

銀行間取引ネットワークモデルを考慮した銀行破綻連鎖の分析

橋本 守人^{a)} 倉橋 節也^{b)}

概要：金融機関における連鎖破綻リスクを回避するため、システミックリスクに関する資金取引ネットワークの研究が、欧州を中心にグローバルで活発に行われてきている。本研究では、Erdos-Renyi ネットワークで構成した銀行間資金取引ネットワークモデルを構築し、ネットワーク特性を考慮することで、最小限のコストで破綻の連鎖を低減するための方策を検証する。エージェントベースモデリングを用いて検証を行った結果、破綻の連鎖を止める目的で実施する資金援助が、結果的に連鎖を増加させてしまう場合があること、また資金援助を実施する金融機関の選定には、ネットワーク特性を考慮した機械学習 (Random Forest 法や深層学習) が効果的であることが示された。

The analysis of bankruptcies' succession using Inter-bank transactional network model.

HASHIMOTO MORITO^{a)} KURAHASHI SETSUYA^{b)}

1. Introduction

金融機関の間で行われる各種証券を媒体とした資金取引が、金融機関の破綻の連鎖のリスク (システミックリスク) を引き起こし、金融市場の安定化を損なう可能性がある。金融機関は、バーゼル 3 (バーゼル銀行監督委員会が公表している国際的に活動する銀行の国際統一基準) による自己資本比率に対する規制等を受けており、金融市場安定化の対策が行われている。一方で、各金融機関は金融自由化による金利や各種手数料等の激しい競争を行っており、経営基盤が全く問題ない状況とは言い難い。このような中、金融機関の破綻は突発的に起こりうるものとして、対策を行う必要がある。金融機関における資金取引の仕組みは複数の金融機関の間のネットワークで実現されている。資金取引ネットワークは、個々の銀行間取引から成り立っているが、銀行間取引は、参加者が銀行を中心とした金融機関に限定された市場である。その市場の一つには、短期資金

の貸借を行う金融市場として、日本にはコール市場があり、日々の資金過不足の調整の場となっている。もう一つの市場は、直物為替や先物為替などの取引を行う外国為替市場であるが、こちらは世界各地に存在する。銀行間取引市場は、金融機関、短資会社、金融当局などから構成されており、主に直接取引や短資会社を通じて取引が行われている。システミックリスク全体を俯瞰すると、S&L 危機、リーマンショック等の発生に対して、資金取引ネットワークにおける破綻連鎖のリスクは未解明の点がある。ひとつの金融機関の業務停止は連鎖的に資金取引が停止するリスクがあり、預金者にとって銀行の資金取引停止は生活基盤の崩壊に直結する。政府は公的資金の注入、預金保険制度の策定や中央銀行貸出等のセーフティネットを設定しているが、金融危機が発生し、金融機関に対して公的資金を注入した場合、国民負担が発生する可能性があるため、国民の関心が高い。金融機関の救済は、金融危機対応会議の議を経て内閣総理大臣が、必要性を認定することにより実施するが、救済する金融機関、注入する資金額は慎重な審議が必要になる。そのためには、銀行間ネットワークの連鎖の仕組みを解明し、どの金融機関に注入するか、どうすれば最小の

ⁱ¹ 現在、筑波大学
Presently with University of Tsukuba

^{a)} hasimoto@gssm.otsuka.tsukuba.ac.jp

^{b)} kurahashi.setsuya.gf@u.tsukuba.ac.jp

コストで破綻の伝播を食い止められるのか等を検証する必要がある。本研究では、資金取引ネットワークの構造から、最もシステミックリスクを低減させる金融機関の救済施策を提案する。資金取引ネットワークにおける破綻の連鎖をネットワーク理論におけるカスケード故障と考えれば、媒介中心性によるノード削除で破綻の連鎖の低減が期待できるが、本研究の検証では破綻の連鎖の予測精度が低いことがわかった。そこで、その精度を向上させる手法を、機械学習によるランダムフォレストと深層学習 (Deep Learning) によって向上させた。以下、2章において関連するシステミックリスクモデル研究を概観した後、3章で提案モデルについて、4章で破綻の連鎖とノード特性の影響、5章で破綻の連鎖のネットワーク指標、6章でネットワーク指標の分析、7章で機械学習によるリンク削除後のネットワーク指標の評価、8章で考察、9章で結論と今後の展開を述べる。

2. ネットワーク理論によるシステミックリスクの研究

ここでは、ネットワーク理論を用いたシステミックリスク研究の概観と、本研究に関連する研究について述べる。

2.1 関連研究

システミックリスクに関する資金取引ネットワークの研究が、欧州を中心に、グローバルで盛んに行われている [1][2][3][4][5] が、国内では資金取引ネットワークのモデリングに関する先行研究として、[7] がある。その中で分析に使用したデータは日銀当座預金のコール取引であり、1997年12月中と2005年12月中の資金取引データを比較している。ネットワークの概観は、1997年は短資会社をハブとしたネットワークで、スター型 (中央集中型) ネットワークといえるが、2005年はリンクが分散化したネットワークとなっていて、完全ネットワークに近いが、degree が概ねべき乗分布に従っている傾向があるため、スケールフリー性がみとめられた。ここで、degree は次数を意味しており、あるノードが他のノードに接続している数を指す。多くの金融機関と取引しており (degree が高い)、取引金額や回数が多い (strength が大きい) 金融機関が、市場参加者のなかで、重要な役割を担っていた。ネットワークの構造としては、コア内部で決済不履行 (default) の連鎖が生じてしまうと平均距離の短さから即時にネットワーク全体に拡大してしまうリスクがある。コアの構成員に流動性を集中的に供給すると効率的かつ効果的と述べている。

2.2 システミックリスクの基本モデル

銀行間取引ネットワークを (図. 1) のように表すが、この中のノードは金融機関、リンクは銀行間の貸借を指し、有向である。このネットワークで、ある金融機関が破綻した場合、貸出しているリンクの接続先金融機関すべてが損

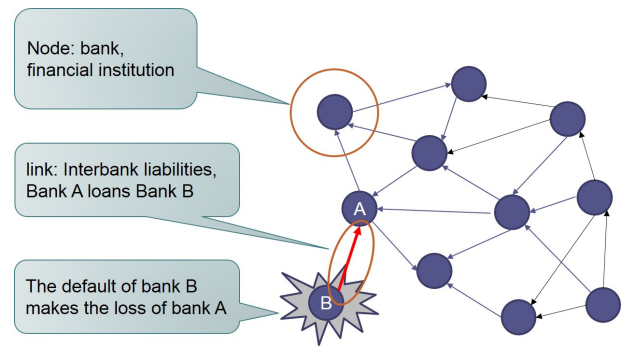


図 1 Modeling of interbank network.

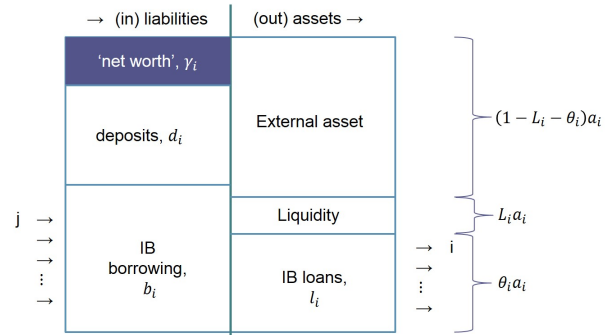


図 2 Balance sheet of bank i using May Model.

失を被るが、リンクの矢印が向いている金融機関、(図. 1) であれば、金融機関 A が損失を被ることになる。

2.3 May モデルの検証

本研究では、金融機関の破綻の伝播のモデルとして May 他 [5] のモデル (以下、May モデル) を採用した。May モデルでは、バランスシート (図. 2) を用いてモデリングしており、以下のような項目を使用する。

- f : 銀行破綻によって対外資産が毀損する割合
- θ : 資産に対する銀行間融資の割合
- $S(I)$: フェーズ 1 ショック
- γ : 自己資本比率

May モデルでは、金融機関の破綻の伝播をフェーズ毎にフェーズ 1、フェーズ 2、フェーズ 3 と定義している。まず、フェーズ 1 ショックは (1) 式のように定義する。

$$S(I) = f(1 - \theta) \quad (1)$$

1 式で、フェーズ 1 ショックを表したとき、(2) 式の条件で伝播したフェーズ 1 ショックが自己資本を上回り、金融機関は破綻する。

$$S(I) > \gamma \quad (2)$$

次に、フェーズ 2 ショックの伝播では、フェーズ 1 の個別銀行による債務不履行が、債務者銀行のフェーズ 2 ショックを発生させる。(3) 式のように、フェーズ 2 ショックは、債務者銀行数が多いほど、緩和される。ここで、下付き文字の「MIN」は小さい方の値を採用することを表す。

z : 銀行間融資の数 (銀行間ネットワークの平均次数)

$$S(II) = \frac{[\theta, s(I) - \gamma]_{MIN}}{z} \quad (3)$$

また、フェーズ3のショックも、フェーズ2ショックと同様の考え方で、入れ子にすることで(4)式のように定義できる。

$$S(III) = \frac{\{\theta, \frac{[\theta, f(1-\theta) - \gamma]_{MIN}}{z} - \gamma\}_{MIN}}{z} \quad (4)$$

ここで、(N : 金融機関数) が z^2 より十分大きいとき、ショックはネットワーク上に十分伝播する。

3. エージェントベースモデリングへの展開

システミックリスクをエージェントベースモデリング(以下、ABM)に適用するメリットには、まず検証の効率性があげられる。ミクロ的な個々の金融機関の貸借関係等の自律的な相互作用は解明されているが、マクロ的な資金取引ネットワークへの創発的なシステミックリスクの影響が未解決なため、ABMによる検証が効率的である。また、銀行間取引の実データは中央銀行でしか扱えないため、実証研究が事実上不可能であることから、ABMなどの演繹モデルの構築が必要である。演繹モデルを採用することで、個々の金融機関の貸借関係等の挙動が解明され、金融機関数等の外観的な関連データを用いることで十分な検証を行うことが可能になる。

エージェントベースモデリングのアプローチは、以下のようなステップを踏んだ。

(A) May モデルをベースに ABM の検証環境を作成

(B) May モデルの平均場近似結果を ABM の検証結果と比較し、モデルの妥当性を検証

(C) その ABM の環境で、本研究の目的とするシステミックリスクを低減するネットワーク特性を検証

3.1 エージェントベースモデリング環境構築

モデル化は、(図. 3) のように行った。まず、①フェーズ1破綻が発生し、②のように伝播して、銀行間融資を行っている金融機関がフェーズ2ショックを受ける。③でショックを受けた金融機関が net worth (自己資本) で吸収できるか判別し、吸収できなければ金融機関破綻の連鎖が発生する。④で、②同様銀行間融資を行っている金融機関がフェーズ3ショックを受け、⑤で net worth で吸収できるか判別するが、そのショックは(図. 3)のように複数回受ける可能性がある。

3.2 May モデルの検証結果との比較

次に、構築した ABM の環境に May 他を検証と同様に、以下のパラメータを設定し、検証を実施した。May 他もまた、NYYA[6] のシミュレーション結果をもとに比較している。




図 3 Agent Based Modeling of May Model.

表 1 Simulation results of ABM using May Model (N=25).

count links	mean path length	phase III number of defaults	phase II number of defaults
121.6	2.138	18.796	3.408

- ネットワーク: Erdos-Renyi ネットワーク
- 自己資本比率 (フェーズが進むと自己資本が減少) : $\gamma=0.8$ (フェーズ1), 0.042 (フェーズ2), 0.016 (フェーズ3)
- 銀行破綻によって対外資産が毀損する割合: $f=1$
- 資産に対する銀行間融資の比率: $\theta=0.20$
- ある銀行 A が別の銀行 B に融資する確率: $p=0.2$

ここで、May 他を検証では、銀行間融資の数 (z) に平均場近似で設定した値 (4.8) を採用したが、本研究では実際のノードの内向きリンク数を使用した。当然ながら、同一のネットワークで同じパラメータを投入した検証は、常に同じ結果になる。ノード数 (N=25) でノード1からノード25まで、個々のノード毎に破綻させたときに発生した平均破綻銀行数はフェーズ3で18.796、フェーズ2で3.408であった(表. 1)。これは、May モデルの値とほぼ一致し、妥当なモデリングができていると判断した。ここで、(表. 1) の列は以下の通りである。

- count links : ネットワークの総リンク数
- mean path length : ネットワークの平均距離
- phase II/III mean defaults : フェーズ2もしくはフェーズ3ショックで破綻する金融機関数の平均値

4. 破綻の連鎖とノード特性の影響

本章では、本研究の主要な項目である破綻の連鎖とノード特性の影響について述べる。本論文でのノード特性とは、資金取引ネットワークにおけるノード毎の指標を整理したものである。

4.1 資金取引ネットワークと資金援助

資金取引ネットワークの検証を実施するために、May モデルと同様に Erdos-Renyi ネットワークを作成し、そのパラメータとして、ノード数は500、connection probability は0.02を採用した。その根拠は、本研究の対象は国内金融

機関ネットワークであり、日本の金融機関数（銀行、信金、信組）は 544 であるため、ノード数を 500 とし、また、[7] で、銀行間の資金取引ネットワークの 2005 年の上位 200 社の平均距離は 3 ステップ以内との計測結果から、connection probability を変化させ、平均距離 3 ステップに近い値を測定したところ、0.02 の値に近いことが分かったためである。これらのパラメータを整理すると以下のようになる。また、 γ, f, θ, p の値は先行研究同様、すべての銀行で同じとし、ネットワーク特性による変化を評価できるようにする。

- 自己資本比率（フェーズが進むと自己資本が減少）：
 $\gamma=0.8$ (フェーズ 1), 0.042 (フェーズ 2), 0.016 (フェーズ 3)
- 資産の毀損比率: $f=1$
- 資産に対する銀行間融資の比率: $\theta=0.20$
- ある銀行 A が別の銀行 B に対して融資を行っている割合: $p=0.02$
- 総銀行数: $N=500$

ここで、 z （銀行間融資の数）は、実際のネットワーク上での次数を採用するが、 N が各々の z^2 よりも十分大きいことが予想されるため、ネットワーク上をショックが十分伝播する。

4.2 検証モデル

本研究では、ひとつの金融機関の経営状況が悪化したケースを想定し、その金融機関を資金援助によって救済し存続させた場合と、その金融機関を破綻させ銀行間の資金取引ネットワークから退場させた場合で、他の金融機関の破綻の連鎖がどのような影響を受けるかを検証した。一般的には、金融機関を救済することが、預金者の決済手段が確保され、金融システムの安定が保たれるため望ましいと思われるが、逆に、金融機関側にはモラルハザードの問題があり、最終的には救済してもらえないという考え方から、金融機関の経営努力の欠如を招き、その金融機関が破綻した場合には破綻前の資本注入、流動性供給等に加え、預金者保護のために公的資金の注入を行うことが想定され、公的資金の注入量が増大するリスクがある。また、ネットワーク理論におけるカスケード故障の考え方では、ノードを削除する、つまり金融機関を破綻させ、資金取引ネットワークから退場させるほうが破綻の連鎖を抑えられる場合があることを示唆している。そこで、本研究ではノードの削除と、破綻の連鎖の関連性について検証するために資金取引ネットワークモデルを構築した。具体的には、Erdos-Renyi ネットワーク上で、ノード i の破綻を想定し、そのノード i のリンクを全て削除し、別のノード j の破綻におけるネットワーク全体の破綻連鎖の数 (A) を、ノード i のリンクを削除しない場合のもの (B) と比較し、その差異を計測した。(図. 4) ノード i のリンクを削除したときは、当該金融機関を救済せず、破綻処理を選択したことを示唆しており、その場合は




図 4 Agent Based Modeling of Systemic risks.




図 5 Schematic flow diagram of dropping node validation.

公的資金の適用により、銀行間貸借が維持され、ノード i からの破綻の連鎖は発生しないが、ノード j の破綻については、既にノード i に対して公的資金を使っており、十分な資金を確保できずに破綻の連鎖が発生するモデルとした。また、ノード i のリンクを削除しないときは、資本増強を行うことで、銀行間貸借関係が維持され、当該金融機関を救済したことになる。ノード j および、ノード i についてそれぞれ 500 パターン計測したため、合計 250000 回の検証を測定した。その検証結果の散布図 (図. 5) は以下の通りである。なお、(図. 5) は縦軸にノードのリンクを削除する前と削除しないときの平均破綻連鎖数の差異、横軸はノード番号を表し、各点はリンクを削除したノード毎の平均値を表している。

検証の結果、(図. 5) の散布図より、ノードのリンクを削除することによって、破綻の連鎖が減少することがあることがわかった。これは、破綻の連鎖を防ぐ目的で行う資金援助が、逆に連鎖を増長してしまうことを示唆しており、資金援助を行う金融機関の選定は慎重に行う必要があることがわかった。

5. 破綻の連鎖のネットワーク指標

本章では、破綻の連鎖に関連するネットワーク指標について分析する。破綻の連鎖とカスケード故障の関連について検証するためには、媒介中心性を考慮する必要がある。媒介中心性については、[7] が言及しており、銀行 $A \cdot B$ の degree が同一であっても、 A 銀行の媒介中心性が高いならば、 A 行はネットワーク上の重要な経路上に位置していることになり、流動性ショックの伝播に巻き込まれやすい、




図 6 Conceptual scheme of node betweenness centrality.

もしくは自行が未払いを起こしたとき B 行以上にネットワーク上に大きな波及をもたらしやすいと考えられるとしている。媒介中心性とは、多くのノード間の橋渡しをしているノードは重要であるという考え方に基づいた中心性である。任意のノードペア間の最短パスのうち、媒介しているパスの割合によりノードをランキングするものである。また、[8] は、媒介中心性によるカスケード故障についての防衛策を言及しており、その中では、媒介中心性が小さい点を除去すると、最終状態において故障する頂点数が減るとしている。これは、頂点は流れの通り道であると同時に、自分を端点とする流れの出発点であるためとの考え方による。また、自分から出発する流れの量は頂点によらず同じであるため、媒介中心性の小さい点は、流れを通すことにあまり寄与せず、かつ、自分から出発する流れを一定量だけ発生するので、除去してしまうほうが良いとしている。一方、媒介中心性の大きい点を除去してしまうと、この点を通っていた流れがほかの経路を迂回することになり、連鎖に影響を与えているのではないかと想定されるが、[8] は、媒介中心性の大きい点を除去した場合は影響が少ないとしている。これを資金取引ネットワークに当てはめると、(図. 6) のように、媒介中心性が小さいノードを除去した場合、当該ノードを起点とする流れが除去され、ネットワークとしての破綻の連鎖リスクが下がる。媒介中心性の大きいノードを除去した場合は、本検証ではネットワークの流れが妨げられ、近隣のノードの流れが増えて破綻の連鎖数が増加したと思われるが、(図. 7) の濃淡図のように、媒介中心性が小さいノードと比較して、破綻の連鎖リスクを説明できていない。破綻の連鎖が大きくなる金融機関に公的資金を注入することは避ける必要があるため、この点が媒介中心性の指標としての欠点である。(図. 6) において、最小の媒介中心性のノードから出る破線は除去される流れを差し、最大の媒介中心性のノード近傍の太い実線は増加する流れを指す。また、(図. 7) は、縦軸にノードのリンクを削除する前と削除しないときの平均破綻連鎖数の差異、横軸に媒介中心性を表す。

(図. 7) のように、媒介中心性だけで破綻の連鎖を予測




図 7 Contrasting scatter diagram of Number of defaults and betweenness centrality.




図 8 The validation of explanatory variables effects using Random Forest.

することには限界があり、特に媒介中心性の大きい領域では拡散し、媒介中心性が小さい領域から右斜め上方に扇型の形状になっている。破綻連鎖数の差異と媒介中心性の相関係数は、10 個のネットワークでの検証の平均で、0.292 であった。

6. ネットワーク指標の分析

本章では、破綻の連鎖を予測するためのネットワーク指標について分析する。破綻の連鎖を予測するためには、媒介中心性だけでは十分説明できないことがわかったため、それ以外の指標で、説明できる指標がないかを Random Forest 法で検証した。測定した指標は媒介中心性 (BC)、近接中心性 (closeness)、次数中心性 (degreeness)、固有ベクトル中心性 (evcentness)、グラフ中心性 (graphcent)、入次数 (in.degree)、外向きの次数 (out.degree)、ページランク (PR) の 8 種類 ((図. 8) の横軸の並びも同様) であるが、10 個のネットワークで同じ検証を実行し、ほぼ同等の傾向を示した。なお、測定した指標は 7 章の「機械学習によるリンク削除後のネットワーク指標の評価」でも変数重要度が高かった指標を選定している。測定した 10 パターンの Random Forest 法による変数重要度の平均値のグラフを (図. 8)、そのうちのひとつのネットワークの説明変数の部分従属プロットを (図. 9) に示す。

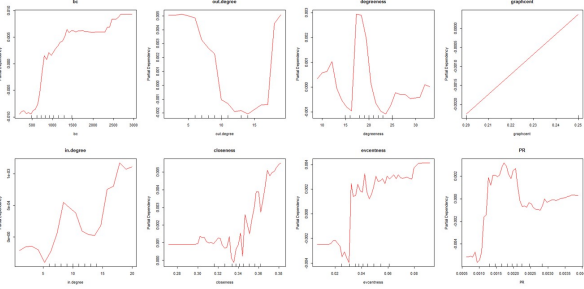


図9 Partial dependency plots of explanatory variables.

表2 Top3 parameters of Classification and Regression trees.

NO.	1	2	3
1	BC	out.degree	evcent
		out.degree	evcent
2	pagerank	evcent	pagerank
3	BC	closeness	clossness
		BC	
4	in.degree	BC	in.degree
			out.degree
5	in.degree	out.degree	clossness
		pagerank	pagerank
6	in.degree	closeness	degreeness
7	in.degree	closeness	evcent
		in.degree	clossness
8	in.degree	evcent	evcent
		pagerank	clossness
9	in.degree	out.degree	degreeness
		closeness	BC
10	in.degree	evcent	clossness
			evcent

(図. 8) の変数重要度では, 想定通り媒介中心性 (BC) がもっとも良い値になり, 続いて固有ベクトル中心性 (evcentness) とページランク (PR) の重要度が高かった. (図. 9) の部分従属プロットでは, 媒介中心性 (BC), 入次数 (in.degree) が線形に近くなっているが, 変数重要度で媒介中心性の次に良い値になっていた固有ベクトル中心性 (evcentness) とページランク (PR) は, 線形に近いとはいえず, 差異が見られた. なお, グラフ中心性 (graphcent) は完全に線形になっているが, 変数重要度が最も低く, 部分従属のカバレッジも少ない. このように, 媒介中心性以外の指標はばらつきがあるため, 10 個のネットワークそれぞれについて, 分類回帰樹木 (CART 樹木) の検証を行った. その検証結果の上位から 3 つめのふしまでを (表. 2) に, CART 樹木のひとつを (図. 10) 示す.

これらの結果から, CART 樹木の最上位のルートでも媒介中心性, 入次数, ページランクと異なっており, CART 樹




図11 The validation of explanatory variables effects using Random Forest.

木のルート, ふしには一定の傾向がなかった.

7. 機械学習によるリンク削除後のネットワーク指標の評価

本章では, 機械学習を使い, ネットワーク指標から破綻の連鎖を予測することで, ネットワーク指標の重要度を評価し, ネットワークの違いによる特性をを検証する. ネットワーク指標は, これまでのリンク削除前のもではなく, リンク削除後のものを採用する.

7.1 リンク削除後のネットワーク指標を使った検証

ここまでの検証で使用したネットワーク指標は, リンク削除前の指標を使っていたが, 当然ながら, ネットワーク指標はリンク削除後に変化することに着目し, リンク削除後のネットワーク指標は, 破綻前のネットワーク指標より説明力が高くなるのではないかという仮説を立てた. その仮説を検証するため, リンク削除後のネットワーク指標と, その削除したネットワークにおける破綻連鎖数を使ったデータセットを用いて検証を行った. データセットは, 500 の金融機関ネットワークのノードひとつづつについてリンク削除を実施し, さらに, その削除したネットワークについてノード毎に破綻を発生させて連鎖数を計測したため, 一つのネットワークあたり, 250,000 件のデータセットを採取している. 検証はまず, 250,000 件のデータセットの半分 (125,000 件) を教師データ, 残り半分 (125,000 件) をテストデータとして, Random Forest 法で破綻の連鎖を予測したところ, 実データとその予測値に対するそれぞれの相関係数が 0.99, 平均二乗誤差が 0.185 であった. そのときの Random Forest 法による変数重要度のグラフを (図. 11) に, 教師データと予測データを比較したグラフの一部を (図. 12) に示す. 最も変数重要度が高かったのは "page rank" であり, 次に固有ベクトル中心性 (evcentness), 近接中心性 (closeness) となり, リンク削除前の指標でもっとも重要度が高かった媒介中心性 (BC) は, 4 番目という結果になった.

次に, 教師データの数に依存してネットワークの自己相関が高くなるのではないかという仮説を立て, Random Forest 法で教師データ, テストデータとも同じネットワークのも

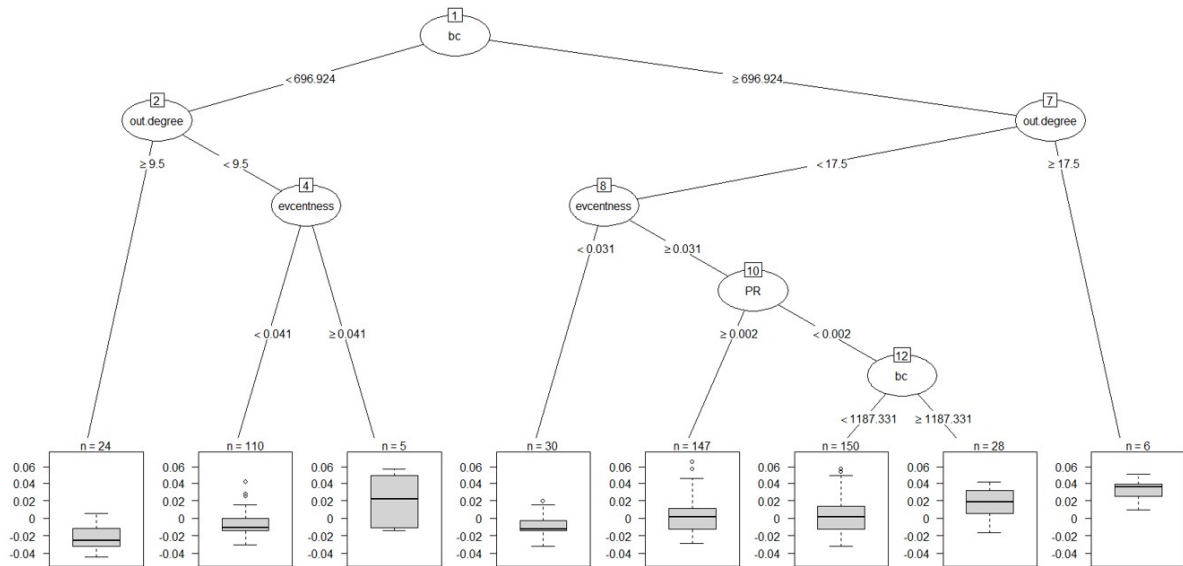


図 10 Classification and Regression trees.




図 12 The comparison between train data and test data.

表 3 Correlation Coefficient of Random Forest on same networks.

Train Data	500	1000	2000	10000
Test Data	500	500	500	500
RF Correlation Coefficient	0.85	0.94	0.97	0.99
RF Mean squared errors	0.680	0.472	0.309	0.204

のを使用して、教師データの数を調べて検証したところ、(表. 3) のような結果になった。結果として、仮説通り教師データの数が多くなるほど予測性能が良くなった。

しかしながら、本検証は同一ネットワークで学習、テストを実施しているため、破綻の連鎖差異が少なく自己相関が高くなっているのではないかと仮説を立て、個々の破綻の連鎖数差異を検証したところ、33%~35%変化し、その差異も大きいもので6破綻の連鎖数が変化していた。そのため、同一ネットワークによるリンク削除後のネットワーク指標による Random Forest 法の予測は、データ差異が微小なためではないことがわかった。これは、Random Forest 法による回帰分析では、各回帰木の予測の平均値をとるため、同一のネットワークによる予測がやりやすいためと考えられる。

表 4 Correlation Coefficient of Random Forest on different networks.

Train Data	500	1000	2000	10000
Test Data	500	500	500	500
RF Correlation Coefficient	0.39	0.37	0.35	0.32
RF Mean squared errors	1.091	1.105	1.124	1.155

そこで、ネットワークの違いによる予測性能の差異を検証するため、教師データとテストデータのネットワークを変えて検証を行った。その結果を(表. 4)に示す。同じネットワークの時に比べて、予測性能が落ちた。

8. 考察

本章では、本研究の考察を述べる。金融機関の資金取引ネットワークモデルで、金融機関の破綻の連鎖が媒介中心性 (betweenness centrality) 等のネットワーク指標と相関があることがわかったが、媒介中心性だけでは破綻の連鎖を十分説明できない。そのため、近接中心性 (closeness)、次数中心性 (degree), 固有ベクトル中心性 (eigencentrality), グラフ中心性 (graphcent), 入次数 (in.degree), 外向きの次数 (out.degree), ページランク (PR) の指標を加えることで、説明力を向上するのではないかと仮説を立てた。しかし、CART 樹木や Random Forest 法による部分従属度をもみても、各指標にばらつきがあり、一定の傾向が見られなかった。そこで、リンク削除後のネットワーク指標を使った検証を行ったが、同じネットワークでは教師データの数に依存して、説明力が高くなった。また、ネットワークの違う教師データを使った検証では、予測性能が落ちた。この結果は機械学習として順当な結果と思われる。また、本検証では大量の教師データをつかうことができるため、Deep Learning での検証を加えた。その結果、Deep Learning での予測のほう

表5 Correlation Coefficient of Random Forest and Deep Learning.

Train Data	500	1000	2000	10000
Test Data	500	500	500	500
RF Correlation Coefficient	0.39	0.38	0.35	0.32
RF Mean squared errors	1.091	1.105	1.124	1.155
DL Correlation Coefficient	0.47	0.48	0.49	0.48
DL Mean squared errors	1.039	1.032	1.037	1.032




図13 The comparison between train data and test data using Deep Learning.

が、Random Forest 法よりも良い性能で予測することができた。その時の結果を(表.5)に、Deep Learningでの教師データと予測データを比較したグラフの一部を(図.13)に、使用したパラメータを以下に示す。Deep Learningで良い予測性能を得られたのは、Random Forest法に近いDropoutを活性化関数に使用したが、Maxoutを加えており、その最大値を選択する特性が有効だったためではないかと思われる。

- 隠れ層: 2 から 5
- 各層のユニット数: 500 から 10000
- 活性化関数: MaxoutwithDropout

9. 結論と今後の展開

本章では、本研究の結論と今後の展開を述べる。本研究では、Erdos-Renyi ネットワークで構成した銀行間資金取引ネットワークモデルを構築し、ネットワーク特性の分析を行った。さらに、破綻の連鎖および提案した機械学習の効果をエージェントベースモデリングで検証し、以下の結果を得た。

(1) 資金援助を行うことによって、破綻連鎖数が増加する場合がある。

(2) 資金援助を行う金融機関を表すノードの媒介中心性は、破綻の連鎖を十分説明することができず、それ以外のネットワーク指標を追加し、機械学習を行うことで精度を向上することができる。

上記(1)については、破綻の連鎖数を低減させる目的で行う資金援助が、期待とは逆に増加させるリスクがあることを検証した。(2)については、その増加させるリスクを回

避するための方策として機械学習による検証を提案し、その精度の向上を確認した。

実際の金融機関に対する公的資金を注入する資金援助は、1行あたり平均1400億円、資本増強でも同様に1行あたり平均2000億円が使われている。実務的には、破綻してしまうと破綻の連鎖数が大きくなる金融機関に対して資金援助を行えるような判別が求められるが、媒介中心性による予測では、その判別精度が十分ではなかった。本研究の結果によって、破綻の連鎖数が大きくなる金融機関の判別精度の向上が期待できる。次に、今後の展開としては、今回はネットワーク特性に着目し、破綻の連鎖に関する判別はサンプルな外生的なもので検証を行ったが、資金の流動性の影響の考慮を追加したモデリングで、検証を行うことが考えられる。

参考文献

- [1] Acharya Viral, Engle Robert, Richardson Matthew., Capital shortfall: A new approach to ranking and regulating systemic risks. vol. 102, no. 3, pp. 59-64. The American Economic Review.(2012)
- [2] Benoit Sylvain, Colliard Jean-Edouard, Hurlin Christophe, Perignon Christophe., Where the Risks Lie: A Survey on Systemic Risk., HEC Paris Research Paper. (2015)
- [3] Eisenberg Larry, Noe Thomas H, Systemic Risk in Financial Systems., vol. 47, no. 2, pp.236-249.,Management Science.(2001)
- [4] Gai Prasanna, Kapadia Sujit. Contagion in financial networks., vol. 50. no. 2, pp. 124.,Bank of England Quarterly Bulletin.(2010)
- [5] May Robert M., Arinaminpathy Nimalan., Systemic risk: the dynamics of model banking systems. vol. 7, no. 46, pp. 823-838.,Journal of the Royal Society, Interface / the Royal Society.(2010)
- [6] Nier Erlend, Yang Jing, Yorulmazer Tanju, Alentorn Amadeo., Network models and financial stability. vol. 31, no. 6, pp. 2033-2060.,Journal of Economic Dynamics and Control.(2007)
- [7] Kei Imakubo, Yutaka Soejima. Funds trading network of the call market., vol. 27, no. -, pp. 47-99.,Studies of Finance.(2008)
- [8] Norio Konno, Naoki Masuda. Complex network. Kindai Kagaku-sya(2010)
- [9] Cifuentes Rodrigo, Ferrucci Gianluigi,Shin Hyun Song. Liquidity risk and contagion., vol. 3, no. 2- 3, p. 556-566., Journal of the European Economic Association. (2005)
- [10] Dias Andre, Campos Pedro, Garrido Paulo., An Agent Based Propagation Model of Bank Failures., , p. 119-130., Springer International Publishing, (2015)
- [11] Hyun Song Shin., Risk and liquidity., Oxford university Press Inc.,
- [12] Montagna Mattia, Lux Thomas. Hubs and resilience: towards more realistic models of the interbank markets. Banking Integration and Financial Crisis: Some Recent Developments. (2015),