that derive from the network structure, as well as the structure itself.

1. はじめに

近年のコミュニケーションネットワークの急速な拡大は、ネットワーク上に多くのコミュニティを生み出している。また、コミュニティを介し、口コミによる急激な流行の拡大やウェブログによる世論形成といった新たな社会現象が生じている。特に、SNS (Social Networking Service) やブログは、社会的ネットワークそのものであり、コミュニケーションネットワークという観点からは、新しい情報基盤を形成するものと考えられている¹⁸⁾。SNS やブログは現在でも拡大を続けており^{*}、その上で起こる現象や事象は、情報社会全体に少なからぬ影響を与えるものと思われる。し

たがって、そのようなネットワークの性質を調べることに重要になる。

ネットワーク上の現象や事象は、ネットワーク構造に依存することが知られており⁹⁾、SNS やブログでも、ネットワークの構造が調べられ、スケールフリー性やスモールワールド性などの性質があることが報告された^{6),8)}。しかしながら、ネットワークの構造は複雑であり、その特徴を既存のネットワーク指標では十分に表しえないことも指摘されている¹⁷⁾。また、SNS やブログのネットワーク構造とネットワーク上の現象や事象の対応関係を明らかにするという研究は始められたばかりであり⁵⁾、ネットワーク構造の十分な分析が必要とされている。

[†] 東京大学人工工学研究センター
Reserch into Artifacts, Center for Engineering, The
University of Tokyo

^{*} mixi を運営する (株) ミクシィの報告には、1 日に 15,000 人
以上の登録があり、会員は約 300 万人 (2006 年 3 月 1 日現
在) とある。

本稿では、SNS に着目し、複雑ネットワーク分析の手法により、その構造や性質を明らかにする。さらに、ネットワークの構造に起因する現象に着目し、相互作用の単純なモデルを用いて、現象の構造依存性を数値実験によって調べる。また、これらのネットワーク構造分析の結果から、SNS のネットワーク構造モデルを推定する。

2. SNS と複雑ネットワーク

2.1 SNS (Social Networking Service)

SNS とは、WWW 上の会員制コミュニティサービスの総称である。主なものとして、国内では mixi[☆]や Gree^{☆☆}、海外では米国の Orkut^{☆☆☆}などがある。会員の紹介がなければ会員登録ができないという制度（インビテーション制）が特徴である。また、会員同士で紹介しあうことで、相互に友人として登録するというシステムを採用しているものが多い。このため、知り合い関係が明確に定義されている。本研究では、この知り合い関係をリンクと見なし、SNS に対してネットワークを形成することでその構造を分析する。

具体的には、国内大手 SNS の運営企業から直接提供を受けた実データを対象とする。提供を受けたデータはユーザと、互いに承認されたユーザ間の知り合い関係を表すリンクの情報からなる。なお、データからは個人を特定できる情報がいっさい消去されている。また、本研究では SNS 上に形成されている人的ネットワークの空間的な構造およびその上で起こる現象を解明することを目的としており、個人の特定や評価を行うことが目的ではないことを付記しておく。

2.2 社会的なネットワークの特徴

SNS のような社会的ネットワークにおいては、個人が周囲から受ける、あるいは周囲に与える影響は均質なものではない。多くの場合、不均一性や不完全性を有するものと考えられる。ネットワークに属する個人を主体と考えたときに、現実の社会的ネットワークでは、主体は一様に分布し、他の主体と均一に結び付いているわけではない。図 1 の模式図に示すように、ノードにはリンク数の差があり、非常に多くのリンクを持つ「ハブ」の存在や、主体どうしが相互に密接に結び付いている「コミュニティ」の存在が知られている^{4),9)}。すなわち、完全に無秩序な構造をしているわけでも、完全に規則的な構造をしているわけでもない。また、主体の数が数万、数十万といった大規模なネッ




図 1 社会的ネットワークの概念図

Fig. 1 Schema of social network.

トワークであることも少なくない。

本稿では、SNS に対して、現実の社会的ネットワークに存在する不均一な構造と大規模性を仮定し、複雑ネットワーク分析の手法を援用することで、ネットワーク構造を分析することから始める。

2.3 複雑ネットワーク分析

ネットワークは、構成要素の関係性によって分析されることが多い。数学的には、構成要素の接続関係によって形成される有向あるいは無向グラフによって解析される。ただし、一般的には、ネットワークの規模が大きくなると、要素間の関係性を個別に説明し、全体像を得ることは難しくなる。

近年、大規模なネットワークの構造やその構造に起因する現象を調べるために、複雑ネットワーク分析が発展し、大規模で複雑な構造のネットワークに対する様々な分析手法が提案されている^{9),16)}。この中で、大規模性を有する複雑ネットワークに対しては、次数分布、平均経路長、クラスタリング係数などの基本統計量⁹⁾と、平均結合相関や中心性などの高次の統計量をネットワークの指標として、構造的な特徴を分析することが多い。

2.4 ネットワークの指標

以下に代表的なネットワーク指標を示す。本稿では、次数分布、平均経路長、クラスタリング係数を基本統計量とする。

次数分布

ノードが持つエッジの数（次数）の分布である。次数 k を持つノードの存在確率分布 $p(k)$ 、もしくはその累積確率である $P(k \leq X)$ が指標となる。現実のネットワークでは $p(k)$ が k の冪乗に比例する冪分布になる例が多く知られており、スケールフリーネットワーク（Scale-free Network）と呼ばれる^{1),9)}。

距離（経路長）・平均経路長

ネットワークの 2 ノード間の距離（経路長）は、そ

☆ <http://mixi.jp/>

☆☆ <http://www.gree.jp/>

☆☆☆ <http://www.orkut.com/>

れらを結ぶ最短経路上に存在するエッジの数（グラフ距離）として定義される．任意の2ノード間の経路長の平均として平均経路長 L は、

$$L = \frac{1}{\frac{1}{2}N(N-1)} \sum_{i \geq j} d_{ij} \quad (1)$$

と定義される．ここで N はネットワークのノード数、 d_{ij} はノード v_i と v_j の間の最短の経路長である．実際のネットワークでは L は N に対して小さいオーダーとなる例が多く報告されており、スモールワールド (Small-world) という性質として知られている^{9),14)}．

クラスタリング係数

クラスタリング係数 C はネットワークの局所的凝集度を示す指標であり、「あるノードの隣接ノード間にエッジが存在する確率」として定義される． k_i をノード v_i の次数、 E_i をノード v_i の隣接ノード間に存在するエッジの数とすると、 C を、

$$C_i = \frac{2E_i}{k_i(k_i - 1)} \quad (2)$$

$$C = \frac{1}{N} \sum_i C_i \quad (3)$$

と定義する¹⁴⁾．実際のネットワークでは、 N が大きい場合でも C の値は比較的大きく、ネットワークの凝集性が保たれることが知られている⁹⁾．

平均結合相関

平均結合相関 $\langle k_{nn} \rangle_k$ は、あるノードの隣接ノードの次数の平均をそのノードの次数 k の関数として表し、式 (4) によって定義される¹²⁾．

$$\langle k_{nn} \rangle_k = \sum_{k'} k' p(k'|k) \quad (4)$$

ここで、 $p(k'|k)$ は、次数 k のノードが次数 k' のノードと接続している確率である．

farness の分布

ネットワークの各ノードの性質を、他のノードへのグラフ距離によって特徴付けることができる．これは、近接中心性 (Closeness centrality) として指標化されている．あるノード v_i の近接中心性 $C_c(v_i)$ は、最短経路長 d_{ij} を用いて式 (5) で定義される²⁾．近接中心性の逆数 C_c^{-1} は他ノードへの平均距離を表すことになり、この値を、本稿ではノードの farness (平均距離) と呼ぶことにする^{*}．




図2 SNS ネットワークの次数分布

Fig. 2 Degree distribution of the SNS network.

$$C_c(v_i) = \frac{N-1}{\sum_{j \neq i} d_{ij}} \quad (5)$$

3. SNS とネットワークモデルとの比較

提供を受けた SNS のデータは以下のとおりである．データからネットワークを形成すると大きな連結成分と小さなものが混在することが分かった．そこで、最大連結成分を取り出し、分析することにした．最大連結成分の規模は、ユーザ数 $N = 360,802$ 、リンク数 (有向) $m = 3,809,228$ である．逆向きのリンクが必ず存在するので、無向グラフと考えた．

はじめに、このデータに対して基本統計量を求める．平均経路長は、 $L = 5.52$ 、クラスタリング係数は、 $C = 0.330$ であった．ノードの総数と比較すると、平均経路長は小さく、クラスタリング係数は高いという傾向が見られる．次数分布は以下のとおりである (図2)．平均次数は $\langle k \rangle = 10.55$ である．冪乗分布的な様子が見られるが、完全に冪乗分布にはなっておらず、低次数の領域と高次数の領域で冪指数が異なっているようである．そこで、区分的に冪指数を求めた．次数の上位 15% である累積確率 $P(k \leq X) < 0.15$ の高次領域 ($k \geq 19$ に相当) では冪指数は 2.64、それより低次の領域では冪指数は 1.08 になる．このように顕著な差が現れ、低次領域では傾きが緩やかになっていることが分かる．

次に、ネットワーク構造モデルとの比較によって、SNS のネットワーク構造について調べる．本稿で用いたネットワーク構造モデルは、

- ランダムグラフ³⁾
- Barabási-Albert (BA) モデル¹⁾
- Klemm-Eguíluz (KE) モデル⁷⁾
- Connecting Nearest Neighbor (CNN)¹¹⁾

の4つである．これらのうち、ランダムグラフ以外の

^{*} farness をすべてのノードについて平均したものが平均経路長 L である．

表 1 SNS とネットワーク構造モデルの基本統計量

Table 1 Basic statistics of SNS and network structure models.

	N	m	L	C
SNS	360,802	3,809,228	5.52	0.330
Random graph	36,000	360,000	4.80	0.0003
BA model	36,000	359,970	4.00	0.002
CNN model	35,085	360,000	6.27	0.402
KE model	36,000	359,970	5.58	0.624

モデルは次数分布が冪乗分布となり、スケールフリーの性質を持つことが知られている。これらのネットワークを数値的に生成し、SNS のネットワーク構造と比較する。なお、ネットワーク生成プログラムの問題で、SNS と比べて、1/10 のノード数での比較となる^{*}。

3.1 基本統計量の比較


それぞれのネットワークの基本統計量：ノード数 N 、エッジ数 m （有向、ただし逆向きが必ず存在するので実質的に無向）、クラスタリング係数 C 、平均経路長 L は、表 1 のとおりである。いずれも平均次数 $\langle k \rangle$ が SNS ネットワークの実データに近く、 $\langle k \rangle = 10$ 付近となるように生成パラメータを設定した。KE モデルを生成するパラメータ μ の値は $\mu = 0.1$ とした。KE モデルでは μ の値によって、平均経路長やクラスタリング係数を制御できることが知られている⁷⁾。いずれのモデルでも、比較的 L が小さい。また、CNN モデルと KE モデルでは C の値が大きく、高い凝集性が再現されている。

3.2 平均結合相関の比較


基本統計量を比較する限りでは、SNS の性質は、CNN モデルと KE モデルに近い。さらに詳しく調べるために、平均結合相関を算出する。図 3 に、SNS およびネットワーク構造モデルの平均結合相関を、 k の関数として示す。社会的ネットワークでは正の相関になる傾向があることが知られているが^{9),11)}、SNS ネットワークも比較的強い正の相関があることが分かる。同様の構造は CNN モデルによるネットワークにも見られる。一方、KE モデルでは負の相関になっている。

3.3 farness (平均距離) の分布


基本統計量、および平均結合相関の結果は、SNS のネットワークは、CNN モデルによって表現できる可能性を示している。しかしながら、farness の分布では、異なる傾向が現れる。SNS ネットワークおよびネット




SNS Network




Random Graph



BA Model



CNN Model



KE Model

図 3 平均結合相関（横軸：次数 k 、縦軸：平均結合相関 k_{nn} ）
Fig. 3 Average nearest neighbor degree as a function of the vertex degree (Degree correlation).




図 4 Farness のヒストグラム

Fig. 4 Histogram of farness of the nodes.

ワークモデルでの farness をヒストグラムによって示す（図 4）。なお、ヒストグラムの区間距離は 0.01 とした。SNS ネットワークでは、ヒストグラムのピーク（ピークとなる farness の値は 5.125、頻度は 2,521）を中心として、平均距離の値が集中する傾向がある。ネットワーク構造モデルに関しては、KE モデルにおいて、ピークを示す平均距離の値が 5.495、その頻度が 434 であり、ネットワークの規模が 1/10 であることを考慮すると、このモデルが SNS をよく表してい

^{*} ネットワーク構造モデルに関しては、1/20 と 1/10 のノード数の結果は同様のものであることを確認しているが、SNS と同スケールでの比較は重要なので、今後の課題の 1 つとしている。

るといえる．一方，ネットワークモデルのうち CNN モデルでは平均距離の頻度分布において，1 つの明確なピークを持つような分布ではなく，広い範囲に分散する傾向がある．

4. ネットワーク上の現象からのモデル推定

前章で述べたように，ネットワークに対する従来の指標と，ネットワーク構造モデルの比較から，SNS のネットワーク構造をある程度は推測することができる．

次数分布に関しては，区分的な冪乗分布となっている．次数によって構造が変化している．基本統計量のネットワーク構造モデルとの比較からは，CNN モデルや KE モデルの性質があることが分かる．平均結合相関からは，CNN モデルとの類似度が高い．一方，平均距離の分布は KE モデルに近く，CNN モデルとは合わない．CNN モデルの結果からは，他のノードから最も近いノードと，他のノードから最も遠いノードが均質に分布している構造が予測されるが，SNS は，そのようなものではなく，farness が平均経路長 L に近いノードが大部分を占めることが分かる．ネットワーク構造モデルに関しては，理論的な分析を含めて多くの知見があるため，そのような知見を利用すれば，SNS のネットワーク構造をより詳細に分析できるものと考えられる．ただし，ネットワーク構造モデルが，SNS のネットワークの構造を，完全に再現しているものはない．したがって，現実の SNS ネットワークの構造には，明らかにされていない要素が存在するものと考えられる．ネットワークの構造分析に対しては，新たな指標が提案され続けているが，多くの議論があることも事実である⁴⁾．

本稿では，視点を変え，ネットワークの機能から構造を調べることを考える．これは，ネットワークの構造と機能が不可分であり，多くの機能（ネットワーク上で起こる現象を含む）が構造に強く依存するという考え方に基づくものである．このことは，現実の SNS ネットワーク上で生起する現象を予測し，制御するという観点からも重要である．すでに述べたように，既存のネットワーク構造モデルは SNS ネットワークの構造を完全に再現するものではない．したがって，SNS ネットワークの構造に起因する相互作用によって生じる現象は，すでに提案されているネットワークモデルを用いて構造を与えた場合とは異なる点があることが予想される．そこで，そのような現象の特徴を用いて，SNS の構造モデルの推定を行う．

4.1 伝播ダイナミクスを利用したモデルの推定

ネットワーク構造に起因する現象を表すモデルには，

伝染病や情報の伝播，相互作用のダイナミクスなどをモデル化したものがある^{10),15)}．これらのモデルをネットワーク構造の分析に利用する際に留意すべきことは，モデルの複雑性がネットワークの性質を隠蔽する場合が多いということである．本稿では，現象そのものを分析の対象にするのではないため，ネットワーク上の現象や事象を表現するできるだけ単純なモデルを導入する．そのモデルを，SNS のネットワークと，ネットワーク構造モデルによって生成されるネットワークに適用した数値実験の結果から，それぞれの構造を分析し，SNS のネットワークのモデル推定を行う．

4.1.1 伝播モデル

本稿では，ネットワーク上で生起する現象のモデルとして，ネットワークのノードを伝わる伝播ダイナミクスの単純なモデルを考える．これは，ある種の意見や情報が，ネットワークを通じた周囲との接触を通じて伝播，流通する様子の素過程としてのモデル化を意図したものである．

ある時刻 t においてネットワークのノード v は $+1$ ，あるいは -1 の状態をとる．次ステップの状態は，周囲の状況によって決まるものとする．この決め方に対して，本稿では以下のルールを採用する． $\sigma_i(t)$ をノード v_i の時刻 t での状態を示すものとする，このモデルは次式で示される．

$$\sigma_i(t+1) = \text{sgn} \left\{ \sum_{j=1}^N c_{ij} \sigma_j(t) \right\} \quad (6)$$

ただし， c_{ij} はノード v_i と v_j の接続を表し， v_i と v_j の間にエッジが存在するときに $c_{ij} = c_{ji} = 1$ ，存在しないときに $c_{ij} = c_{ji} = 0$ となる．また， $\sum_{j=1}^N c_{ij} \sigma_j(t) = 0$ のときは， $\sigma_i(t+1) = \sigma_i(t)$ とする．すなわち，隣接ノードの状態のうち，多い方の状態に遷移し，同数の場合は状態を維持するモデルである．このモデルを用いて，初期条件として $t=0$ での状態を制御し，その後の 2 状態の比率の変化を伝播ダイナミクスの特性として分析する．

4.1.2 初期条件

初期条件は以下のとおりである．

はじめに， $t=0$ に状態 $+1$ を与えるノードの割合 r を決定する．次に，状態 $+1$ を与えるノードのネットワーク上での空間的な分布を制御する．初期状態を与える空間的な分布としては，ランダムな分布，およびノードの中心性指標に従ったものの 2 通りを考える．これは，伝播の起点を制御していることに相当する．

ノードの総数を N としたとき，ランダムな分布では rN 個のノードにランダムに状態 $+1$ を，残りの

ノードに状態 -1 を与える. この場合は, rN を固定し, 複数回の数値実験を試みることになる.

中心性に従った分布では, それぞれの中心性指標が高いものから順に rN 個のノードに状態 $+1$ を与える. 中心性指標とは, ネットワークの構造によって, それぞれのノードの中心概念の尺度を数値化した指標ものである¹³⁾. 本稿では, 中心性指標として次数中心性, および媒介中心性の 2 種類の異なる指標を用いる. 次数中心性 C_D は, ノードの次数を正規化したものであり, ノードの総数を N とすると次式で定義される²⁾.

$$C_D(v_i) = \frac{k_i}{N-1} \quad (7)$$

媒介中心性 C_B は他ノードの最短経路を媒介している割合であり, $\sigma_{v_j v_k}$ をノード v_j とノード v_k の最短経路の数, $\sigma_{v_j v_k}(v_i)$ を v_j と v_k の最短経路のうちノード v_i を通る経路の数とすると, 次式で定義される²⁾.

$$C_B(v_i) = \sum_{v_j \neq v_i \neq v_k} \frac{\sigma_{v_j v_k}(v_i)}{\sigma_{v_j v_k}} \quad (8)$$

4.2 数値実験結果：SNS ネットワーク

SNS ネットワークをネットワーク構造として用いた実験結果の代表的なものを, 図 5, 図 6, 図 7 に示す. 左図の横軸はステップ数, 縦軸は $+1$ の状態を持つノードの割合である. $r = 0.1$ から $r = 0.9$ までの




図 5 SNS ネットワークでの数値実験結果 (ランダムな分布)
Fig. 5 Numerical result on the SNS network (Random).




図 6 SNS ネットワークでの数値実験結果 (次数順)
Fig. 6 Numerical result on the SNS network (Degree).




図 7 SNS ネットワークでの数値実験結果 (媒介中心性順)
Fig. 7 Numerical result on the SNS network (Betweenness centrality).




図9 ネットワークモデルでの数値実験結果(状態 +1 の割合の推移, ランダムな初期状態分布を与えたもの)
Fig.9 Simulation result on network models (Random: Transition ratio of +1 state).

9種類の試行に対して, +1 の状態の割合の推移を示している. 右図の横軸は r , 縦軸は 20 ステップ経過時の状態 +1 の割合である. 本稿では, 20 ステップ経過時を終状態としている. 図5はランダムな分布とした場合の結果である. 複数回の試行で同様の結果を得ているが, $r = 0.5$ の場合は, 結果に大きなばらつきが見られた. また, 図6は次数順の場合, 図7は媒介中心性順の場合の結果である.

ランダムな分布とした場合, 初期に多い方の状態が大勢を占める状態に収束する. したがって, 初期状態と終状態の状態 +1 の割合の関係は階段関数的な形になる. ただし, $r = 0.5$ 近傍では初期の分布のわずかな違いによってその後の挙動が大きく異なる.

次数順や媒介中心性順の場合, 初期状態と終状態での状態 +1 の割合の関係は上に凸であり, 初期の割合 r よりも大きい値に収束する傾向がある. したがって, これらの性質を持つノードを起点とした場合, より広い範囲に伝播が生じ, これらのノードが伝播に関して強い影響力を持っていることが分かる. なお, 媒介中心性順の場合, $r = 0.1$ と $r = 0.2$ の間に閾値があることが分かる(図7右).

さらに, 多くの初期条件で, すべてのノードの状態が +1, あるいは -1 のいずれか一方の状態にはならないことが分かった. これは, 局所的に平衡状態となる構造があることを示唆している. たとえば, 本稿で用いた伝播モデルでは, 図8の点線枠で示した部分で局所的に安定な状態となり, いずれか一方の状態が




図8 状態が局所的に安定する構造
Fig.8 Schema of local stable structure.

残ることになる.

4.3 ネットワーク構造モデルとの比較

ネットワーク構造モデルによって作られたネットワーク上で, SNS の場合と同じ数値実験を行った. それらの結果を図9から図14に示す. 図9はランダムな分布, 図10は次数順, 図11は媒介中心性順の結果である. 図12, 図13, 図14は, それぞれの初期条件での各構造モデルごとの r (横軸) と 20 ステップ経過時の状態 +1 の割合(縦軸)の対応関係を表す.

ランダムグラフや BA モデルでは, $r = 0.5$ 近傍を除くと, 速やかに片方の状態が消滅する. また, KE モデルでは, 大きな振動の後に収束する様子が現れている. このように, 本稿で用いた伝播モデルによるネットワーク上での伝播ダイナミクスは, ネットワークの空間構造によって大きく影響を受けることが分かる. その中で, CNN モデルでの伝播の挙動は, 実験を行っ




図 10 ネットワークモデルでの数値実験結果 (状態 +1 の割合の遷移, 次数順の初期状態分布を与えたもの)
Fig. 10 Simulation on network models (Degree: Transition ratio of +1 state).




図 11 ネットワークモデルでの数値実験結果 (状態 +1 の割合の遷移, 媒介中心性順の初期状態分布を与えたもの)
Fig. 11 Simulation on network models (Betweenness centrality: Transition ratio of +1 state).

たすべての初期条件で SNS ネットワークでの挙動に類似している。この結果は, CNN モデルが, 従来の指標による構造分析で表しえない SNS ネットワークに特有な構造を再現しているものと考えられる。

5. SNS の構造・成長モデル

これまで示したように, SNS ネットワークの構造

は CNN モデルによるネットワークの構造に類似している点が多い。しかしながら, 表 1 や図 4 に示すように, 平均経路長や, farness の分布が異なる。

この理由を, ネットワークが形成される過程から考察する。CNN モデルは,

- a) 新たなノードを生成し, ランダムに選んだ既存のノード 1 つとの間にエッジを生成する,




図 12 ネットワークモデルでの数値実験結果（収束時の状態 +1 の割合，ランダムな初期状態分布を与えたもの）

Fig. 12 Simulation on network models (Random: Convergence ratio).




図 13 ネットワークモデルでの数値実験結果（収束時の状態 +1 の割合，次数順の初期状態分布を与えたもの）

Fig. 13 Simulation on network models (Degree: Convergence ratio).




図 14 ネットワークモデルでの数値実験結果（収束時の状態 +1 の割合，媒介中心性順の初期状態分布を与えたもの）

Fig. 14 Simulation on network models (Betweenness: Convergence ratio).

b) 「隣の隣」どうしを 1 組ランダムに選択し結合する，

の 2 つの操作を確率的に選択して繰り返すことで，局所的な作用によってネットワークを成長させるモデルである¹¹⁾。

ところが，現実の人的なネットワークの形成過程を考えたとき，人間関係は「友人の友人」だけから形成されるわけではなく，それまでいっさい関係のなかった

人間と新たに関係が築かれることもある。いい換えれば，局所的ではない作用が内在し，その作用の結果が構造の違いとして現れているものと推察できる。SNS では，プロフィールに基づいて他のユーザを検索する機能や，共通の興味や関心を持つユーザが集まる SIG (Special Interest Group) と呼ばれるグループを作る機能が提供されている。それらの機能が，局所的ではない作用をもたらしている可能性がある。そして，SNS における人的ネットワークの成長には，それらに起因するものがあると考えられる。

本稿で示した知見からは，CNN モデルの成長モデルに基づき，局所的でない作用を加え，平均経路長や farness の分布を比べ，同様の伝播ダイナミクスが生じることを確かめることで，SNS ネットワークの構造や成長過程のモデルを構築できるものと考えられる。

6. おわりに

本稿では，実際に運用されている SNS 上の人的ネットワークに対してネットワークの静的な構造の分析とモデル推定を，ネットワーク構造モデルから形成されるネットワークとの比較と，ネットワーク構造上の伝播ダイナミクスの分析によって行った。

はじめに，SNS ネットワークには冪乗分布的な次数分布や高いクラスタリング係数に見られる凝集性など，空間的に均一ではない性質が存在することを確認した。また，ネットワーク構造モデルとの比較分析を行い，既存のモデルは SNS ネットワークの構造の特徴を完全に再現しているわけではないことを示した。

次に，相互作用の単純な伝播モデルを用いて，ネットワーク上の伝播ダイナミクスを分析した。その結果，SNS ネットワークにおいては，伝播の起点となるノードの中心性の差によって，伝播挙動に差異が生じることが分かった。また，ネットワークモデルとの比較により，伝播モデルによるダイナミクスはネットワークの構造に大きく依存していることを示した。これらの結果は，スモールワールド性やスケールフリー性などの基本的な統計的性質の再現に注力したモデル化では，現実の SNS のネットワーク構造に起因して生じる現象を分析し，予測するためには不十分であることを示すものである。

一方，静的な構造分析，およびネットワーク構造における伝播ダイナミクスの結果の多くは，SNS ネットワークの構造が CNN モデルによって形成されるネットワークと類似していることを示唆している。今後は，CNN モデルに基づいて，SNS ネットワークの構造・成長のモデル化を行い，ネットワーク構造に起因して

生じる現象と構造との関連性について詳細な分析を試みる予定である。

参考文献

- 1) Barabási, A.-L. and Albert, R.: Emergence of scaling in random networks, *Science*, Vol.286, pp.509–512 (1999).
- 2) Brandes, U.: A faster algorithm for betweenness centrality, *Journal of Mathematical Sociology*, Vol.25, No.2, pp.163–177 (2001).
- 3) Erdős, P. and Rényi, A.: On random graphs, *Publicationes Mathematicae*, Vol.6, pp.290–297 (1959).
- 4) Girvan, M. and Newman, M.E.J.: Community structure in social and biological networks, *Proc. National Academy of Sciences of the United States of America (PNAS)*, Vol.99, No.12, pp.7821–7826 (2002).
- 5) Gruhl, D., Liben-Nowell, D., Guha, R. and Tomkins, A.: Information diffusion through blogspace, *SIGKDD Explor. Newsl.*, Vol.6, No.2, pp.43–52 (2004).
- 6) Holme, P., Edling, C.R. and Liljeros, F.: Structure and Time-Evolution of an Internet Dating Community, *Social Networks*, Vol.26, pp.155–175 (2004).
- 7) Klemm, K. and Eguíluz, V.M.: Growing scale-free networks with small-world behavior, *Physical Review E*, Vol.65, No.057102 (2002).
- 8) Kumar, R., Novak, J., Raghavan, P. and Tomkins, A.: On the bursty evolution of blogspace, *WWW '03: Proc. 12th international conference on World Wide Web*, New York, NY, USA, ACM Press, pp.568–576 (2003).
- 9) Newman, M.E.J.: The Structure and function of complex networks, *SIAM Review*, Vol.45, pp.167–256 (2003).
- 10) Pastor-Satorras, R. and Vespignani, A.: Epidemic Spreading in Scale-Free Networks, *Physical Review Letters*, Vol.86, No.14, pp.3200–3203 (2001).
- 11) Vázquez, A.: Growing network with local rules: Preferential attachment, clustering hierarchy, and degree correlations, *Physical Review E*, Vol.67, No.056104 (2003).
- 12) Vázquez, A., Pastor-Satorras, R. and Vespignani, A.: Large-scale topological and dynamical properties of the Internet, *Physical Review E*, Vol.65, No.066130 (2002).
- 13) Wasserman, S. and Faust, K.: *Social Network Analysis: Methods and Applications*, Cambridge University Press (1994).
- 14) Watts, D.J. and Strogatz, S.H.: Collective dynamics of ‘small-world’ networks, *Nature*, Vol.393, pp.440–442 (1998).
- 15) 林 幸雄：流行ダイナミクスの Scale-free ネットワークモデル, *JSMB Newsletter*, No.44, p.102 (2004).
- 16) 増田直紀, 今野紀雄：複雑ネットワークの科学, 産業図書 (2005).
- 17) 湯田聡夫, 小野直亮, 藤原義久：ソーシャル・ネットワーク・ワーキング・サービスにおける人的ネットワークの構造, 情報処理学会論文誌, Vol.47, No.3, pp.865–874 (2006).
- 18) 藤巻潤一：ネットコミュニティビジネスの動向～急増する「クチコミサイト」「ブログ」「ソーシャルネットワークワーキングサービス」～, 経営情報サーチ 2005/冬, 大和総研, pp.29–43 (2004).

(平成 17 年 10 月 28 日受付)

(平成 18 年 6 月 1 日採録)



内田 誠 (正会員)

昭和 56 年生。平成 16 年東京大学工学部システム創成学科卒業。平成 18 年東京大学大学院工学系研究科環境海洋工学専攻修士課程修了。現在、東京大学人工物工学研究センター学術研究支援員。複雑ネットワークの構造分析やその可視化に関する研究に従事。平成 17 年度日本機械学会計算力学部門ビジュアライゼーション優秀表彰。日本機械学会会員。



白山 晋 (正会員)

昭和 34 年生。昭和 57 年京都大学工学部航空工学科卒業。昭和 62 年東京大学大学院工学系航空工学専攻博士課程修了。(株) 計算流体力学研究所、(株) ソフテックにおいて、流体解析手法、流体解析システム、可視化手法、および可視化システムの研究に従事。平成 11 年より東京大学大学院工学系研究科助教授。現在、東京大学人工物工学研究センター助教授。大規模データマネジメント、可視化情報からの知識抽出、複雑ネットワーク分析に関する研究に従事。工学博士。平成 14 年可視化情報学会論文賞受賞、平成 17 年同学会技術賞受賞、平成 14 年度、同 17 年度日本機械学会計算力学部門ビジュアライゼーション優秀表彰。可視化情報学会、日本計算工学会、日本機械学会、日本流体力学会各会員。