

金融機関の破綻連鎖と
システミックリスク指標の研究

筑波大学審査学位論文（博士）

2017

橋本 守人

筑波大学大学院
ビジネス科学研究科 企業科学専攻

概要

金融機関における連鎖破綻の仕組みを解明するため、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いる。欧州では、一つの金融機関の破綻が自国のみならず欧州内の複数の国に拡散し連鎖破綻を起こすリスクがあるため、特に注目度が高い。一方、日本においては2000年代初頭の平成金融危機において、金融機関の破綻が数多く発生する等の事例があることから、金融機関の連鎖破綻リスクは金融システム安定化のために監視すべき項目の一つになっている。金融機関における資金取引の仕組みは複数の金融機関間の接続によるネットワークで実現されている。そのため、ひとつの金融機関の業務停止が連鎖的に他の金融機関の資金取引停止リスクにつながる。一般国民を含む預金者にとって、金融機関の資金取引停止は決済手段を失うことになるため、生活基盤への影響が大きい。そこで、政府は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整備しているが、金融危機が発生した場合には金融機関に対して公的資金を注入する可能性があり、国民負担になることもあることから社会的関心が高い。

そこで、本研究では金融機関の資金取引ネットワークにおいて、破綻の連鎖の仕組みを解明し、金融機関の救済において最小限のコストで破綻の連鎖リスクを低減するための方策を検証した。一つ目として、ランダムネットワーク（Erdos-Renyi モデル）とスケールフリーネットワーク（Barabasi-Albert モデル）で構成した開示されている財務データ等から矛盾のないシンプルな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して、破綻の連鎖の仕組みを検証した。May モデル May et al.2010 [MA10] の研究においてエージェントベースモデリングを用いて検証を行うことで、恣意的な仮説を立てずにシミュレーションを行うことによって、汎用的な検証の結果から特徴的な振る舞いをするエージェントを特定し、演繹的に金融システムを説明した。実務的には各金融機関のバランスシートを用いて、金融機関の破綻の連鎖を創発し、金融市場の変化を検証した。二つ目は、Barabasi-Albert モデルに比べて説明力が十分ではないランダムネットワーク（Erdos-Renyi モデル）で構成した銀行間資金取引ネットワークモデルにおいて、金融機関

の破綻連鎖リスクを測る指標として、機械学習による平均破綻連鎖数の予測値を提案した。検証の中では、平均破綻連鎖数の予測を行うためには機械学習のひとつである Xgboost (eXtreme Gradient Boosting) 法が有効であることを示した。また、リスクを測る指標として平均破綻連鎖数に加えて最大破綻連鎖数を提案し、複数の角度から分析を行った。さらに、ネットワーク特性の評価として有効な媒介中心性のような既存の指標だけではシステミックリスクの評価には不十分であるため、媒介中心性を拡張した新しいシステミックリスク指標を提案し、予測精度を向上させた。三つ目は、シンプルなバランスシートと預金準備率、自己資本率等の規制を考慮したエージェントベースモデルによるシステミックリスクの評価モデルを提案した。このモデルは、金融機関の規模と銀行間ネットワーク上の内生的なリスクの影響を考慮し、金融機関に対する規制の元での動的に変化するバランスシートの科目と銀行間資金取引の動きをシミュレーション可能にした。さらに、このモデルを用いて、金融機関の合併または統合を行うことによって金融機関の破綻連鎖への影響がどのように変化するか検証を行い、最近の日本の中・小規模銀行に対する銀行再編の流れを考慮して、金融機関の合併・統合の影響を検証した。これは [MA10] 等のベーシックモデルではできない分析である。

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。これは、今久保他 2008 [IS08] らによる金融機関の資金取引ネットワーク分析の特性を、公的資金の投入に対する確実性の向上を図るリスク指標を提言している意味で経済効果は大きい。

目次

第 1 章	序論	1
1.1	背景	1
1.2	目的	3
1.3	定義	4
1.4	構成	5
第 2 章	関連研究	7
2.1	はじめに	7
2.2	ネットワーク理論によるシステムリスクの関連研究	9
2.3	金融システムに関連するリスク指標	13
2.4	エージェントベースモデルによるシステムリスクの研究	16
2.5	本研究の位置づけ	17
2.6	まとめ	19
第 3 章	資金取引ネットワークを考慮したエージェントベースモデルによるシステムリスクモデル	21
3.1	はじめに	21
3.2	資金取引ネットワークのモデリング	22
3.3	エージェントベースモデルへの展開	24
3.4	ネットワーク指標を考慮した破綻連鎖リスクの分析	31
3.5	まとめ	37
第 4 章	ランダムネットワーク (Erdos-Renyi モデル) によるシステムリスクの評価	40

4.1	はじめに	40
4.2	平均破綻連鎖数の検証	41
4.3	最大破綻連鎖数の検証	45
4.4	システミックリスク指標の設定と評価	50
4.5	まとめ	55
第 5 章	資金取引ネットワークモデルに基づく金融機関の経営統合影響分析	58
5.1	はじめに	58
5.2	金融機関の経営統合影響分析モデル	59
5.3	経営統合影響分析モデルの検証	63
5.4	金融機関の統合影響分析の検証	67
5.5	金融機関の統合影響分析の評価	74
5.6	まとめ	77
第 6 章	結論	78
6.1	本研究の結論	78
6.2	今後の展開	83
6.3	むすび	84
	謝辞	86
	参考文献	87
	関連業績リスト	97

目次

1.1	日本の金融機関の一般的なバランスシート	2
1.2	日本と米国の破綻金融機関数の比較. 縦軸は破綻金融機関数, 横軸は年. 日本と米国で破綻金融機関数のピークに差異が見受けられる.	3
2.1	2016年6月発行の国際通貨基金 (IMF) の金融システムレポートで発表されたシミュレーション結果.	8
2.2	銀行間取引ネットワークのモデル. 銀行間取引を有向リンクで表す. 破綻が発生した場合は矢印の方向にショックが伝播する.	10
2.3	[IS08] の日本における 1997 年と 2005 年のコール市場の資金取引ネットワークの概念図. 1997 年はスター型に近いが, 2005 年はスケールフリー性が見られた.	11
2.4	[Usu17] による VaR の概念図	14
3.1	May モデルをベースとしたバランスシート. 左が負債で右が資産. 外部資産の損失に対して, 自己資本で吸収する.	23
3.2	May モデルをエージェントベースドモデルへ適応. フェーズ毎にショックが伝播し, 複数の金融機関からショックを受ける場合もある.	25
3.3	ABM による本研究の結果と先行研究 (May モデル) の結果の比較 (N=25).	27
3.4	ノードを削除する検証モデルのフロー図. ノード i, ノード j とも 500 ノードあるため, ネットワークあたり 250,000 回の検証を実施.	29
3.5	Erdos-Renyi モデルでのノード削除による破綻の連鎖数の増減の散布図. 縦軸は救済候補ノードのリンクを削除した後の平均破綻連鎖数から削除する前の平均破綻連鎖数を引いた増減, 横軸はノード番号. 平均破綻連鎖数が増加するケースがある.	30

3.6	本研究で使用した Erdos-Renyi モデル（上段）と Barabasi-Albert モデル（下段）における平均破綻連鎖数の増減の平均値と標準偏差。縦軸が平均破綻連鎖数の増減の平均値及び標準偏差，横軸がネットワークの番号を指す。各ネットワークあたり 500 個のデータを採取。	31
3.7	Barabasi-Albert モデルにおける削除するノードの次数と平均破綻連鎖数の増減の散布図。縦軸は平均破綻連鎖数の増減，横軸は次数。次数との強い相関がみられる。	32
3.8	媒介中心性を考慮したネットワーク図。媒介中心性の小さいノードはそのノードが流れの起点となり，媒介中心性の大きいノードは近傍のノードに流れの影響を与える。	34
3.9	媒介中心性とノード削除による破綻連鎖数増減の散布図。縦軸は平均破綻連鎖数の増減，横軸は媒介中心性。左下から右上に扇型に拡散していく形が見受けられる。平均破綻連鎖数の増減と救済候補ノードの媒介中心性にはわずかな相関 ($R^2 = 0.0835$) がある。	34
3.10	RandomForest 法による変数重要度のグラフ。縦軸は変数重要度。媒介中心性が最も変数重要度が高い。	35
3.11	8 種類のネットワーク指標を対象とした説明変数の部分従属プロット。	36
3.12	CART 図。最上位は媒介中心性。それ以外に出次数，固有ベクトル中心性，ページランクが出現している。	38
4.1	ノード削除後の平均破綻連鎖数で分類した Xgboost 法の検証結果による ROC 曲線。縦軸は感度，横軸は特異度。	44
4.2	Xgboost 法による変数重要度のグラフ。	45
4.3	Xgboost 法による変数重要度のグラフ。	48
4.4	500 ノードの金融機関について，縦軸を破綻の連鎖数，横軸を SRI とした散布図。	51
4.5	最大及び最小の SRI のノードを削除した場合と削除しない場合の差を比較した破綻連鎖数のグラフ。	52
4.6	媒介中心性による前半と後半に分類したときの散布図。前半，後半とも 250 ノード存在する。	55

5.1	経営統合影響分析のバランスシート	60
5.2	内生的リスクを発生させる資産の損失吸収プロセス. 損失が発生した場合, 自己資本の範囲で資産で吸収されるが, 総資産額及び総負債額は減少する.	62
5.3	銀行間融資と対外債務の損失プロセス.B 銀行が破綻した場合,A 銀行の対外資産 (External assets) は 1/3 損失する.	63
5.4	完全ネットワークの概念図	65
5.5	金融機関 A が金融機関 B を合併・統合する概念図. 下段はバランスシートを表し,L は負債,A は資産を表す.	68
5.6	金融機関ノードの次数と破綻連鎖数の散布図. 上が統合・合併前, 下が統合合併後. 縦軸が金融機関ノードの次数, 横軸が平均破綻連鎖数.	71
5.7	すべての金融機関のバランスシート合算値のグラフを示す. 上段は, メガバンクの破綻時のものを示し, 下段は小規模銀行の破綻時のものを示す. 縦軸は資金の合算値, 横軸は月数を示す. 本シミュレーションでは 12 月目に破綻が起きている.	76

表目次

2.1	システミックリスクの基本モデル	9
2.2	先行研究に対する本研究の位置付け	18
3.1	ABM による本研究の結果と先行研究 (May モデル) の結果の比較 (N=25) .	26
3.2	上位 3 つめのふしまでの CART 樹木による検証結果.10 種類のネット ワークで検証したところ, 最上位のふしには媒介中心性, ページランク, 入 次数が表れたが, 変数重要度とは一致していない.	37
4.1	Xgboost 法による破綻の連鎖の検証結果. 教師データ 1000 以降はわずか な精度の向上になっている. 媒介中心性の相関係数 (0.2889) に比べて向上.	43
4.2	ノード削除後の平均破綻連鎖数で分類した Xgboost 法の検証結果. 平均破 綻連鎖数が増加するものとそれ以外の 2 クラスに分類し, 検証を行った. .	43
4.3	ネットワーク毎の最大破綻連鎖数の検証結果. 括弧内の数字は, 各値の データ数.	46
4.4	全体での最大破綻連鎖数の増減の範囲	46
4.5	RandomForest 法による予測値と実データの比較	47
4.6	RandomForest 法による精度とマクロ平均	48
4.7	Xgboost 法による精度とマクロ平均	49
4.8	Xgboost 法による予測値と実データの比較	49
4.9	Xgboost 法による予測値と実データの比較	50
4.10	破綻連鎖数と SRI の相関係数と検定結果	52
4.11	BC と SRI を昇順に並べたときの破綻連鎖数の増減の推移	53
4.12	BC と SRI を降順に並べたときの破綻連鎖数の増減の推移	54
4.13	spearman と kendall の順位相関結果	54

5.1	リスク・ウェイト・アセットの設定	61
5.2	ドイツの 2011 EBA stress report をベースにしたバランスシートデータ (1:比率).	64
5.3	ドイツの 2011 EBA stress report をベースにしたバランスシートデータ (2:負債).	64
5.4	ドイツの 2011 EBA stress report をベースにしたバランスシートデータ (3:資産).	65
5.5	先行研究と本研究の検証結果の比較.	66
5.6	メガバンク, 中規模銀行, 小規模銀行のバランスシートモデル.	67
5.7	スケールフリーネットワークによる破綻連鎖数の検証結果.() 内はノード 番号を指す.	68
5.8	金融機関 2 行統合による平均破綻連鎖数の変化の検証結果. 括弧内の数字 はノード番号を表す.	69
5.9	金融機関 3 行統合による平均破綻連鎖数の変化の検証結果. 括弧内の数字 はノード番号を表す.	69
5.10	金融機関の合併・統合による破綻連鎖数の Top3 の検証結果. 括弧内は破 綻連鎖数の合算値.	70
5.11	金融機関の合併・統合を考慮した金融機関ノードの接続先の検証結果. 括 弧内の数字は次数を表す。No. はネットワークの識別番号を表す。from の領域が空白であれば、合併・統合ノードを表す。	72
5.12	銀行間取引の接続先と合併・統合したときの破綻連鎖数の検証結果. 合併・ 統合ノードの括弧内の数字は前者が入次数, 後者が出次数を表す.	73
5.13	銀行間取引の接続先と合併・統合したときの金融機関タイプ別の破綻連鎖 数の検証結果. 合併・統合後の破綻連鎖数を合併・統合後の値で除すこと で合併前と合併後の破綻連鎖数の比率を表している.	73

第 1 章

序論

1.1 背景

金融機関における連鎖破綻の仕組みを解明するため、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いる。欧州では、一つの金融機関の破綻が自国のみならず欧州内の複数の国に拡散し連鎖破綻を起こすリスクがあるため、特に注目度が高い。一方、日本においては 2000 年代初頭の平成金融危機において、金融機関の破綻が数多く発生する等の事例があることから、金融機関の連鎖破綻リスクは金融システム安定化のために監視すべき項目の一つになっている。金融機関における資金取引の仕組みは複数の金融機関間の接続によるネットワークで実現されている。

金融機関における資金取引の仕組みは複数の金融機関ネットワークで実現されている。金融機関ネットワークは、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あり、24 時間稼働している。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。

銀行のバランスシートを図 1.1 で表すと、「資産」の「現金預け金 (Cash and Due from Banks)」の一部が日本銀行預け金または他行への預け金を表し、同様に「コールローン」がコール市場を経由する資金貸付を表す。

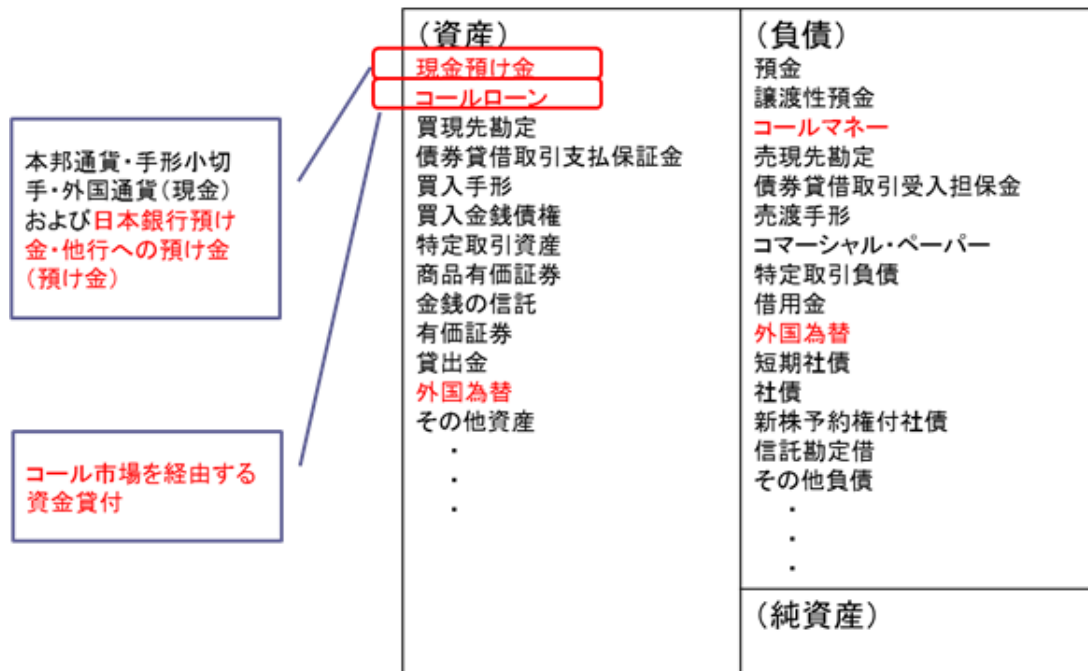


図 1.1 日本の金融機関の一般的なバランスシート

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、個別の金融機関の支払不能等や、特定の市場または決済システム等の機能不全が、他の金融機関、他の市場、または金融システム全体に波及するリスク）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。しかし、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。

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。図 1.2 は縦軸に金融機関の破綻数、横軸に年を表すが、日本と米国を比較すると、金融機関の破綻の増減のピークに関連がない。

これは、経済や金融システムに対して重大な悪影響を及ぼすとみなされる金融機関の場合には、日本と米国どちらも救済されることが多いが、それ以外の金融機関においては日本と米国で破綻処理のポリシーの違いが表れていると考えられる。米国では金融機関

の経営状況悪化に対してコスト最小化の原則のもと破綻処理を行っているため、事前に資本増強等を行う場合が少なく、破綻後に預金者を救済することを主な方策としているが、日本では同様の状況になった場合、資本増強や合併による救済が行われることが多い [Har09, Tak12] . 実際の破綻処理の傾向を確認するため、連邦預金保険公社 (FDIC) および預金保険機構の破綻処理データ [FDI17, DIC17] を分析した。日本のデータが存在する1998年以降現在までを調査したところ、米国の救済が行われた件数は、2008年11月23日のCITIBANK 関連等の5先、2009年1月16日のBank of America 傘下の8先がこれに該当し、計13先が資本増強を受けて救済されていた。これは同時期の破綻処理および救済件数全体の2.19%に相当する。一方日本では、金融機能強化法、組織再編法、預金保険法（危機対応）、早期健全化法等によって預金保険機構が救済を行うことになっており、1998年以降117先の資本増強・救済事例があった。これは同時期の破綻処理および救済件数全体の41.78%に相当する。

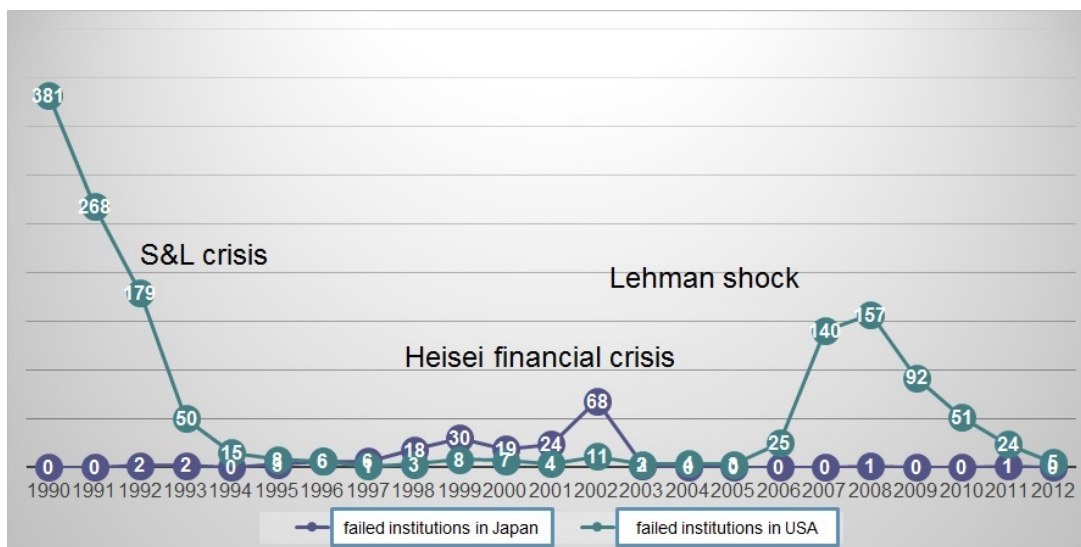


図 1.2 日本と米国の破綻金融機関数の比較。縦軸は破綻金融機関数、横軸は年。日本と米国で破綻金融機関数のピークに差異が見受けられる。

1.2 目的

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 [NS13] . 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、注入する資金額に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、どの金融機関に資金を注入するか、どうすれば最小の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。最近では、2016年12月のFSBのレポート [FSB16] においても、日本における破綻処理の透明性とガイダンスの必要性が指摘されており、引き続き課題になっている。

一方、金融機関の状況を鑑みると、バーゼル III への規制対応の方向性が見えてきたところで、メガバンクについては新たな TLAC (Total Loss Absorbing Capacity) の枠組みが検討され、さらなる規制対応が求められることになる。また、金融機関を取り巻く環境は、IT 技術の進化による決済の 24 時間対応、仮想通貨 (ビットコイン)、フィンテック (FinTech) によるビジネス等、新たな変化が起こっている。これらの変化によって金融機関の経営状態が変化すれば、それに備えて金融機関への規制の強化、預金保険の責任準備金の積み上げ、金融機関統合の推進等、システミックリスクへの新たな対策を進める必要がある。

1.3 定義

1.3.1 金融機関

金融機関とは、広義には経済社会において資金の供給・仲介などを行う金融取引に関する業務を営む組織 (機関) のことを言う。これは、資金の需要者と供給者の間にあって、資金の受け入れや貸し出しなどを行うことが許可されている機関であり、日本においては、中央銀行 (日本銀行)、公的金融機関 (公共的な目標達成を目的とした機関：政策金融機関、特殊法人、独立行政法人)、民間金融機関 (預金を取り扱う機関、預金を取り扱わない機関) の三つに大別される。

現在、民間金融機関には、預金を取り扱う機関として、普通銀行 (都市銀行、地方銀行、第二地方銀行、ゆうちょ銀行)、長期金融機関 (信託銀行)、中小企業金融専門機関 (信用金庫、信用組合、労働金庫、商工中金)、農林漁業金融機関があり、また預金を取り扱わない機関として、生命保険会社、損害保険会社、ノンバンク、証券会社、短資会社などがある。

本研究での金融機関は、狭義での預金取扱金融機関、いわゆる銀行等を指すものと定義

する.

1.4 構成

本研究では、一つ目として、銀行間の資金取引ネットワークは単一のモデルでは表せないが、今久保他 2008 [IS08] らが述べているように、コアペリフェラル型の複合的なネットワーク構造が見受けられるため、スケールフリー性、ランダム性を持つ。そのため、ランダムネットワーク (Erdos-Renyi モデル) とスケールフリーネットワーク (Barabasi-Albert モデル) 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、破綻の連鎖の仕組みを検証する。また、銀行間取引の実データは中央銀行等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、数理モデルを拡張したエージェントベースモデルにより、シンプルなエージェントの振舞いから創発的に起こる現象によってモデル化し、予測不可能な金融機関の破綻の連鎖をシミュレーションして検証を行うことで、破綻の連鎖を止める目的で実施する資本増強が、結果的に連鎖を増加させてしまう場合があることを検証し、資本増強を実施する金融機関の選定の重要性を明らかにする。

二つ目は、銀行間資金取引ネットワークを構成するコアペリフェラル構造において、スケールフリー性についてはリンクを削除する金融機関ノードの次数との強い相関が確認できるが、特に予測難易度が高いランダム性についてランダムネットワーク (Erdos-Renyi モデル) で構成した銀行間資金取引ネットワークモデルにおいて、機械学習のひとつである Xgboost 法が有効であることを示し、精度を上げるための新しい方策を提案する。その中では、破綻の連鎖が発生するメカニズムを解明するために、銀行間資金取引ネットワークの構造による影響を機械学習の手法を用いて分析する。また、リスク指標として最大破綻連鎖数についても検証し、複数の角度から分析を行う。さらに、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金融機関を選定するための新しいシステミックリスク指標を提案する。ネットワーク特性の評価として有効な媒介中心性のような既存の指標だけではシステミックリスクの評価には不十分であるため、判断の基準となるシステミックリスク指標を新たに提案し精度の向上を図る。これは、金融機関の資金取引ネットワーク分析の特性を、公的資金の投入に対する確実性の向上を図るリスク指標を提言している意味で経済効果は大きい。

三つ目は、シンプルなバランスシートと預金準備率、自己資本率等の規制の元で、内生的なリスクを考慮したエージェントベースモデルによるシステミックリスクの評価モデルを提案する。このモデルは、銀行間の貸借を資金取引ネットワークとして表し、金融機関に対する規制の元での資金取引の動きを考察する。さらに、このモデルを用いて、金融機関合併または統合を行うことによってシステミックリスクへの影響がどのように変化するか検証を行う。本モデルでは、金融機関を規模別に、メガバンク、中規模銀行、小規模銀行の3タイプに分類してエージェントを定義するが、分類を金融機関ノードの次数で判別するため、ネットワークは次数分布の大きいスケールフリーネットワークを採用する。さらに、2017年2月16日の日本銀行黒田総裁のコメント [Kur17] にもあるように、特に日本では金融機関の合併・統合により収益力を強化する動きがあるため、合併・統合による金融機関の破綻の連鎖の影響を検証する。合併・統合の効果については、必ずしも肯定的なものばかりではない [BDS99, 足立 13]。また、エージェントベースモデルを使うことで、金融機関の取引が金融システム全体に及ぼす影響を、シンプルなエージェントの振舞いから創発的に起こる現象によって、予測不可能な金融機関の破綻の連鎖をモデル化できるメリットがある。

本研究では以降、2章において関連するシステミックリスクモデル研究の関連研究を概観した後、3章で資金取引ネットワークを考慮した ABM によるシステミックリスクモデルについて、4章でランダムネットワーク (Erdos-Renyi モデル) によるシステミックリスクの評価について、5章で金取引ネットワークモデルに基づく金融機関の経営統合影響分析について述べ、6章で結論と今後の展開を述べる。

第 2 章

関連研究

2.1 はじめに

本章では、本研究の関連研究として、まず現在のシステミックリスク研究の動向について概観する。続いて、本研究でベースとした「ネットワーク理論によるシステミックリスクの関連研究」で、まず様々な研究の基礎となったベーシックモデルについて整理し、さらに日本の資金取引ネットワークの関連研究について述べた後、ネットワーク理論によるシステミックリスク研究の課題について整理する。その後、既存のベーシックモデルの課題を解消させるために発展させる要素として本研究で検討した金融システムのリスク指標を「金融システムに関連するリスク指標」で述べ、次に「エージェントベースモデルによるシステミックリスクの研究」で最近のエージェントベースモデルによる研究の傾向について整理し、「本研究の位置づけ」で既存の研究に対する本研究の位置づけを明らかにする。本章の最後では、「まとめ」として関連研究について総括する。

2.1.1 システミックリスクの定義

システミックリスクの定義は様々あり、例えば「ある金融機関の悪いニュースもしくは破綻または金融市場の崩壊が、単一もしくは複数の金融機関または市場に、連続的に相当程度の負の影響を与えるイベント」 [DBH00]、「金融システムの安定や公的な信頼を脅かすリスク」 [BGLP12]、または「経済成長や富が深刻な被害を受けるほど、金融システムの機能に損害を与える金融安定化のリスク」 [Ban10] などがある。

公式な定義では、IMF（国際通貨基金）、FSB（金融安定理事会）および BIS（国際決済銀行）が G20 首脳会合に共同で報告した「金融機関のシステム上の重要性を評価するガイ

ドライン」 [IBF09] では、「金融システム全体あるいは一部の障害により顕在化し、実体経済に深刻な負の結果をもたらす潜在性を保有する、金融サービスのフローを途絶するリスク」があり、本研究でもこの定義を採用する。

システミックリスクの定義に関する論文には、他にも [N⁺13, MS94, Kan13, Fuc10, Kob10, Sug10] などがある。

2.1.2 システミックリスク研究の動向

2016年6月発行の国際通貨基金（IMF）の金融システムレポート [Fun16] では、EUにおけるドイツ銀行のシステミックリスクの危険性が発表された。レポートの中では、世界的システミックリスクを抱える28の銀行のリスク度合いが実名入りで示されたため、大いに議論を呼んだが、本リスクの算定には [DY14, EVS10] による図 2.1 のようなシステミックリスクのシミュレーションが使われている。EUを中心とするシステミックリスクの研究は、近年数が増えてきており、数理モデル、実データを使った実証研究、さらには、本研究のようなエージェントベースドモデルを使ったもの等、研究テーマとして充実してきている。




図 2.1 2016年6月発行の国際通貨基金（IMF）の金融システムレポートで発表されたシミュレーション結果。

IMF などの国際的な機関から出されたシステミックリスクの論文には、他にも

[FLLO16, RLM12, SMJG12, LM11, RLK11, DPB+09] などがある。

2.2 ネットワーク理論によるシステミックリスクの関連研究

ネットワーク理論によるシステミックリスクの研究には、非常に多くの引用が行われているベーシックモデルが存在する。ここでは、まずベーシックモデルについて整理し、その後日本の資金取引ネットワークの研究について述べ、ネットワーク理論によるシステミックリスク研究の課題を整理する。さらにここで、既存のベーシックモデルの課題を解消させるために発展させる要素として本研究で検討した金融システムのリスク指標、エージェントベースモデルによるシステミックリスクの研究について述べる。

2.2.1 システミックリスクのベーシックモデル

システミックリスクの研究は、Eisenberg-Noe モデル Eisenberg et al.2001 [EN01] をベースとして発展し、NAMATAME2013 [Nam13] は、[EN01] を含め、以下の 4 モデルをシステミックリスクのベーシックモデルとして定義した。表 2.1 にそれらの特徴を表す。

表 2.1 システミックリスクの基本モデル

No.	モデル	文献	説明
1	Eisenberg-Noe Model	[EN01]	$N \times N$ マトリックスを使用し、システミックリスクのシミュレーション研究のベースとなった。
2	GK Model	[GK10]	バランスシートの資産側から伝播のショックを測定し、有向ネットワークとしての [Wat02] のカスケードモデルを拡張したものを採用した。
3	NYYA Model	[NYYA07]	小規模の金融ネットワーク ($N=25$) を使用し、スケールフリーネットワークを含む大規模ネットワークに拡張可能なモデリングをした。
4	May Model	[MA10]	GK と NYYA は、彼らのベンチマーク値の一つの値を変化させてモンテカルロシミュレーションを実施した。May は分析結果を提示し、NYYA の結果を平均場近似で検証した。May のモデルは、それぞれの銀行は同一のバランスシートを持ち、外向きと内向きのリンクの数が一致するモデル。

表 2.1 の (No. 2, 3, 4) の研究では、銀行間資金取引ネットワークを、図 2.2 のように表したが、ノードは金融機関、リンクは銀行間の貸借を指す。この中で、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失を被る。

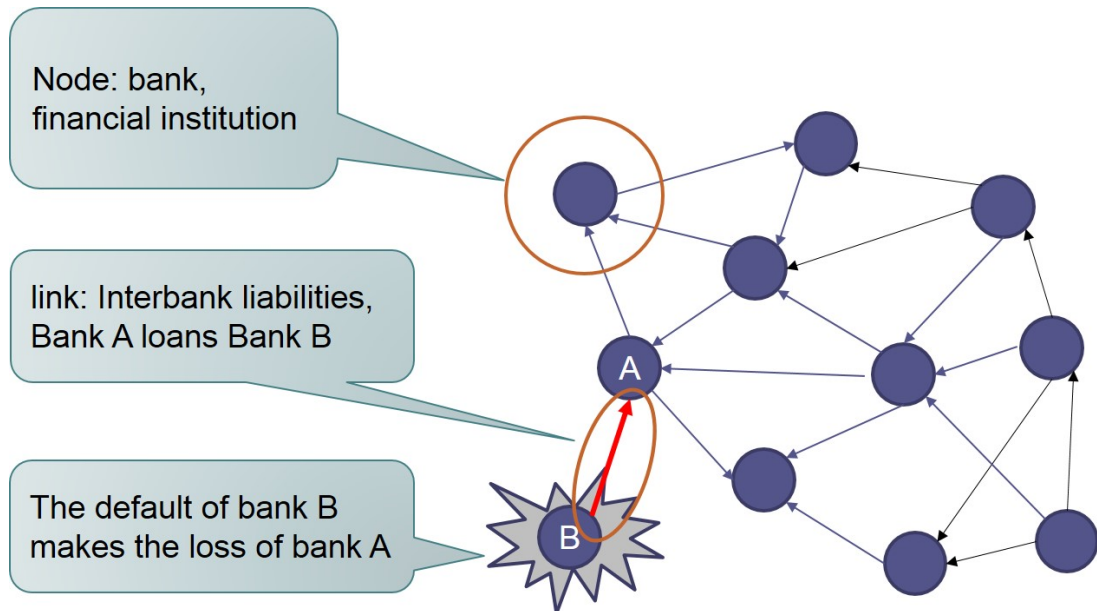


図 2.2 銀行間取引ネットワークのモデル. 銀行間取引を有向リンクで表す. 破綻が発生した場合は矢印の方向にショックが伝播する.

本研究でも、金融機関の破綻の連鎖について May モデル May et al.2010 [MA10] をベースにモデル化する。また、これらのベーシックモデル以外に引用の多い代表的なシステミックリスクの論文は、他に [HM11, FPR00, APPR10, RT96, Ach09, AOTS15] などがある。

[MA10] はベーシックモデルの中でも NYYA モデル Nier et al.2007 [NYYA07] を拡張したモデルであり、GK モデル Gai et al.2010 [GK10] は Watts2002 [Wat02] のネットワークモデルが前提のため制約があるので、本研究では金融機関の破綻の連鎖について [MA10] をベースにモデル化する。また、これらのベーシックモデル以外に引用の多い代表的なシステミックリスクの論文は、他に [HM11, FPR00, APPR10, RT96, Ach09, AOTS15] などがある。

2.2.2 日本の資金取引ネットワークの関連研究

本研究では、日本の資金取引ネットワークに関する総括的なものとして 今久保他 2008 [IS08] を参考にした。

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。比較前後では、月中取引実績があった金融機関数は 20% 減少し、取引を行った金融機関の組み合わせ数は 24% 増加している結

果となった。さらに、資金取引ネットワークが疎になっており、月中の総取引回数・総取引額の変化は3割程度減っていた。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、図2.3のようにスケールフリー性がみとめられた。[IS08]はこのような性質をコアペリフェラル構造と分類したが、コアペリフェラル構造は、複合的なネットワーク構造のため、スケールフリー性、ランダム性を持つ。コアペリフェラル構造については、イタリアの資金取引ネットワーク（e-MID）についての論文[IDMP⁺08]が言及しており、資金取引ネットワークはランダム性とスケールフリー性を持つコアペリフェラル構造であると述べている。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。

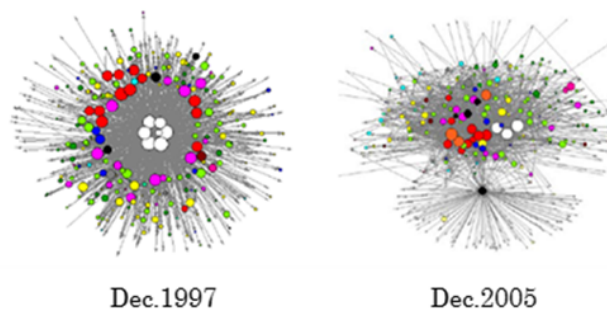


図 2.3 [IS08] の日本における 1997 年と 2005 年のコール市場の資金取引ネットワークの概念図。1997 年はスター型に近いが、2005 年はスケールフリー性が見られた。

[IS08] は、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としており、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り、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。システミックリスクについては、平時において想定されることは、資金市場にストレスが生じていて、特にコアの構成員がストレス下にある場合、平時の資金仲介が機能しないリスクをあげている。周辺でスター化しているローカルなネットワークで内部に資金が再分配される可能性があるとき、構成員の一先がコアにつながる場合、中央銀行の流動性供給手段にアクセス可能となる

ことが重要であるとしている。

日本の資金取引ネットワークに関する論文には、他にも [Mak11, S⁺05, INST03, MMMA12, Yos12, OH12] などがある。

2.2.3 ネットワーク理論によるシステミックリスク研究の課題

銀行間の資金取引ネットワークは、動的に変化するためある特定のネットワークモデルで表すことが難しい。本研究ではその点に着目し、ベースとなるネットワークはランダムネットワーク、スケールフリーネットワーク等の既存のものを使用するが、ある金融機関の破綻や、金融機関の合併・統合によるネットワーク構造の変化を想定して動的に変化する振る舞いを分析する。

ネットワーク構造に着目した関連研究には、[BK15, HVHS12, MMHK12, ML15, LW17, NS17, TIMR16] 等がある。また、システミックリスクの研究ではないが、ネットワーク構造として階層的にアプローチする手法として KURAHASHI et al.2013 [KS13]、リンクの予測を扱った DavidLiben et al.2007 [Davi07] があり、本研究ではこれらを参考にした。

また、小林 2014[Kob14] は、ベーシックモデルのような金融ネットワークモデルでは銀行間市場の貸借を想定してネットワークを構築し、その上でどこかのノードが破綻した場合の影響を分析するという手続きを踏んでいるが、現実にはこれだけではなく、保有外部資産の目減りによる自己資本の毀損や金融市場の機能不全によって流動性資産が枯渇することで、システミックリスクを顕在化させたとしている。そのような金融市場から発生するシステミックリスクを考慮するためには、内生的リスクを検討する必要がある。

加藤他 2012 [KT12] は、内生的なリスクとは、金融機関の集合的な行動から生じるリスクのことであり、既存のマクロ経済学のモデルでは、「銀行」を経済における一種の摩擦 (friction) としてモデル化しており、金融工学では基本的には危機をテイルリスク (tail risk) という発想でとらえていたとしているが、システミックリスクの研究でも内生的リスクを扱っている研究が増えてきている。

Cifuentes et al.2005 [CFS05] は、内生的なリスクを扱った研究のベースとなるものであり、不況下の非流動性資産の売却は市場価格を押し下げ、内生的に発生する資産の売却を促進して価格をさらに押し下げ、さらなる売却を促す可能性を指摘した。論文の中ではシミュレーション結果によって内生的リスクを定量化し、流動性資産の供給がシステミックリスクを低減するために有効であると述べた。

Chen et al.2016 [CLY16] は、債務救済のためのネットワークチャネルと資産の売買に使用する流動性チャネルの2つのチャネルの相互関係から内生的リスクを考慮したシステムミックリスクにアプローチし、欧州の金融機関の財務データから破綻の連鎖をシミュレーションし、結果を検証した。

他に内生的なリスクを扱った研究には [Hel12, CZ17, BBCH17, CWL17, MA17] があり、本研究でも内生的リスクを考慮する。

2.3 金融システムに関連するリスク指標

システムミックリスクとは、個別の金融機関の支払不能等や、特定の市場または決済システム等の機能不全が、他の金融機関、他の市場、または金融システム全体に波及するリスクのことをいう。システムミックリスク自体の大きさを表す指標はないが、関連するリスク指標について整理する。

2.3.1 金融動向指数

金融システムは平成バブルのような大規模な金融不均衡の発生だけでなく、金融機関の信用不安の発生や実体経済活動の落ち込みによっても、不安定化する可能性がある。内閣府の「景気動向指数」と同様の考え方に基づいて作成した金融システムの不安定化を事前に察知するためのDI (Diffusion Index) として、「金融動向指数」がある [KN11]。金融動向指数の先行指数がプラスからマイナスに転じることは、金融システムが近い将来に不安定化する可能性を示唆する。また、遅行指数がプラスからマイナスに転じることは、金融システムが既に不安定化していた可能性を示すが、金融動向指数は金融システム全体の概観を表す指標である。

2.3.2 VaR

次に、個別のリスク要素の損失度合いを測る指標として、VaR (Value at Risk) について述べる。[Usu17] による VaR の概念図を図 2.4 に示す。VaR はリスク要素の推移とその確率分布から、将来の損失が超過する確率が1%、つまり99%の確率で VaR を超過することがない状態を表すが、標準的な VaR は過去データをベースとして求めているため、環境の変化への対応が取り込めず、予測値としては限界があるという意見もある [YY00]。




図 2.4 [Usu17] による VaR の概念図

VaR を発展させた指標として、CoVaR と MES がある。CoVaR は [AB16] によって提唱され、個別金融機関に生じたストレスが金融部門全体に波及する度合いを計測した指標である。値が大きいくほど、個別金融機関に生じたストレスが金融部門全体に伝播しやすい状態であることを示す。CoVaR は、世界の大手銀行 29 行（いわゆる G-SIBs）の株式 VaR をもとに推計する。Co は、条件的（conditional）・共動的（co-movement）・伝染（contagion）・または寄与（contributing）を意味する。また、MES（Marginal Expected Shortfall）は [AER12] の提唱によるもので、金融部門全体に生じたストレスが個別金融機関の企業価値を悪化させる度合いを計測した指標であり、金融部門全体の株式 VaR がある水準を超えたときに個別金融機関が被る期待損失を示す。具体的には、金融部門全体の株式時価総額が下側 5% 点を下回った日における個別金融機関の株式時価総額の変化率として算出される。また、MES をさらに拡張した SRISK と呼ばれている指標もあるが、SRISK は金融機関の負債と規模を考慮する [BE16]。

これらは、株価や財務情報を元に確率変数として株価リターンや負債リターン使用しており、モンテカルロシミュレーションなどで評価する。損失分布の仮定に結果が依存してしまうという指摘もあり、デファクトスタンダードと呼べるものはまだない [Kan10]。

2.3.3 ストレステスト

最近ではストレステストによるリスク管理もよく行われている。ストレステストは、日常的に発生確率が低いと考えられるリスクシナリオを複数想定し、ヒストリカルデータから異常な環境下のものを抽出して、その発生確率や変動パターンを当該シナリオに当てはめ、現在のポジションが抱える潜在的なリスク量を計測し、不測の事態に備えるものであり、「例外的ではあるが、蓋然性のあるイベント (exceptional but plausible events) に対して、金融機関がどの程度脆弱であるかを検証するために用いられる手法」と定義されている。規制上の観点では、バーゼル銀行監督委員会より、2009年5月に、ストレステストの諸原則とまとめた最終文書「健全なストレステスト実務及びその監督のための諸原則」[Sup09] が公表されている。しかし、ストレステストではシナリオの設定が難しく、ある特定の変数を動かしてしまうと、他の変数との相関関係や、そもそもその変数を極端に動かすことの現実性を証明することが難しくなる [Fuj08]。ストレステストでリスクを評価した研究には [KM+17, DH17] 等がある。

2.3.4 個別の金融機関のリスク指標

他に、CDS (Credit Default Swap) のリスクを扱った研究 [MMNM14, DBPS17]、金融規制の影響をリスクで評価した研究 [Far17, ZC17, AJ17, Van17, FOS17, GLT15] 等があるが、これらは金融システム全体のリスクを測る指標であり、個別の金融機関のリスクは一般的にバランスシートの項目の比率を使った自己資本比率等の指標が使われている。自己資本比率は BIS による個別の銀行への資本規制として用いられているが、バランスシートでリスクを評価した研究には [F+17, HORV17, HZZ09] がある。

ただし、これらも含め、個別の金融機関の破綻の連鎖に関連するリスク指標は存在していないため、本研究では破綻の連鎖による金融システムへの影響を指標として表し、金融機関への資本増強を行うかどうか判断する尺度として評価する。さらに、リスク指標の設定にはシミュレーション結果から機械学習によって設定する手法も検討する。

2.4 エージェントベースモデルによるシステミックリスクの研究

システミックリスクの研究において、従来は数理モデルが多く採用されたが、[Ter10]によると数理モデルでは以下のようなアプローチが多く用いられた。

1. システムのふるまいを模倣する確率モデルをコンピュータ上に作成
2. そのモデルに対して試行実験を繰り返す
3. 得られた実験結果を統計的に解析してシステムの性能を推定

一方、一般的にエージェントベースモデルでは、「エージェント」と呼ぶ内部状態と意思決定・問題解決能力、ならびに通信機能を備えた複数の主体による以下のようなボトムアップな特徴を持つモデル化を試みて、インタラクションに基づく創発的な現象やシナリオを分析すると [Ter10] は述べている。

1. ミクロ的な観点においてエージェントが（個別の）内部状態を持ち、自律的に行動・適応し、情報交換と問題解決に携わる点
2. その結果として対象システムのマクロ的な性質が創発する点
3. エージェントとエージェントを囲む環境とがミクロ・マクロリンクを形成し、互いに影響を及ぼしあいながら、システムの状態が変化していく点

これを本研究に当てはめれば、「個別の内部状態」は「各金融機関のバランスシート」、
「創発するマクロ的な性質」は「金融機関の破綻の連鎖」、
「システム状態の変化」は「金融市場の変化」となる。

また,[Ter10] は、エージェント内部のデザイン、インタラクションの方式、ミクロ・マクロリンクの形成がシステムの評価以前に大きな問題になるリスクを上げており、KISS 原理 (Keep It Simple, Stupid!, ばかばかしいほどモデルを単純化せよ) を一つの回答としている。もちろん、KISS 原理だけでは金融システムの複雑な現象のモデル化は不可能であるが、エージェントベースモデルはシミュレーションの形を採用するとはいえ、特定の実験的な応用例を正確に描いて見せるのが目的ではなく、さまざまな応用例に表れる基本的なプロセスについての理解を深めるものであるため、本研究においてもシンプルなモデリン

グを方針のひとつとしている。

これらを踏まえ、エージェントベースモデルの手法を使ってシステミックリスクを研究するメリットを3点があげられる。

- 機密性の高い銀行間取引の実データは中央銀行等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。開示されている財務データ等から矛盾のないシンプルな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て十分な検証を行うことが可能になる。
- 金融機関の取引が金融システム全体に及ぼす内生的リスクのような挙動を、シンプルなエージェントの振舞いから創発的に起こる現象によってモデル化し、予測不可能な金融機関の破綻の連鎖をシミュレーションできる。
- 恣意的な仮説を立てずにシミュレーションを行うことができるため、汎用的な検証の結果から特徴的な振る舞いをするエージェントを特定し、演繹的に金融システムを説明できる。

特に3点目については、シミュレーション結果から影響を及ぼしたエージェントの振舞いを特定し、複雑な金融システムを解明できる。

ここで現状の研究者による論文の傾向をみると、[CF13, SKS17]らのサーベイ論文によればエージェントベースモデルを使ったシステミックリスクの論文はまだ少ないとされているが、最近の研究発表を見ると [DCG15, Lau17, GRPDG16, BBEHA17, DDG17, CW17, W⁺17, PC17], 日本でも [KKY⁺16a, KKY⁺16b] 等が発表され、次第に数が増えてきている。

2.5 本研究の位置づけ

これらの先行研究に対する本研究の位置付けは以下の表 2.2 のとおりである。

表 2.2 先行研究に対する本研究の位置付け

No.	著者名	論文	基本方式	内生的リスク	ノード数	ネットワーク
1	Eisenberg et al.	[EN01]	$N \times N$ マトリクス	考慮せず	規定せず	不使用
2	Gai et al.	[GK10]	[Wat02] のカスケードモデル	考慮せず	1000	ランダムネットワーク
3	Nier et al.	[NYYA07]	少数の銀行モデル	考慮せず	25	ランダムネットワーク
4	May et al.	[MA10]	平均場近似	考慮せず	25	ランダムネットワーク
5	Cifuentes et al.	[CFS05]	内生的リスク	考慮	10	ランダムネットワーク
6	Chen et al.	[CLY16]	財務データとシミュレーション結果の対比	考慮	11	完全ネットワーク
7	菊地他	[KKY+16a, KKY+16b]	市場性資産の価格変動による影響をエージェントベースモデルで分析	考慮	20	完全ネットワーク
8	橋本他	本研究	システミックリスクの研究をエージェントベースモデルに拡張	考慮	100,500	ランダムネットワーク, スケールフリーネットワーク, 動的变化を考慮

表 2.2 に記載した本研究の位置づけから、先行研究に対する本研究の優位性は以下のとおりである。

- [GK10, NYYA07, MA10, CLY16, KKY+16a, KKY+16b] では、資金取引ネットワークにランダムネットワークもしくは完全ネットワークを使用しているが、本研究では日本の分析結果に基づきランダムネットワークに加え、スケールフリーネットワークでの検証も行っている。【第 3 章, 第 5 章】
- [EN01, GK10, NYYA07, MA10] では、内生的リスクを考慮した市場型システミックリスクに対応できていないが、本研究では内生的リスクを考慮している。【第 5 章】
- [CFS05, CLY16, KKY+16a, KKY+16b] は内生的リスクを考慮した研究であるが、金融機関数が少なく金融システム全体のモデル化になっていないが、本研究では日

本の金融機関数を想定し、実データに即したネットワークを採用している。【第3章, 第4章】

- [CFS05, CLY16] は内生的リスクを数理モデルで表しているが、本研究ではエージェントベースモデルによりシンプルなエージェントの振舞いから創発的に起こる現象によってモデル化し、予測不可能な金融機関の破綻の連鎖をシミュレーションしているため、シミュレーション結果から影響を及ぼしたエージェントの振舞いを特定し、複雑な金融システムを解明できる。【第3章, 第4章, 第5章】

加えて、本研究では日本では金融機関の合併・統合により収益力を強化する動きがあるため、合併・統合による金融機関の破綻の連鎖の影響を検証する。合併・統合の効果については、必ずしも肯定的なものばかりではない [BDS99, Ada13, OS03, HK02, PR98, NBZZ04]。また、合併・統合による動的なネットワークの変化をエージェントベースモデルで実装することで、金融機関の取引が金融システム全体に及ぼす影響をモデル化できる。【第5章】

2.6 まとめ

本章では、関連研究として、ネットワーク理論によるシステムリスクの関連研究、金融システムに関連するリスク指標、エージェントベースモデルによるシステムリスクの研究をサーベイした。

本研究は、システムリスクのベーシックモデルでは扱っていない内生的リスクを考慮し、関連研究では行っていない実際の日本の金融機関数規模のシミュレーションを行い、リスク指標の設定には機械学習の手法を使っているが、それに加えて日本の金融機関の最近の動きとして増えてきている合併・統合を扱う。合併・統合については、動的なネットワークの変化を扱いやすいエージェントベースモデルによるモデル化をすることで、金融機関の取引が金融システム全体に及ぼす影響を、シンプルなエージェントの振舞いから創発的に起こる現象によって予測不可能な金融機関の破綻の連鎖をモデル化できるメリットがある。

また、機密性の高い銀行間取引の実データは中央銀行等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。開示されている財務データ等から矛盾のないシンプルな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て十分な

検証を行うことが可能になる。

以降, 第 3 章で本研究のベースとなる資金取引ネットワークを考慮したエージェントベースモデルによるシステミックリスクモデルを説明し, 第 4 章ではモデル化でリスク指標の設定が難しかったランダムネットワーク (Erdos-Renyi モデル) によるシステミックリスクの評価を行い, 第 5 章では資金取引ネットワークモデルに基づく金融機関の経営統合影響分析について述べる。

第3章

資金取引ネットワークを考慮した エージェントベースモデルによるシ ステミックリスクモデル

3.1 はじめに

前章では、システミックリスク研究の関連研究について述べ、本研究の位置づけを明らかにした。本章では、本研究のベースとなる資金取引ネットワークを考慮したエージェントベースモデル（以降、ABM）によるシステミックリスクモデルについて説明する。

まず、金融機関の破綻連鎖モデルとして [MA10] のモデルを拡張し、エージェントベースモデルを用いてネットワークの構成の変化が動的に銀行間取引に影響を与えるモデルを構築する。検証ではランダムネットワーク（Erdos-Renyi モデル）とスケールフリーネットワーク（Barabasi-Albert モデル）で構成した銀行間資金取引ネットワークモデルを使用し、ネットワークモデルの差異によって破綻の連鎖の仕組みがどのように影響を受けるかを検証する。

本章の「資金取引ネットワークのモデリング」でモデリングの手法について述べるが、本研究では金融機関の破綻の連鎖について [MA10] をベースにモデル化する。次に、「エージェントベースモデルへの展開」で資金取引ネットワークモデルを ABM に拡張する手法を明らかにする。続いて、「ネットワーク指標を考慮した破綻連鎖リスクの分析」で、破綻連鎖リスクについて資金取引ネットワークのネットワーク指標で分析するが、本研究ではスケールフリー性の検証として Barabasi-Albert モデル、ランダム性の検証として

Erdos-Renyi モデルの各ネットワークを採用して検証を行う。さらに、本章の最後に「まとめ」で本章で行った資金取引ネットワークを考慮した ABM によるシステミックリスクモデルについて評価を行い、本章を総括する。

3.2 資金取引ネットワークのモデリング

3.2.1 May モデルの検証

本研究では、金融機関の破綻の破綻連鎖モデルとして [MA10] のモデル（以下、May モデル）を採用した。May モデルでは、金融機関の破綻は所与のものとして与えられるが、考慮すべき原因としてこれ以外に特定資産の投売りや、短期金融市場の機能不全等がある。本研究では、発生した破綻の連鎖を最小のコストで食い止めることを研究の主な目的としているため、金融機関の破綻発生の原因を May モデルと同じシンプルな構成にし、金融市場は金融機関の破綻が発生しうる状況であることを前提としているが、本件には拡張の余地があるため「6.2 今後の展開」で記述する。本研究では May モデルのバランスシート図 3.1 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。

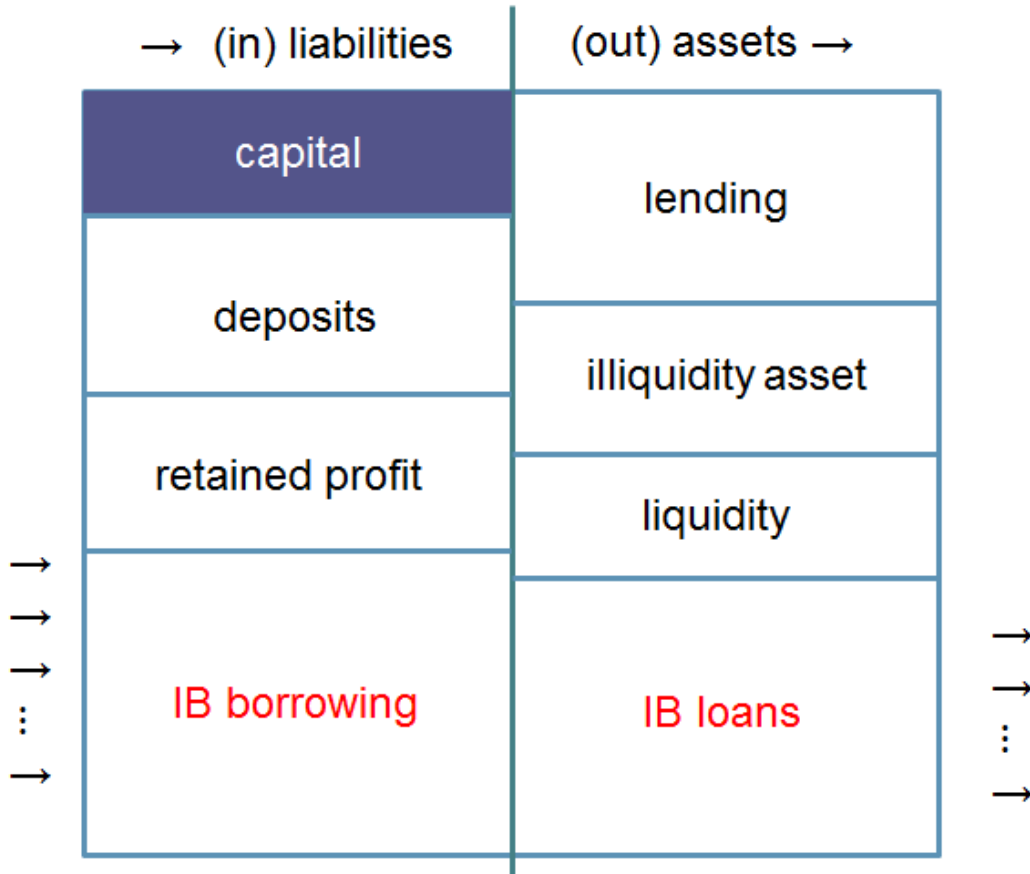


図 3.1 May モデルをベースとしたバランスシート. 左が負債で右が資産. 外部資産の損失に対して, 自己資本で吸収する.

f : 対外資産に対するショックの割合

θ : 資産に対する銀行間融資の割合

S_I : フェーズ I 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 I, フェーズ II, フェーズ III と定義している. まず, フェーズ I ショックは 3.1 式のように定義する. ただし, 以下の値はすべての銀行で同じとする.

$$S_I = f(1 - \theta) \tag{3.1}$$

3.1 式で, フェーズ I ショックを表したとき, 3.2 式の条件で伝播したフェーズ I ショックが自己資本を上回り, 金融機関は破綻する.

$$S_I > \gamma \tag{3.2}$$

次に、フェーズ II ショックの伝播では、フェーズ I の個別銀行による債務不履行が、債務者銀行のフェーズ II ショックを発生させる。3.3 式のように、フェーズ II 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）

$$S_{II} = \frac{[\theta, S_I - \gamma]_{MIN}}{z} \quad (3.3)$$

また、フェーズ III のショックも、3.3 式の S_I に、 S_{II} を代入することで、3.4 式のように定義できる。

$$S_{III} = \frac{\{\theta, [\theta, f(1 - \theta) - \gamma]_{MIN}/z - \gamma\}_{MIN}}{z} \quad (3.4)$$

フェーズ I ショックの時と同様に、フェーズ II ショックおよびフェーズ III ショックが発生した場合も、自己資本比率を上回った場合は金融機関が破綻する。また、 N （金融機関数）が z^2 より十分大きいとき、各々のショックはネットワーク上を十分伝播するが、ショックは z で除されるため、次数が多いノードはショックが低減される。

3.3 エージェントベースモデルへの展開

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 [Hyun15][Kan10] が、資金取引ネットワークを構成する金融機関全体への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等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。

ABM 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、モデルの近似性を検証
- (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

3.3.1 エージェントベースモデリング環境構築

モデル化は、図 3.2 のように行った。まず、① フェーズ I 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 II 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 III 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 3.2 のように複数回受ける可能性がある。

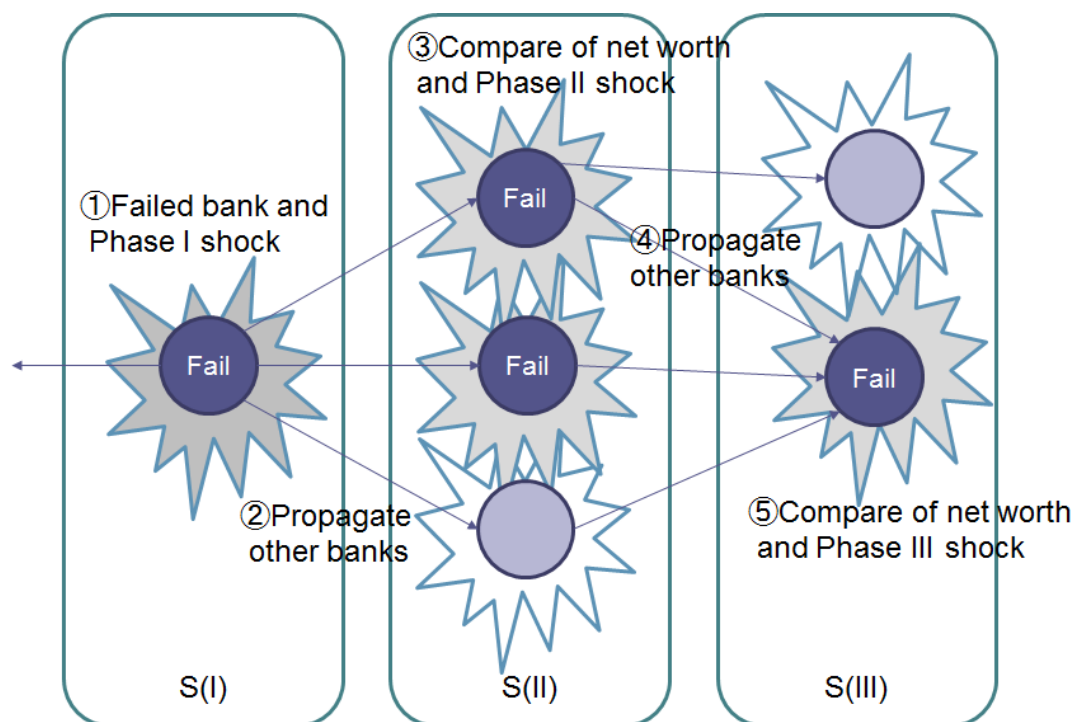


図 3.2 May モデルをエージェントベースモデルへ適応。フェーズ毎にショックが伝播し、複数の金融機関からショックを受ける場合もある。

ここで、May モデルでは、3.3 式、3.4 式の銀行間融資の数 (z) として、平均場近似で求めた代表値 (4.8) を使用しているが、本研究ではエージェントベースモデルを用い、各ノードの内向きのリンク数（入次数）を銀行間融資数として採用した。このことにより、金融ネットワークの構造によって銀行間融資における銀行毎の外部資産の値が変化する。また、後述する銀行の破綻もしくは救済するモデルにおいても、ノードのリンク削除によって銀行の

外部資産の値が変化し、破綻の連鎖への影響をより現実に即した形で実装している。

3.3.2 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 他の検証と同様に、以下のパラメータを設定し、検証を実施した。May 他にもまた、NYYA[NYYA07] のシミュレーション結果をもとに比較している。

・ネットワーク: ランダム (Erdos-Renyi モデル) , スケールフリーネットワーク (Barabasi-Albert モデル)

- ・自己資本比率: $\gamma=0.8$ (フェーズ I) , 0.042 (フェーズ II) , 0.016 (フェーズ III)
- ・資産の毀損比率: $f=1$
- ・資産に対する銀行間融資の比率: $\theta=0.20$
- ・銀行 A が銀行 B に融資する確率: $p=0.2$

ここで、May 他の検証では、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の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 III で 18.796、フェーズ II で 3.408 であった。その結果を表 3.1 に表す。これは、図 3.3 の「★」で表した値になり、フェーズ II および、フェーズ III 破綻の平均場近似の結果と同等で、近似性があるモデリングができていると判断した。ここで、表 3.1 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 II もしくはフェーズ III ショックで破綻する金融機関数の平均値

表 3.1 ABM による本研究の結果と先行研究 (May モデル) の結果の比較 ($N=25$) .

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




図 3.3 ABM による本研究の結果と先行研究（May モデル）の結果の比較（N=25）。

3.3.3 ネットワークモデルの構築

銀行間の資金取引ネットワークは単一のモデルでは表せないが, [IS08] らが述べているように, コアペリフェラル型の複合的なネットワーク構造が見受けられるため, スケールフリー性, ランダム性を持つ. コアペリフェラル構造については, イタリアの資金取引ネットワーク (e-MID) についての論文 [IDMP+08] が言及しており, 資金取引ネットワークはランダム性とスケールフリー性を持つコアペリフェラル構造であると述べている. そのため, 本研究ではスケールフリー性の検証としてスケールフリーネットワーク (Barabasi-Albert モデル), ランダム性の検証としてランダムネットワーク (Erdos-Renyi モデル) を採用して検証を行った. ここで, Barabasi-Albert モデルのべき指数は 3, Erdos-Renyi モデルの connection probability は 0.02 を採用している. connection probability の根拠は, [IS08] 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.

また, それ以外にネットワーク共通のパラメータとして, ノード数は 500 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, 日本の金融機関数は 548 であるためノード数を 500 としている, これらのパラメータを整理すると以下のようなになる.

- ・資産の毀損比率: $f=1$
- ・資産に対する銀行間融資の比率: $\theta=0.20$

- ・銀行 A が銀行 B に融資する確率: $p=0.02$
- ・Barabasi-Albert モデルのべき指数: 3
- ・総銀行数: $N=500$

3.3.4 システミックリスクを低減するネットワーク指標の検証

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の資金取引ネットワークと、その金融機関を破綻させ市場から退場させた場合の資金取引ネットワークとで、資金取引ネットワーク全体の破綻連鎖リスクを、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で検証した。ここで、金融機関の破綻は例えば 1994 年の北海道拓殖銀行等の事例では、不良債権の増加、預金の流出、流動性資金不足といった状況の結果として破綻が発生したが、そのような複合的な状況の結果ひとつの金融機関の経営状況が悪化し、ほかの金融機関についても連鎖破綻が起こりうる状況を想定している。

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ろという考え方から、金融機関の経営努力の欠如を招き、その金融機関の経営状況が悪化する度に資金援助が必要になり、公的資金の注入量を増長させるリスクもある。また [KM10] では、ネットワーク理論における媒介中心性を考慮することで、破綻の連鎖を増長しうるノードを削除する、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言及しており、本検証でもそのような結果が起こりうるという仮説を立てた。

具体的な検証は、金融機関の資金取引ネットワーク上で、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を、ノード i のリンクを削除しない場合のものと比較し、その増減を計測した。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、その場合は公的資金の適用によりノード 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、公的資金の注入により資本増強を行い、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、ひとつのネットワークあたり合

計 250,000 回の検証を測定した. その検証のフロー図を図 3.4 に, 検証結果の散布図を図 3.5 に示す. なお, 図 3.5 は縦軸に救済候補ノードのリンクを削除した後の平均破綻連鎖数から削除する前の平均破綻連鎖数を引いた増減, 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破綻連鎖数の増減の平均値を表している.

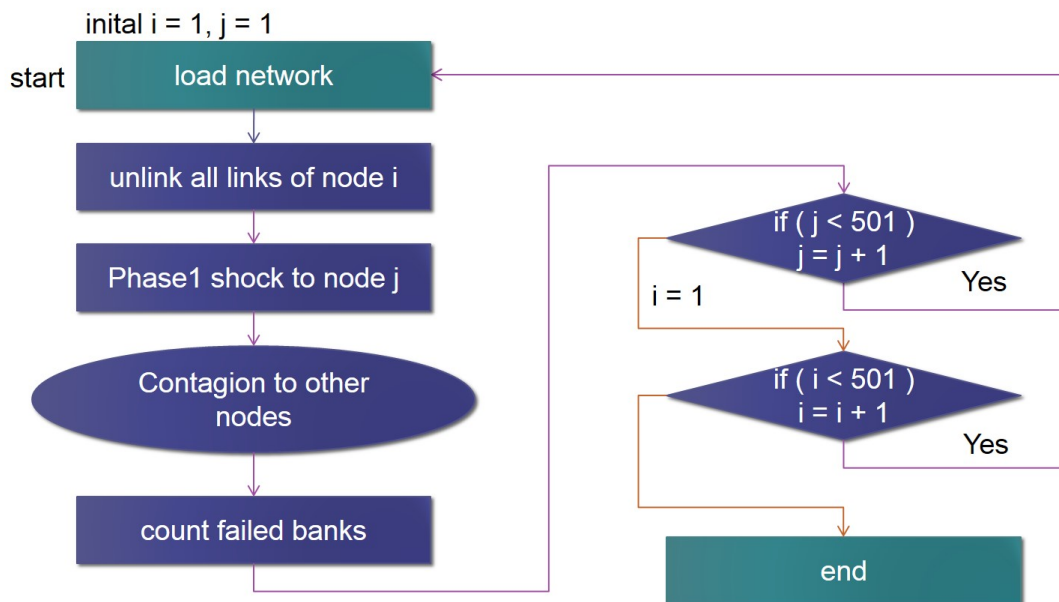


図 3.4 ノードを削除する検証モデルのフロー図. ノード i , ノード j とも 500 ノードあるため, ネットワークあたり 250,000 回の検証を実施.




図 3.5 Erdos-Renyi モデルでのノード削除による破綻の連鎖数の増減の散布図. 縦軸は救済候補ノードのリンクを削除した後の平均破綻連鎖数から削除する前の平均破綻連鎖数を引いた増減, 横軸はノード番号. 平均破綻連鎖数が増加するケースがある.

検証の結果, Erdos-Renyi モデルおよび Barabasi-Albert モデルそれぞれ 10 ネットワークにおいて, ノードのリンクを削除することによって, 仮説通り破綻の連鎖が減少することがわかった. しかし, 破綻の連鎖が増える場合もあり, 資本増強による金融機関の存続が, 連鎖を増長してしまうことがあるため, 資本増強を行う金融機関の選定は慎重に行う必要があることが確認できた. Erdos-Renyi モデルの破綻の連鎖の増減を図 3.5 に示す. なお, 個々のネットワークの構造による影響について検証するため, 10 個の異なるネットワークを生成し, 破綻連鎖数の母平均の差の検定するために, 一元配置分散分析を行ったところ, Barabasi-Albert モデルについて有意水準 5% で帰無仮説「母平均は等しい」は棄却されず (p 値 0.801), また Erdos-Renyi モデルについても同様に棄却されなかった (p 値 0.086). このことにより, 図 3.5 で示した平均破綻連鎖数の増減の統計的等質性が確認できた. 本研究で使用した 10 種類のネットワークによる平均破綻連鎖数の増減の平均値と標準偏差のプロットは図 3.6 の通りである. ただし, Erdos-Renyi モデルの場合は有意水準 10% では, ネットワークの差異による影響を排除できないため, 機械学習による破綻の連鎖の予測 (4.2 節) では, 乱数シードが異なる 10 種類のネットワークを用いて機械学習を行った.




図 3.6 本研究で使用した Erdos-Renyi モデル（上段）と Barabasi-Albert モデル（下段）における平均破綻連鎖数の増減の平均値と標準偏差。縦軸が平均破綻連鎖数の増減の平均値及び標準偏差，横軸がネットワークの番号を指す。各ネットワークあたり 500 個のデータを採取。

3.4 ネットワーク指標を考慮した破綻連鎖リスクの分析

ここでは、破綻連鎖リスクの評価を資金取引ネットワークのネットワーク指標で分析する。本研究ではスケールフリー性の検証として Barabasi-Albert モデル、ランダム性の検証として Erdos-Renyi モデルを採用して検証を行った。

3.4.1 スケールフリーネットワーク（Barabasi-Albert モデル）による分析

本研究ではまず、スケールフリーネットワーク（Barabasi-Albert モデル）で破綻の連鎖を計測した。スケールフリー性を持つネットワークは、一般的にランダムな故障や攻撃に対して強い特性があるが、Barabasi-Albert モデルでノード削除を行った場合、平均破綻連鎖数の増減と、リンクを削除するノードの次数との強い相関を図 3.7 のように確認することができた。このときの相関係数は、10 個のネットワークでいずれも 0.79 以上（分散は 0.00056）であった。これは、次数の高いノードのリンクを削除する場合、破綻が連鎖せず分断されてしまう場合が多くなる事象を表していると考えられるが、ハブのような次数の高いノードのリンクを削除することを考慮すれば、妥当な結果と思われる。




図 3.7 Barabasi-Albert モデルにおける削除するノードの次数と平均破綻連鎖数の増減の散布図。縦軸は平均破綻連鎖数の増減、横軸は次数。次数との強い相関がみられる。

3.4.2 Erdos-Renyi モデルによる分析

次に、Erdos-Renyi モデルで検証を行う。本研究では、Erdos-Renyi モデルの破綻の連鎖に対する媒介中心性の影響を考慮する。媒介中心性については、[IS08] が言及している通り、銀行 A・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、銀行破綻ショックの伝播に巻き込まれやすい、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、[KM10] は、媒介中心性によるネットワークの流量の影響について言及しており、その中では、媒介中心性が小さい点を除去すると、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、連鎖の影響が少なくなるとの考え方による。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させるので、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、[KM10] 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 3.8 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、近傍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 3.9 の散布図のように、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。本研究では、破綻連鎖のショックは 3.3 式、3.4 式で表されるが、これらの分母が (z) 、つまり「実際のノードの入次数」であるため、図 3.8 にあるようにあるノードを取り除くことによって分母が小さくなり、近傍ノードの破綻連鎖ショックの流れの量が大きくなる。バランスシートを考慮すると、あるノードを取り除くことは、銀行間融資における外部資産の 1 行あたりの大きさが増えることになり、その銀行に対する依存度が高まる。本研究では、入次数の変化によって、金融機関の資金異動メカニズムを表しているが、May モデルでは (z) は定数であるため、破綻連鎖のショックはネットワーク構造の影響を受けない。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 3.8 において、最小の媒介中心性のノードから出る破綻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 3.9 は、縦軸にノードのリンクを削除する前と削除した後の削除するノード毎の平均破綻連鎖数の増減、横軸に媒介中心性を表す。

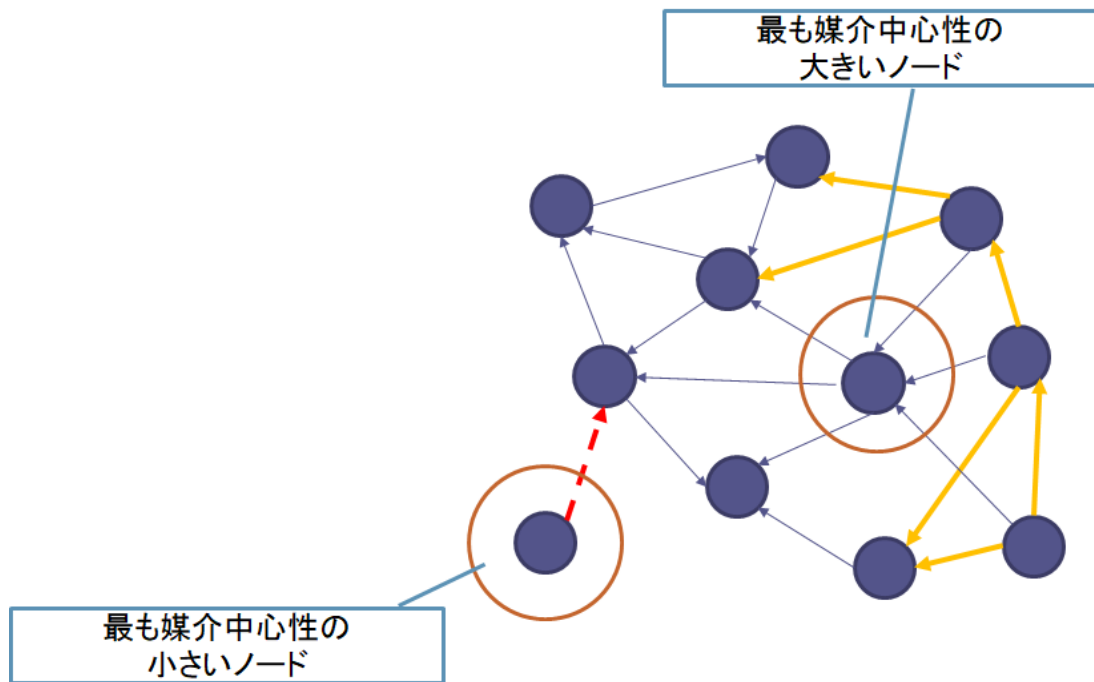


図 3.8 媒介中心性を考慮したネットワーク図. 媒介中心性の小さいノードはそのノードが流れの起点となり, 媒介中心性の大きいノードは近傍のノードに流れの影響を与える.




図 3.9 媒介中心性とノード削除による破綻連鎖数増減の散布図. 縦軸は平均破綻連鎖数の増減, 横軸は媒介中心性. 左下から右上に扇型に拡散していく形が見受けられる. 平均破綻連鎖数の増減と救済候補ノードの媒介中心性にはわずかな相関 ($R^2 = 0.0835$) がある.

図 3.9 のように, 媒介中心性だけで破綻の連鎖を予測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. 破綻連鎖数の増減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.

3.4.3 Erdos-Renyi モデルにおけるネットワーク指標の分析

破綻の連鎖を予測するためには,媒介中心性だけでは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,機械学習の Random Forest 法で測定した. Random Forest 法を使用することで,ネットワーク指標の重要度(寄与度)を算出することができる.測定した指標は媒介中心性(BC),近接中心性(closeness),次数中心性(degree),固有ベクトル中心性(eigenvector),グラフ中心性(graph),入次数(in.degree),出次数(out.degree),ページランク(PR)の8種類(図 3.10 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.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 3.10 に,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 3.11 に示す.




図 3.10 RandomForest 法による変数重要度のグラフ. 縦軸は変数重要度. 媒介中心性が最も変数重要度が高い.

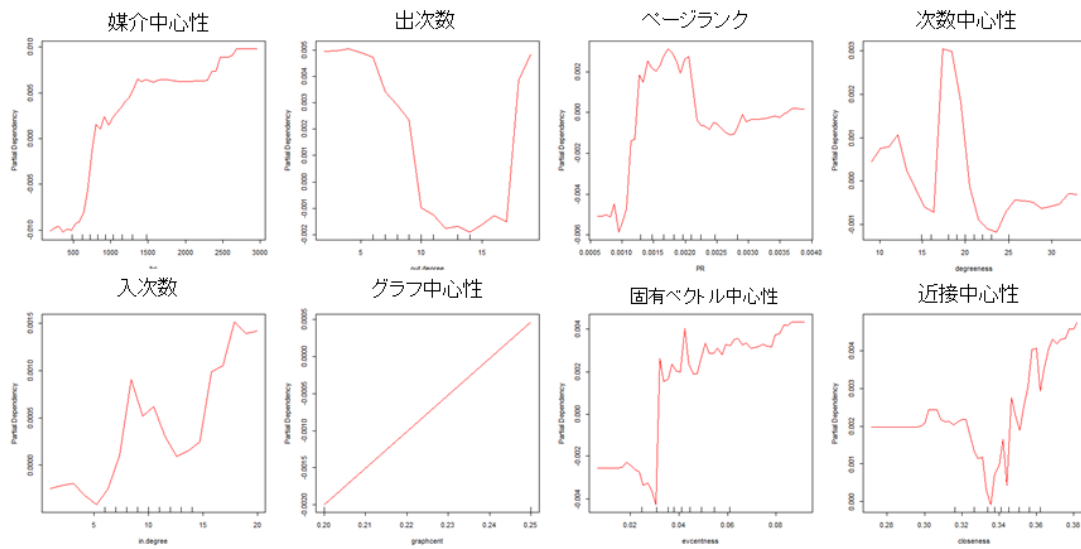


図 3.11 8 種類のネットワーク指標を対象とした説明変数の部分従属プロット.

図 3.10 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. このように, 媒介中心性の説明力が最も高かったが, その他の指標と格段の差があるわけではないため, 10 個のネットワークそれぞれについて, CART 樹木による検証を行った. その検証結果の上位から 3 つめのふしまでを表 3.2 に, CART 樹木のひとつを図 3.12 示す.

表 3.2 上位3つめのふしまでの CART 樹木による検証結果.10 種類のネットワークで検証したところ, 最上位のふしには媒介中心性, ページランク, 入次数が表れたが, 変数重要度とは一致していない.

ネットワーク	1 段目	2 段目	3 段目
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

ここで, 比較のために同様の指標で重回帰分析のステップワイズ法による変数選択についても調査したが, やはり同様に変数選択にばらつきがみられ, 一貫性がなかった. これらの結果からみても, ルートは媒介中心性, 入次数, ページランクと異なっており, 媒介中心性以外の指標を考慮する必要があることが分かった.

3.5 まとめ

ここでは, 資金取引ネットワークを考慮した ABM によるシステミックリスクモデルの評価を行う.

本章では, まず, 資金取引ネットワークのモデリングの手法について述べた. 本研究では金融機関の破綻の連鎖について [MA10] をベースにモデル化を行ったが, 数理モデルで行

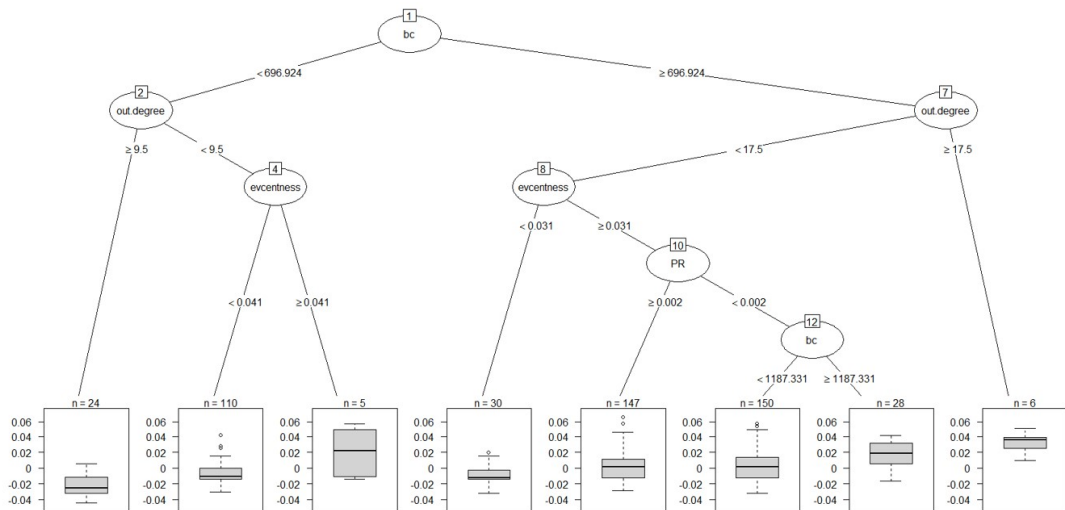


図 3.12 CART 図. 最上位は媒介中心性. それ以外に出次数, 固有ベクトル中心性, ページランクが出現している.

われている [MA10] の May モデルを整理し, 破綻の連鎖のふるまいを明らかにした. May モデルでは, 銀行間融資の数 (z) として, 平均場近似で求めた代表値 (4.8) を使用しているが, 本研究ではエージェントベースモデルを用い, 各ノードの内向きリンク数 (入次数) を銀行間融資数として採用した. このことにより, 金融ネットワークの構造によって銀行間融資における銀行毎の外部資産の値が変化する. また, 銀行の破綻もしくは救済するモデルにおいても, ノードのリンク削除によって銀行の外部資産の値が変化し, 破綻の連鎖への影響をより現実的に即した形で実装できた.

次に, 資金取引ネットワークモデルを ABM に拡張する手法を明らかにした. さらにその検証結果を先行研究と比較し, 図 3.3 のように先行研究の検証結果と本研究の ABM の検証結果がほぼ同等の値になることを確認した.

また, 本章の主要な成果として破綻連鎖リスクの評価を資金取引ネットワークのネットワーク指標で分析した. 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の資金取引ネットワークと, その金融機関を破綻させ市場から退場させた場合の資金取引ネットワークとで, 資金取引ネットワーク全体の破綻連鎖リスクを, 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で検証した. 使用したネットワークは, スケールフリー性の検証としてスケールフリーネットワーク (Barabasi-Albert モデル), ランダム性の検証としてランダムネットワーク (Erdos-Renyi モデル) を採用して検証を行った. Barabasi-Albert モデルについて

は、リンクを削除する金融機関ノードの次数との強い相関が確認できたが、Erdos-Renyi モデルについては媒介中心性のようなネットワーク指標である程度の説明をすることができるが、有効なネットワーク指標がネットワーク構成によって変わり、Barabasi-Albert モデルのような強い相関は確認できなかった。Erdos-Renyi モデルのシステミックリスクの評価については、4 章で評価する。

第 4 章

ランダムネットワーク (Erdos-Renyi モデル) によるシステムミックリスクの評価

4.1 はじめに

前章では、資金取引ネットワークを考慮したエージェントベースモデルによるシステムミックリスクモデルについて説明したが、銀行間の資金取引ネットワークは単一のモデルでは表せず、[IS08] らが述べているように、コアペリフェラル型の複合的なネットワーク構造が見受けられスケールフリー性、ランダム性を持つ。そこで本研究で使用したネットワークは、スケールフリー性の検証としてスケールフリーネットワーク (Barabasi-Albert モデル)、ランダム性の検証としてランダムネットワーク (Erdos-Renyi モデル) を採用して検証を行い、Barabasi-Albert モデルについては、リンクを削除する金融機関ノードの次数との強い相関が確認できた。しかし、Erdos-Renyi モデルについては媒介中心性のようなネットワーク指標である程度の説明をすることができるが、有効なネットワーク指標がネットワーク構成によって変わり、Barabasi-Albert モデルのような強い相関は確認できなかった。そこで本章では、Barabasi-Albert モデルに比べて説明力が十分ではないランダムネットワーク (Erdos-Renyi モデル) で構成した銀行間資金取引ネットワークモデルにおいて、金融機関の破綻連鎖リスクを測る指標として、機械学習による平均破綻連鎖数の予測値を提案する。その検証の中で、平均破綻連鎖数の予測を行うためには機械学習のひとつである Xgboost (eXtreme Gradient Boosting) 法が有効であることを示し、破綻の

連鎖が発生するメカニズムを解明するために、銀行間資金取引ネットワークの構造による影響を機械学習の手法を用いて分析する。また、リスクを測る指標として平均破綻連鎖数に加えて最大破綻連鎖数を提案し、複数の角度から分析を行う。さらに、ネットワーク特性の評価として有効な媒介中心性のような既存の指標だけではシステムリスクの評価には不十分であるため、媒介中心性を拡張した新しいシステムリスク指標を提案し、予測精度を向上させる。

なお、本研究で機械学習を使用する理由は以下のとおりである。

- 機械学習を行うことで、複数のネットワーク指標による教師データの中から、変数重要度（寄与度）を算出することができる。
- 突出した精度の説明変数がないため、機械学習による予測値を破綻の連鎖を表す指標とすることができる。
- エージェントベースモデルによるシミュレーションで生成される大量のデータを高速に処理することができる。
- 恣意的な操作を排除し、採取した教師データの特徴から金融機関の破綻連鎖を分析し予測できる。

まず、「平均破綻連鎖数の検証」で、機械学習として Xgboost 法を採用し、平均破綻連鎖数の予測を行う。次に、破綻連鎖リスクを検討するうえで破綻連鎖数の最大値の変化を見ることによって、リスクの尺度とすることもできるため、「最大破綻連鎖数の検証」で破綻連鎖数の最大値について検証する。さらに、「システムリスク指標の設定と評価」で既存のネットワーク指標ではなく新しいシステムリスク指標を設定し、破綻の連鎖予測の精度向上を図り、「まとめ」で本章を総括する。

4.2 平均破綻連鎖数の検証

ここでは、機械学習を使い、ネットワーク指標から破綻の連鎖リスクを評価する手法を検証する。

4.2.1 機械学習による破綻の連鎖の予測

3.4.3 のように本研究では、10 個のネットワークを使って金融機関の破綻の連鎖を解明する検証を行ったが、それぞれのネットワーク全体について同一になる傾向は現れず、ネットワーク毎に、説明変数としての有効な指標は異なっていた。そこで、個別のネットワーク指標によらず、多様なデータを教師データとして予測を行うことで説明力の精度が上がるのではないかと仮説を立て、検証をおこなった。

また、機械学習の手法として本研究では Xgboost 法を用いて評価を行ったが、Xgboost 法は、教師データを用いて学習を行い、その学習結果を踏まえて逐次に重みの調整を繰り返すことで複数の学習結果を求め、その結果を組み合わせることで精度を向上させるものである。組み合わせは逐次的に実施し、新しい学習を実施する際に、それまでに構築されたすべての学習結果を利用する。その後、ブースティングでステップ毎に学習して損失関数を最小化するため、各学習データのうち、前のステップで間違えて識別されたものへのウェイトを重くして、次のステップで間違えたものをうまく識別できるようにしている。Xgboost 法では RandomForest 法と同様に、樹木モデルを使うことで、回帰と分類どちらへも対応可能であり、外れ値や欠損値に強いという性質を持っているものであるため、RandomForest 法よりも出現率の低いデータを予測できる可能性があり、高い精度が期待できる。

具体的には、10 個のネットワークのうち、9 個を教師データとし、残りの 1 つを訓練データとする方式として、Xgboost 法によって検証を行った。ここで、10 個のネットワークから 9 個の教師データを作成するケースは 10 種類あるため、その 10 回の平均値を表 4.1 に示す。1 つのネットワークデータは 500 あるので、教師データは 4500、訓練データは 500 になるが、データ量により精度に差が出るかどうかを検証するため、教師データは (500,1000,2000,4500) の 4 パターン計測した。なお、Xgboost 法のパラメータは、(max_depth: 1, eta: 0.15, nrounds: 150, objective: reg:linear) である。

表 4.1 Xgboost 法による破綻の連鎖の検証結果. 教師データ 1000 以降はわずかな精度の向上になっている. 媒介中心性の相関係数 (0.2889) に比べて向上.

教師データ	500	1000	2000	4500
訓練データ	500	500	500	500
spearman	0.32	0.39	0.40	0.41
kendall	0.23	0.28	0.28	0.28
pearson	0.32	0.38	0.38	0.38
平均 2 乗誤差	0.00030	0.00029	0.00029	0.00029
pearson の p 値	2.12e-13	2.2e-16	2.2e-16	2.2e-16

表 4.1 の結果のように, 教師データの数を増やすことの有効性が確認できたが, 本研究では, 対象としている問題の影響が大きいものであるため, 結果をすべて一様に解釈するのではなく, 救済する基準を決定し, ROC 曲線を描いて AUC で評価する方法を検討した. 具体的には, ノードを削除することによって, 平均破綻連鎖数が増加するものとそれ以外, つまり変化がないか減少するものの二値に分類し, クラス分類問題として検証を行った. 分類には同様に Xgboost 法を用い, その結果を表 4.2 に, 教師データが 4500 件の結果のうちの一つの ROC 曲線を図 4.1 に示す. なお, 検証は 10 分割交差検証で実施し, 表 4.1 と同様に 10 個のネットワークから 9 個の教師データを作成するケースは 10 種類あるため, その 10 回の平均値を採用している. この図 4.1 の ROC 曲線では, 感度 0.53, 特異度 0.78, 正答率 0.67 が達成できた. これは, 別途検証を行った SVM (正答率 55.1%), RandomForest 法 (正答率 54.58%) よりも高い精度が得られている. なお, Xgboost 法のパラメータは, (max_depth: 4, eta: 0.01, nrounds: 100, objective: reg:logistic) である.

表 4.2 ノード削除後の平均破綻連鎖数で分類した Xgboost 法の検証結果. 平均破綻連鎖数が増加するものとそれ以外の 2 クラスに分類し, 検証を行った.

教師データ	500	1000	2000	4500
訓練データ	500	500	500	500
正答率	0.62	0.63	0.67	0.67




図 4.1 ノード削除後の平均破綻連鎖数で分類した Xgboost 法の検証結果による ROC 曲線. 縦軸は感度, 横軸は特異度.

4.2.2 機械学習による破綻の連鎖の分析

Xgboost 法による変数重要度の平均値のグラフ 図 4.2 を以下に示す. Xgboost 法による変数重要度では媒介中心性が最も説明力が高かった. 媒介中心性を考慮して破綻の連鎖を低減させるためには, 図 3.8 に示したように, 媒介中心性の小さいノードを削除する方が考えられる. しかし, ノードを削除することは金融機関を資金取引ネットワークから除くことになるため, 積極的にとるべき方策ではない. それ以外の方策としては, 金融機関を合併・統合させることが考えられるが, 合併・統合については第 5 章で評価する. また, 2 番目に入次数, 3 番目に出次数の説明力が高いが, これらのネットワーク指標については, 4.4 で評価する.




図 4.2 Xgboost 法による変数重要度のグラフ.

4.3 最大破綻連鎖数の検証

ここでは、Erdos-Renyi モデルの評価の方策として、最大破綻連鎖数を検討する。3.4.2 で検証したように Barabasi-Albert モデルに対して、Erdos-Renyi モデルは予測が難しいが、いままで平均破綻連鎖数を評価してきたのに対して、本章では最大値の破綻連鎖数を扱う。最大破綻連鎖数において、Erdos-Renyi モデルでの特性が現れれば、破綻連鎖リスクの有効な指標とすることができる。

4.3.1 最大破綻連鎖数の検討の目的

金融機関の破綻連鎖リスクを評価する場合、ネットワーク毎の平均破綻連鎖数以外に、最大破綻連鎖数を検討することが考えられる。最大破綻連鎖数は、最も破綻の連鎖が多く発生した場合の数を表すが、リスクとして評価する場合、最も悪い値を想定することは、市場リスクの予想最大損失額を算出する指標である VaR (Value at Risk) 等の指標と同様の考え方であり、金融リスクの評価では考慮すべき指標である。ここで、最大破綻連鎖数は、平均破綻連鎖数と同様に、経営状況が悪化した金融機関を救済するかどうか、つまりノード i を削除するかどうかの影響をみるために、あるノード i 削除の有無の 2 パターンで、破綻す

るノード j を 1 から 500 まで変化させたときの最大破綻連鎖数を計測した. 表 4.3 にその結果を示す. ここで, 「最大破綻連鎖数の増減の範囲」は, あるノード i を削除した場合の破綻するノード j を 1 から 500 まで変化させたときの破綻連鎖数の最大値から, ノード削除を行っていない元のネットワークで同様に計測した破綻連鎖数の最大値を引いた値の範囲を指す. 削除するノード i も 1 から 500 まで変化させるため, 破綻連鎖の最大値もネットワーク毎に 500 個の値がある. 検証はネットワークごとに 10 分割交差検証で実施し, 各ネットワーク当たり 250,000 件のデータを採取したため, 合計 2,500,000 件のデータで分析した. なお, 括弧内の数字は, 各値のデータ数である.

表 4.3 ネットワーク毎の最大破綻連鎖数の検証結果. 括弧内の数字は, 各値のデータ数.

	最大破綻連鎖数	最大破綻連鎖数の増減の範囲
1	7	0(473), 1(27)
2	8	-2(1), -1(7), 0(485), 1(7)
3	7	-1(9), 0(482), 1(9)
4	9	-2(1), -1(8), 0(477), 1(13), 2(1)
5	7	-1(7), 0(479), 1(14)
6	7	-1(6), 0(487), 1(7)
7	5	0(432), 1(67), 2(1)
8	8	-2(1), -1(7), 0(485), 1(7)
9	7	-2(2), -1(478), 0(20)
10	6	0(482), 1(18)

4.3.2 最大破綻連鎖数の評価

表 4.4 のように, 10 個のネットワークで検証した結果の合計でも, 最大破綻連鎖数の増減は取りうる値の範囲が小さく, 2 増えるパターンも 5000 件のデータに対して 2 件, つまり 0.04% しか発生せず, 極めて稀である.

表 4.4 全体での最大破綻連鎖数の増減の範囲

	-2	-1	0	1	2
10 ネットワーク合計値	5	522	4302	169	2

ここで, 最大破綻連鎖数の増減に対する説明力の高いネットワーク指標を検証するために RandomForest 法で検証を行った. 使用したネットワーク指標は, 3.4.3 同様, 媒介中心性 (BC), 近接中心性 (closeness), 次数中心性 (degree), 固有ベクトル中心性

(evcentness), グラフ中心性 (graphcent), 入次数 (in.degree), 出次数 (out.degree), ページランク (PR) の 8 種類である. RandomForest 法を使用した理由は, 本研究では 3.4.3 のように RandomForest 法で平均破綻連鎖数の変数重要度を採取しており, 最大破綻連鎖数の変数重要度と比較できること, RandomForest 法が高性能であり, 回帰分析だけでなく分類問題にも対応できること, があげられる. 検証にあたって, 最大破綻連鎖数の増減は表 4.3 のように, 取りうる値の範囲が狭く, 加えて 2 増えるパターンおよび, 2 減るパターンの出現率が稀であるため, 回帰分析では予測不可能であった. そのため, 最大破綻連鎖数の増減のバリエーションを分類問題ととらえ, 予測を行った. 10 個のネットワークの平均の精度は 0.952 であったが, 表 4.5 のように, もっともバリエーションの多い 4 番目のネットワークの予測値と実データを比較すると, 出現率の低いデータは予測できておらず, 出現率の高いデータが高い精度に貢献しているものであった.

表 4.5 RandomForest 法による予測値と実データの比較

	増減	予測値				
増減		-2	-1	0	1	2
実測値	-2	0	0	1	0	0
	-1	0	0	8	0	0
	0	0	1	476	0	0
	1	0	0	13	0	0
	2	0	0	1	0	0

本研究では, 出現率が低い最大破綻連鎖数の増減を予測することが重要なため, 4.2.1 同様, Xgboost 法を用いて評価を行った. Xgboost 法は, 教師データを用いて学習を行い, その学習結果を踏まえて逐次に重みの調整を繰り返すことで複数の学習結果を求め, その結果を組み合わせて精度を向上させるものである. Xgboost 法では RandomForest 法と同様に, 樹木モデルを使うことで, 回帰と分類どちらへも対応可能であり, 外れ値や欠損値に強いという性質を持っているものであるため, RandomForest 法よりも出現率の低いデータを予測できる可能性がある.

まず, Xgboost 法を適用するにあたり, 変数重要度を評価したが, 10 個のネットワークの平均が図 4.3 のようになり, 媒介中心性 (BC), 近接中心性 (closeness), 固有ベクトル中心性 (evcentness), ページランク (PageRank) の値が高かったため, 教師データとしてはこの 4 指標を採用した.




図 4.3 Xgboost 法による変数重要度のグラフ.

次に、出現率の低いデータを分類問題として評価するにあたり、マクロ平均を採用した。マクロ平均は、各クラスの精度の平均値であり、各々のクラスの精度を評価する指標として有効である。また、教師データとしては訓練のデータも含めているが、本件については後段で評価する。

RandomForest 法の結果を表 4.6 に、Xgboost 法の結果を表 4.7 に示す。なお、9 番目のネットワークのデータは、極端に低い値になったため外している。Xgboost 法のパラメータは、(nrounds: 100, num_class: 5, objective: multi:softmax) である。

表 4.6 RandomForest 法による精度とマクロ平均

自分データあり		各セットの正解率					
RF	accuracy	-2	-1	0	1	2	macro average
1	0.946	0	0	0.946	0	0	0.189
2	0.974	1	1	0.974	0	0	0.595
3	0.966	0	1	0.966	0	0	0.393
4	0.956	1	0	0.956	0	0	0.391
5	0.958	0	0	0.958	0	0	0.192
6	0.978	0	1	0.978	0	0	0.396
7	0.868	0	0	0.867	1	0	0.373
8	0.97	0	0	0.970	0	0	0.194
10	0.964	0	0	0.964	0	0	0.193
average	0.953						0.324

表 4.7 Xgboost 法による精度とマクロ平均

自分データあり		各セットの正解率					
xgboost	accuracy	-2	-1	0	1	2	macro average
1	0.952	0	0	0.952	1	0	0.390
2	0.99	0	1	0.990	1	0	0.598
3	0.984	0	1	0.984	1	0	0.597
4	0.994	1	1	1	1	1	1
5	0.994	0	1	0.994	1	0	0.599
6	0.99	0	1	0.990	1	0	0.598
7	0.914	0	0	0.909	1	1	0.582
8	0.984	0	1	0.984	1	0	0.597
10	0.994	0	0	0.994	1	0	0.399
average	0.977						0.595

このように、精度、マクロ平均とも Xgboost 法が勝っており、RandomForest 法で予測できなかつた出現頻度の低いデータも、表 4.8 のように、完全に予測ができています。

表 4.8 Xgboost 法による予測値と実データの比較

増減	増減	予測値				
		-2	-1	0	1	2
実測値	-2	1	0	0	0	0
	-1	0	8	0	0	0
	0	0	0	477	0	0
	1	0	0	0	13	0
	2	0	0	0	0	1

4.3.3 最大破綻連鎖数の特性

本研究の RandomForest 法および Xgboost 法での教師データには、訓練データを含んでいるが、訓練データを外した場合、表 4.9 のように、精度はさほど変わらないがマクロ平均の値が悪くなっており、出現率の低いデータが予測できていない。これは、出現率の低いデータを教師データとするにあたり、教師データ数が少ないため精度が落ちてしまったことが要因の一つと考えられる。出現率の低いデータの教師データを増やす方策として、本研究では訓練データを教師データに含めた。また、前章で記載したように、有効なネットワーク指標がネットワーク構成によって変わることが Erdos-Renyi モデルの特性であるため、ネットワークが変わると出現率の低いデータが表れにくくなるともいえる。

表 4.9 Xgboost 法による予測値と実データの比較

	RandomForest 法		Xgboost 法	
	精度	マクロ平均	精度	マクロ平均
教師データに訓練データ含まず	0.952	0.190	0.939	0.215
教師データに訓練データ含む	0.953	0.324	0.977	0.595

4.4 システミックリスク指標の設定と評価

ここでは, Erdos-Renyi モデルの評価の方策として, 新しいシステミックリスク指標を設定する. 3.4.2 で検証したように Barabasi-Albert モデルに対して, Erdos-Renyi モデルは予測が難しいため, Erdos-Renyi モデルで予測の精度を向上させ, 破綻の連鎖が多く発生する金融機関ノードを識別するための独自の指標を提案する. また, モデルの構造が明確な指標を用いることで, 破綻のメカニズムの一部を明らかにする.

4.4.1 システミックリスク指標の設定

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ため, 資金援助を行うことによる破綻の連鎖の影響を表す指標を検討する. その指標を SRI とし, (4.1) 式で表す.

$$SRI = \sum_{i \neq j \neq k} \frac{g_{jk}(i)}{g_{jk}} + \left[\frac{D_{out} - D_{in}}{D_{in} + D_{out}} * \alpha N \right]_{cond} \quad (4.1)$$

- ・ *SRI*: Systemic Risk Index の意
- ・ g_{jk} : 頂点 j と頂点 k の間の最短経路数
- ・ $g_{jk}(i)$: 頂点 j と頂点 k の間の最短経路のうち頂点 i を通るものの数
- ・ D_{in} : 入ってくるリンクの次数
- ・ D_{out} : 出ていくリンクの次数
- ・ α : 係数, 本検証では 2
- ・ N : ノード数
- ・ *cond*: 入ってくるリンクの次数と出ていくリンクの次数の両方がそれぞれの次数の平均より大きいときのみ考慮

図 3.5 と同じ結果について, 横軸に SRI をとった散布図を 図 4.4 に示し, 最大および最小の SRI のノードを削除した場合について, 削除有/無のノード毎の破綻連鎖数を比較

したグラフ 図 4.5 を以下に示す.

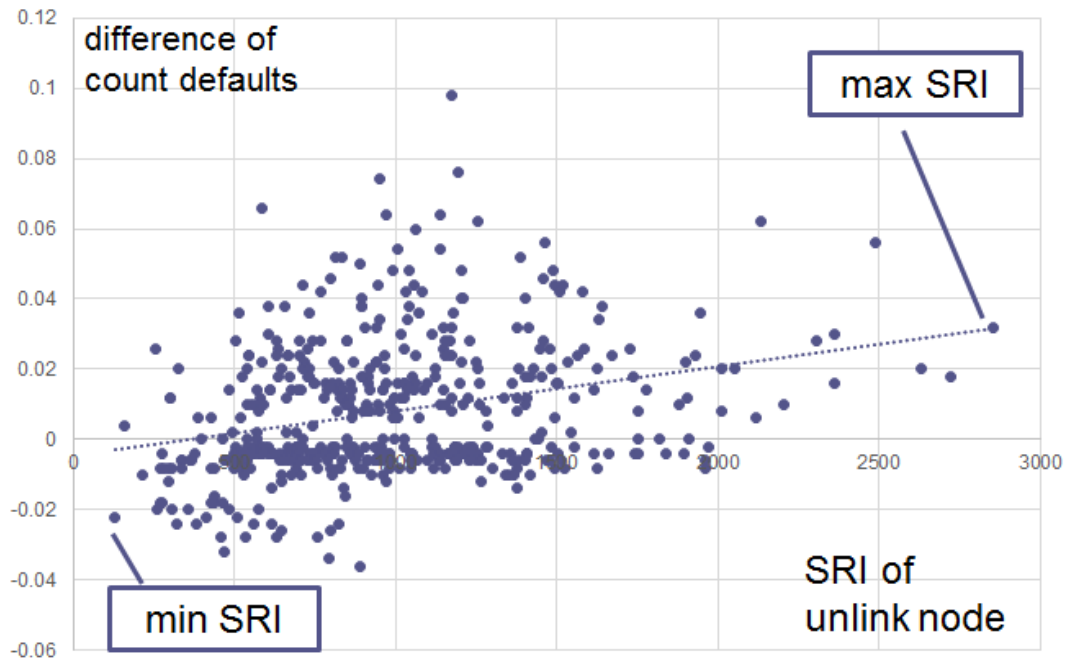


図 4.4 500 ノードの金融機関について, 縦軸を破綻の連鎖数, 横軸を SRI とした散布図.

図 4.5 の最大の SRI のノードのリンクを削除したケースでは, 12 個のノードで 1 金融機関の破綻の連鎖の増加が発生し, 2 個のノードで減少が発生した. 同様に, 最小の SRI のノードのリンクを削除したケースでは, 11 個のノードで 1 金融機関の破綻の連鎖が減少し, 増加した破綻の連鎖は発生しなかった. また, 同じ検証について, 10 個の別のネットワークで実施したときの結果を表 4.10 に示す. その結果はすべての検証で相関がみられ, 強く統計的に有意であった.

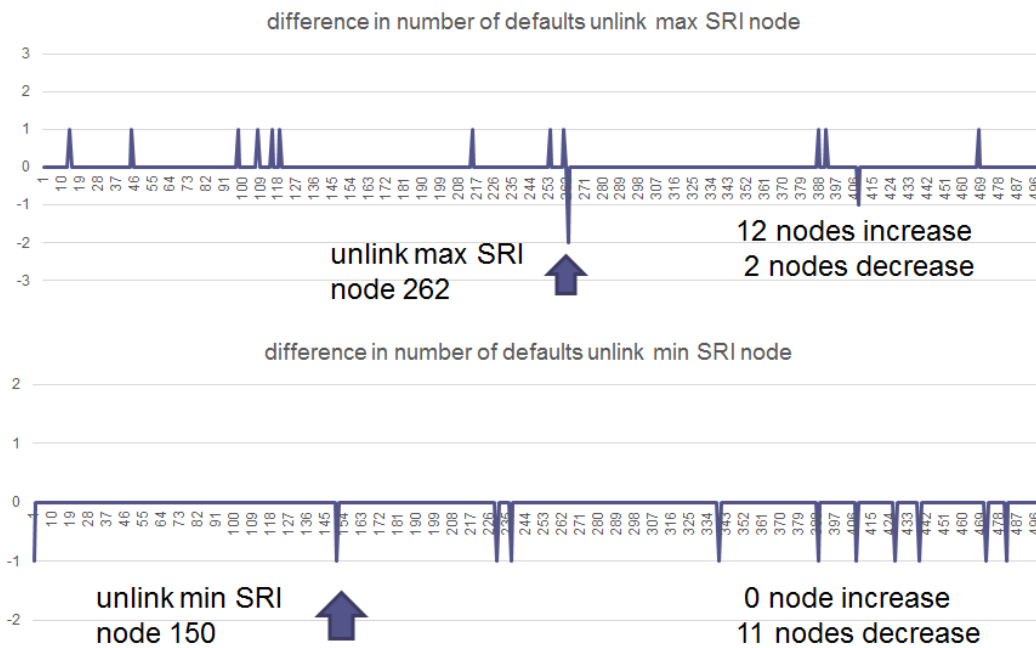


図 4.5 最大及び最小の SRI のノードを削除した場合と削除しない場合の差を比較した破綻連鎖数のグラフ。

表 4.10 破綻連鎖数と SRI の相関係数と検定結果

No.	相関係数	t value	p value
1	0.285	6.627	8.925E-11
2	0.286	6.667	6.968E-11
3	0.319	7.499	2.962E-13
4	0.356	8.496	2.220E-16
5	0.269	6.233	9.784E-10
6	0.229	5.241	2.368E-07
7	0.306	7.174	2.662E-12
8	0.319	7.512	2.718E-13
9	0.291	6.776	3.497E-11
10	0.330	7.803	3.575E-14
平均値	0.299	7.003	2.380E-08

SRI の (4.1) 式は、第 1 項に媒介中心性の値、第 2 項に資金援助を行う金融機関を表すすべてのリンクを削除するノードの入出の次数差の考慮を加えた値で表すが、第 1 項に媒介中心性の値を採用しているのは、前述の 10 パターンのネットワークによる Random Forest 法での変数重要度の平均値のグラフ 図 3.10 , および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 図 3.11 にあるように、媒介中心性が SRI の説明変

数として、もっとも当てはまりが良かったためである。

媒介中心性については、3.4.2 で述べたようにネットワーク指標として有効であるが、媒介中心性だけでは、破綻の連鎖を表すことに限界があるため、4.1 式の右辺第 2 項を加えた。これは、ノードのリンクを切ったときに破綻の連鎖が増加するにもかかわらず、当該ノードの媒介中心性の値が小さいパターンを補正することを目的としている。次数の入ってくる量と出ていく量の差異が破綻の連鎖に関連することから、入ってくるリンクの流れから出ていくリンクの流れを差し引き、全体の次数やノード数との比率を考慮した値を加えた。ただし、次数の少ないノードについては、その性質から、媒介中心性が少ない値になる傾向があるため、平均よりも入出の次数がともに大きいもののみ考慮することにし、条件に加えた。その根拠として、前述の CART 樹木 図 3.12 により検証し、破綻連鎖数の増加の多いケースの分類では、入ってくる次数と出ていく次数が分類に影響を与えることがわかったため、指標に加えた。

4.4.2 システミックリスク指標の評価

次に、媒介中心性と SRI の効果を比較するため、10 回検証したネットワークの 1 つについて、それぞれの値の昇順上位 10 ノード、下位 10 ノードのリンクを削除した場合の破綻の連鎖数の増減を比較した。表 4.11 に昇順上位 10 ノード、表 4.12 に下位 10 ノードの結果を示す。

表 4.11 BC と SRI を昇順に並べたときの破綻連鎖数の増減の推移

No.	BC	differences	SRI	differences
1	0	0.002	0	0.002
2	110.4802	-0.006	110.4802	-0.006
3	179.5253	-0.008	179.5253	-0.008
4	191.2865	0.001	191.2865	0.01
5	196.8176	0	196.8176	0
6	200.5888	-0.002	200.5888	-0.002
7	234.8976	-0.012	234.8976	-0.012
8	239.4583	0	239.4583	0
9	243.8241	-0.014	243.8241	-0.014
10	246.0996	-0.016	246.0996	-0.016

表 4.12 BC と SRI を降順に並べたときの破綻連鎖数の増減の推移

No.	BC	differences	SRI	differences
1	2783.172	0.004	2661.996	0.054
2	2758.77	0.054	2631.656	0.004
3	2554.198	0.054	2625.626	0.054
4	2540.356	0.014	2438.516	-0.01
5	2471.129	0.002	2309.839	0.002
6	2458.212	-0.002	2299.403	0.016
7	2455.867	0.02	2290.356	0.014
8	2341.742	-0.01	2230.06	0.02
9	2261.595	-0.004	2200.889	0.102
10	2209.038	-0.008	2194.838	0.048

上記結果のように、表 4.11 の昇順上位 10 ノードでは、媒介中心性と SRI の差異がなかったが、表 4.12 の昇順下位 10 ノードでは、破綻の連鎖が増えることが予想される資金援助先の金融機関に、実際には破綻の連鎖が減る金融機関が表れるノードが、媒介中心性では 4 ノードに対して、SRI は 1 ノードと削減した。

ここで、順位についての有効性を検証するために、spearman と kendall の順位相関について検証する。さらに、媒介中心性の大きい値についての SRI の効果を検証するために、媒介中心性の昇順にソートし、図 4.6 のように媒介中心性の小さい前半と大きい後半のそれぞれ 250 ノードに分け、それらの相関係数、順位相関について検証した。その結果を表 4.13 に示す。

表 4.13 spearman と kendall の順位相関結果

	手法	全体	前半	後半
BC	spearman	0.265	0.168	0.111
	kendall	0.183	0.118	0.075
	pearson	0.272	0.196	0.113
SRI	spearman	0.273	0.170	0.142
	kendall	0.189	0.119	0.096
	pearson	0.286	0.197	0.148
改善率	spearman	1.030	1.013	1.280
	kendall	1.031	1.012	1.283
	pearson	1.054	1.005	1.315

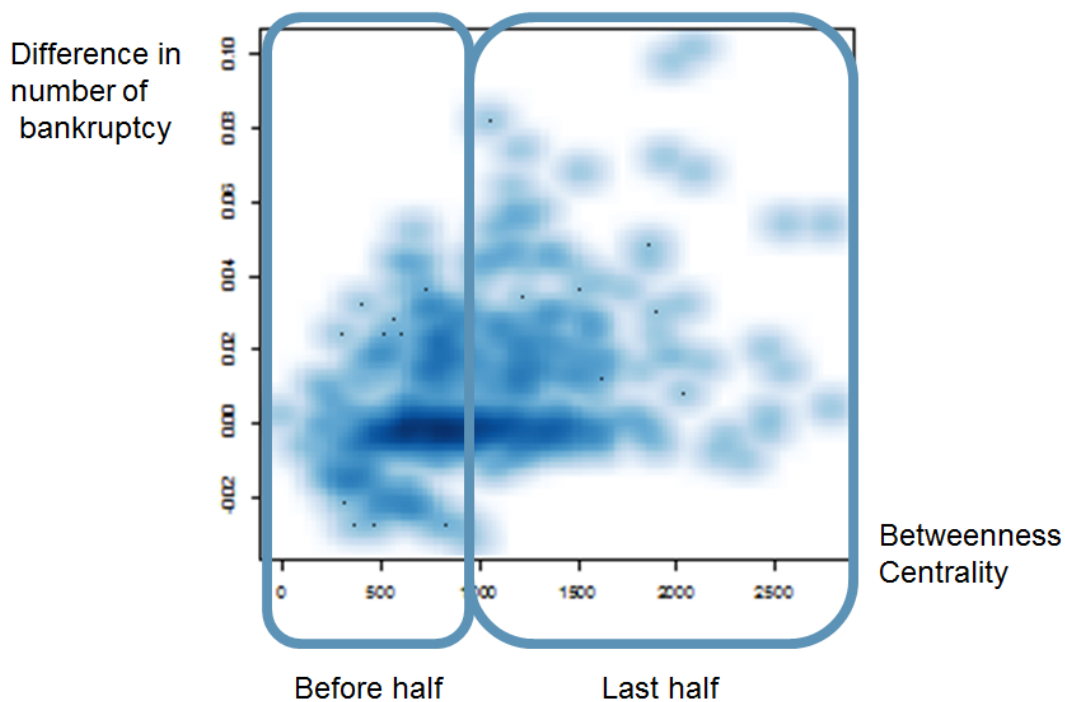


図 4.6 媒介中心性による前半と後半に分類したときの散布図. 前半, 後半とも 250 ノード存在する.

表 4.13 の結果のように, 媒介中心性のレンジが半分になっているため値は低減しており, 全体では 3% から 5% の改善であるが, 後半の改善率は 28% から 31% 改善しており, 課題としていた数値の大きい媒介中心性の説明力について, 媒介中心性に加えて, 入出次数とノード数の補正を加えることで, 破綻可能性の説明力を改善できた.

4.5 まとめ

ランダムネットワーク (Erdos-Renyi モデル) によるシステミックリスクの評価のまとめを述べる.

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 (graph centrality), 入次数 (in.degree), 外次数 (out.degree), ページランク (PR) の指標を加え, 検証を行った. 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, 個別のネットワーク指標によらず, 多様なデー

タを教師データとして予測を行うことで精度が上がるのではないかと仮説を立て、機械学習（Xgboost 法）を行う方策を提案し、媒介中心性だけを用いた場合よりも、高い精度で破綻の連鎖を説明することができた。Xgboost 法は、教師データを用いて学習を行い、その学習結果を踏まえて逐次に重みの調整を繰り返すことで複数の学習結果を求め、その結果を組み合わせることで精度を向上させるものである。Xgboost 法では RandomForest 法と同様に、樹木モデルを使うことで、回帰と分類どちらにも対応可能であり、外れ値や欠損値に強いという性質を持っているものであるが、本研究で採用した手法を用いることで、高い精度で破綻の連鎖を説明することができた。また、ネットワーク指標を変数ベクトルとした機械学習（Xgboost）によって、破綻の連鎖数を一定程度予測することが可能であることを示した。この機械学習の検証結果によって、銀行間の資金取引ネットワーク構造が破綻の連鎖に影響を与えていることを明らかにし、システミックリスクの発生メカニズムの解明に貢献できた。

また、Erdos-Renyi モデルの評価の方策として、最大破綻連鎖数を検討した。Barabasi-Albert モデルに対して、Erdos-Renyi モデルは予測が難しいが、いままで平均破綻連鎖数を評価してきたのに対して、ここでは最大値の破綻連鎖数を扱った。最大破綻連鎖数を機械学習による予測で検証を行ったが、ネットワーク特性にバラツキがあることが判明し精度の改善が難しかったが、訓練データを教師データを加えることでネットワーク間のバラツキを補完することができ、性能が向上した。

媒介中心性で破綻の連鎖を説明するにあたり、値の大きい領域で精度が落ちるという弱点があった。そこで、次数の内向きのもので外向きのものとの差異が説明力を上げることができるといふ仮説のもと、媒介中心性を拡張し、新しい SRI (Systemic Risk Index) の指標を提案し、精度の向上を実証した。SRI を使うことでネットワーク指標を拡張して破綻の連鎖リスクを表すことができるため、資金取引ネットワーク構造だけでリスク指標が設定可能になる。検証結果では、媒介中心性が不得手としていた値が大きい領域の精度を 30% 程度向上することができた。

前章と本章では、システミックリスクのベーシックモデルをベースにエージェントベースモデルに拡張し、スケールフリー性の検証として Barabasi-Albert モデル、ランダム性の検証として Erdos-Renyi モデルを採用して検証を行い、破綻の連鎖の予測精度を向上させる手法を検証し、機械学習の検証結果によってシステミックリスクの発生メカニズムの解明に貢献できたが、保有外部資産の目減りによる自己資本の毀損や金融市場の機能不全に

よって流動性資産が枯渇することによるシステミックリスクを考慮するためには、内生的リスクを検討する必要がある。そこで、次章では内生的リスクを考慮した新しいモデルを提案し、先行研究の結果と比較する。このモデルでは、バランスシートにおいて預金支払準備率（Reserve Ratio）と自己資本比率（Capital Adequacy Ratio）を考慮し、金融規制の影響を受ける。さらに、次章のモデルでは、金融機関の合併または統合を行うことによって金融機関の破綻連鎖への影響がどのように変化するか検証を行い、最近の日本の中・小規模銀行に対する銀行再編の流れを考慮して、金融機関の合併・統合の影響を検証する。

第5章

資金取引ネットワークモデルに基づく金融機関の経営統合影響分析

5.1 はじめに

前章までは、システミックリスクのベーシックモデルをエージェントベースモデルに拡張してモデル化しており、バランスシートをすべての金融機関で同一とし、ネットワーク構成の差異によるシステミックリスクの影響をみることに焦点を当てていたが、本章では金融機関のモデル化において以下の点を考慮し、より現実的な金融機関のシミュレーションを可能にする。

- 金融機関の規模別にバランスシートを変更
- 金融規制の影響を考慮
- 内生的リスクの考慮
- 金融機関の合併・統合によるネットワークの変化

本章では、保有外部資産の目減りによる自己資本の毀損や金融市場の機能不全によって流動性資産が枯渇することによるシステミックリスクを考慮するため、内生的リスクを考慮したエージェントベースモデルを提案する。まず「金融機関の経営統合影響分析モデル」で、内生的リスクを考慮するためのバランスシートのモデル化について述べ、次に「経営統合影響分析モデルの検証」で先行研究の結果と比較する。このモデルでは、バランスシートにおいて預金支払準備率（Reserve Ratio）と自己資本比率（Capital Adequacy Ratio）を考慮し、金融規制の影響を受ける。さらに、「金融機関の統合影響分析」で、最近の日本

の中・小規模銀行に対する銀行再編の流れを考慮して、金融機関の合併・統合の影響を検証し、「金融機関の統合影響分析の評価」で検証結果を評価する。本研究のモデルでは金融機関の合併・統合により資金取引ネットワークが変化するだけでなく、合併・統合対象のバランスシートが変化する。さらに、金融機関の破綻によって資金取引ネットワークが動的に変化し、破綻のショックが時間的変化で損失吸収されるモデルになっており、損失によって本モデルの金融システムの状態を表すバランスシートの資産・負債の総計が減少する。

5.2 金融機関の経営統合影響分析モデル

5.2.1 バランスシートの構成

本研究では,Eisenberg-Noe [EN01] によるバランスシートモデルを拡張し, エージェントベースモデルに適用している. 採用したバランスシートとその中で表している勘定を図 5.1 に示す.

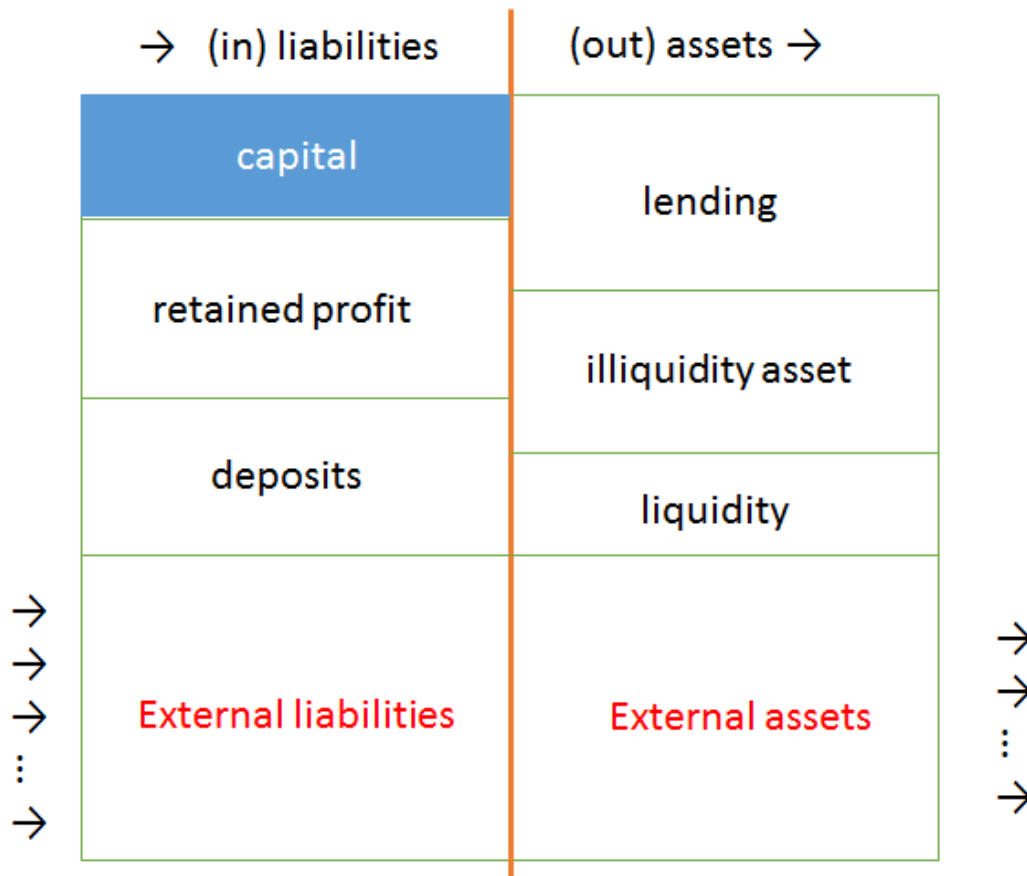


図 5.1 経営統合影響分析のバランスシート

図 5.1 にあるように, バランスシートは以下の勘定を含む.

- Liabilities:負債
 - capital:自己資本
 - deposits:預金
 - retained profit:内部留保利益
 - External liabilities:対外負債（銀行間借入, 対外債務）

- Assets:資産
 - lending : 融資（住宅ローン, 個人・企業ローン等）
 - illiquidity asset : 非流動性資産（社債等）
 - liquidity : 流動性資産（現金等）
 - External assets : 対外資産（銀行間融資, 対外債権）

本バランスシートの勘定は、以下の (5.1) 式のようにバランスする。

$$\begin{aligned} & capital + deposits + retainedprofit + Externalliabilities \\ & = lending + illiquidityasset + liquidity + Externalassets \end{aligned} \quad (5.1)$$

5.2.2 預金支払準備率 (RR) と自己資本比率 (CAR) の考慮

本研究では、バランスシートにおいて預金支払準備率 (Reserve Ratio) と自己資本比率 (Capital Adequacy Ratio) を考慮する。まず、預金支払準備率は、中央銀行において流動性資産を預金に対して保有する比率であり、発展途上国では高い比率が求められる。その比率を表す式を、5.2 式に表す。

$$ReserveRatio = \frac{liquidity}{deposits} \quad (5.2)$$

次に、自己資本比率は金融機関のシステミックなリスクに対する影響度に応じて設定される比率であるが、その比率を表す式を、5.3 に示す。

$$CapitalAdequacyRatio = \frac{capital + retainedprofit}{RiskWeightedAssets} \quad (5.3)$$

リスク・ウェイト・アセットは、以下の (表 5.1) から算出する。

表 5.1 リスク・ウェイト・アセットの設定

勘定	ratio
<i>liquidity</i> (流動性資産)	0%
<i>lending : Mortgage</i> (融資 : 住宅ローン)	50%
<i>lending : Loans</i> (融資 : 個人・企業ローン)	100%
<i>Externalassets</i> (対外資産)	20%

5.2.3 エージェントベースモデルへの適合

本研究では、エージェントベースによるモデル化を行った。モデルは、時系列に、月毎にバランスシートを更新する。毎月、External assets の 1/10 が満期を迎え、自己資本比率 (CAR) の規定値 (本研究では 10%) を維持できていれば再融資、できなければ融資を行わず自己資本 (capital) および内部留保利益 (retained profit) を減少させ自己資本比率を維

持しようとするが、このとき自己資本 (capital) もしくは内部留保利益 (retained profit) が減少し、自己資本がマイナスになった場合はデフォルトとする。また、対外負債 (External liabilities) と、対外資産 (External assets) は、毎月同額を借入または融資するとし、変動しないこととする。そのときの、資産の損失吸収プロセスを 図 5.2 に示す。この資産が吸収される連続プロセスの中で金融機関の自己資本比率が減少し破綻リスクを増長する内生的リスクが発生する。

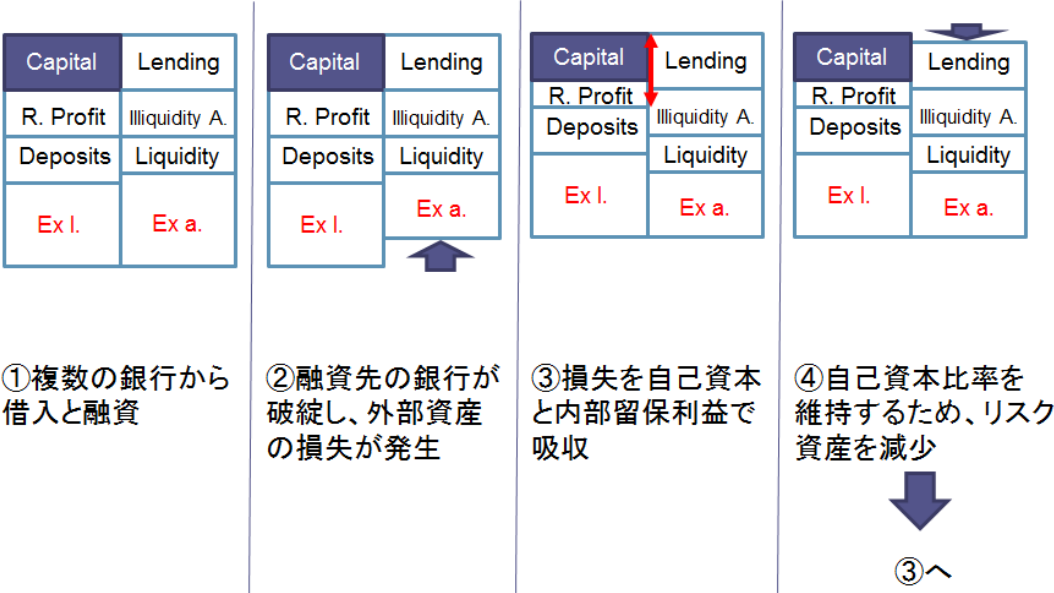


図 5.2 内生的リスクを発生させる資産の損失吸収プロセス。損失が発生した場合、自己資本の範囲で資産で吸収されるが、総資産額及び総負債額は減少する。

ここで、ある月にひとつの金融機関において住宅ローン等の融資が回収できなくなり、金融機関の破綻が発生したとする。このとき、この破綻銀行に融資している銀行の対外資産 (External assets) が銀行間ネットワークの接続先に応じて消滅する。図 5.3 の例で B 銀行が破綻した場合あれば、銀行間ネットワークの接続数が 3 行であるので、A 銀行の対外資産 (External assets) の 1/3 が損失する。この損失を自己資本 (capital) および内部留保利益 (retained profit) で吸収し、自己資本比率 (CAR) が維持できれば存続するが、マイナスになった場合はデフォルトする。ここで、存続した場合でも、次月以降自己資本比率の規定値を満たすことが必要になる。

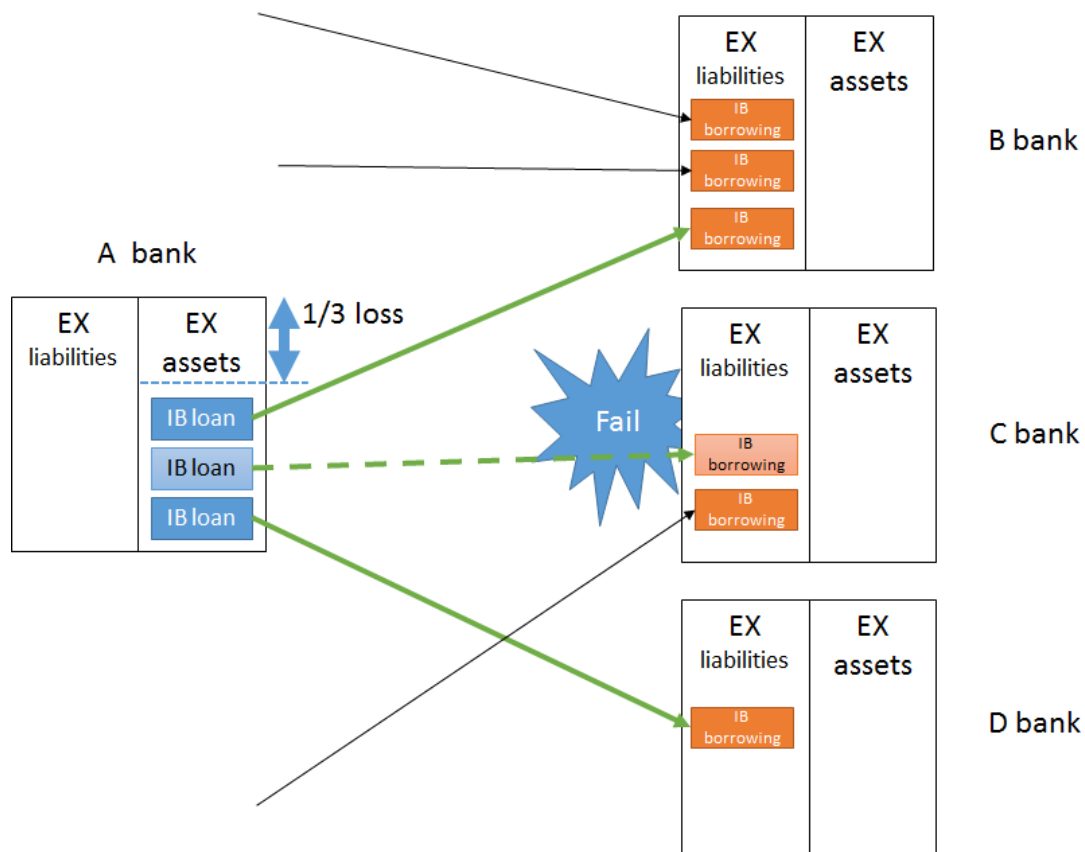


図 5.3 銀行間融資と対外債務の損失プロセス.B 銀行が破綻した場合,A 銀行の対外資産 (External assets) は 1/3 損失する.

5.3 経営統合影響分析モデルの検証

本章では, 本研究で構築したモデルを関連研究の結果で検証を行う.

5.3.1 関連研究の作成モデルと本研究のモデルとの比較

Chen, Liu, Yao [CLY16] のモデルでは, ドイツの銀行の 2011 EBA stress report を元に検証を行っているが, 銀行間信用と共通資産保有に起因する破綻の連鎖について数理モデルを作成し, シミュレーションを行っている. [CLY16] は銀行間の貸借関係を同一とし, バランスシートの値のみを変化させたモデルであるが, 本研究ではネットワーク構成から金融機関ノード間のリンクによって貸借関係を表し, その貸借関係の多寡によって金融機関の規模をモデル化している. また, 破綻の影響で発生する銀行間貸借の損失も, ネットワーク構造を考慮して金融機関ノード間のリンク数の影響を受けるため, E/A の影響を受ける.

この研究のバランスシートの勘定としては、総資産（Total Asset）、自己資本（Capital）、ドイツ内の銀行間エクスポージャでのデフォルト時貸出残高（Domestic Interbank EAD）を用いている。本研究では、それ以外の勘定について、預金支払準備率と自己資本比率を考慮して、以下の表 5.2、表 5.3、表 5.4 のように作成した。なお、斜字体はドイツの銀行の 2011 EBA stress report の値を表し、表 5.2 の E/A は EAD/Assets でデフォルト時貸出残高が資産に占める比率、CAR は Capital Adequacy Ratio、RR は Reserve Ratio を表す。

表 5.2 ドイツの 2011 EBA stress report をベースにしたバランスシートデータ (1:比率).

銀行コード	銀行名	E/A	CAR	RR
DE017	DEUTSCHEBANKAG	2.47%	7.97%	15.90%
DE018	COMMERZBANKAG	6.47%	17.33%	15.61%
DE019	LANDESBANKB – W	24.36%	13.14%	12.75%
DE020	DZBANKAGDT.Z – G	30.94%	11.28%	11.67%
DE021	BAYERISCHELANDESBANK	21.03%	18.18%	13.40%
DE022	NORDDEUTSCHELANDESBANK – GZ	24.03%	8.69%	12.68%
DE023	HYPORALESTATEHOLDINGAG	2.42%	8.44%	15.92%
DE024	WESTLBAGDUSSELDORF	12.53%	11.01%	14.50%
DE025	HSHNORDBANKAGHAMBURG	3.08%	14.69%	16.03%
DE027	LANDESBANKBERLINAG	20.70%	19.28%	13.49%
DE028	DEKABANKDEUTSCHEGIROZENTRALE	23.74%	12.89%	12.84%

表 5.3 ドイツの 2011 EBA stress report をベースにしたバランスシートデータ (2:負債).

銀行コード	自己資本	預金	内部留保利益	対外負債	負債合計
DE017	30361	1870558.8	0	4710.2	1905630
DE018	26728	739485.9	0	4987.1	771201
DE019	9838	355454.9	0	9120.1	374413
DE020	7299	306269.1	0	10009.9	323578
DE021	11501	298199.5	0	6653.5	316354
DE022	3974	219119.9	0	5492.1	228586
DE023	5539	321784.4	0	795.6	328119
DE024	4218	184904.3	0	2400.7	191523
DE025	4434	146031.5	0	464.5	150930
DE027	5162	125928.3	0	2770.7	133861
DE028	3359	123851.3	0	3093.7	130304

表 5.4 ドイツの 2011 EBA stress report をベースにしたバランスシートデータ (3:資産).

銀行コード	融資	流動性資産	非流動性資産	対外資産	資産合計
DE017	371705.6	297364.5	1189457.9	47102	1905630
DE018	144266.0	115412.8	461651.2	49871	771201
DE019	56642.4	45313.9	181255.7	91201	374413
DE020	44695.8	35756.6	143026.6	100099	323578
DE021	49963.8	39971.0	159884.2	66535	316354
DE022	34733.0	27786.4	111145.6	54921	228586
DE023	64032.6	51226.1	204904.3	7956	328119
DE024	33503.2	26802.6	107210.2	24007	191523
DE025	29257.0	23405.6	93622.4	4645	150930
DE027	21230.8	16984.6	67938.6	27707	133861
DE028	19873.4	15898.7	63594.9	30937	130304

また, 銀行間ネットワークは銀行数 11 ノードの完全ネットワーク図 5.4 を採用している.




図 5.4 完全ネットワークの概念図

5.3.2 関連研究とのシミュレーション結果比較

関連研究である Chen, Liu, Yao [CLY16] のモデルと本研究の結果の比較は以下の表 5.5 の通りである。

表 5.5 先行研究と本研究の検証結果の比較.

デフォルト順	先行研究での破綻銀行	先行研究での破綻数	本研究での破綻銀行	本研究での破綻数
0	DE017	1	DE017	1
1	DE022, DE023	3	DE020, DE022	3
2	DE020, DE024	5	DE019, DE021	5
3	DE019, DE028	7	DE024, DE027, DE028	8

先行研究と本研究の結果では、金融機関の破綻の順序、破綻の数に差異が見られた。これは、先行研究が自己資本比率（CAR）を重視したモデルとなっており、実際に先行研究の検証結果では自己資本比率（CAR）が大きい銀行（DE025 の 14.69% 以上）では破綻が発生していない。一方、本研究は自己資本比率（CAR）に加えて、E/A(デフォルト時貸出残高が資産に占める比率) を考慮した拡張モデルになっている。そのため、表 5.5 にあるように、本研究の結果では DE019 が先行研究より早く破綻し、また、本研究では先行研究では破綻していない DE027 が破綻しているが、これらはどちらも E/A が 20% 以上と高いことが要因であることが考えられる。一方、自己資本比率（CAR）をみると、どちらも自己資本比率が少ない銀行が破綻している傾向が見受けられるが、DE023 については、自己資本比率が 8.44% と 10% を下回っているにもかかわらず、本研究では破綻していない。これは、E/A が 2.42% と極端に少ないことが要因と考えられる。

また、図 5.3 のように本研究では銀行間ネットワークの接続数に応じて対外資産（External assets）の損失が発生するモデルになっているが、破綻発生毎に一定量の損失が発生するモデルとした場合、先行研究と同じ結果になることを確認している。

5.3.3 金融機関の規模別のバランスシートモデル

Chen, Liu, Yao [CLY16] のモデルのバランスシートの勘定としては、総資産（Total Asset）、自己資本（Capital）、ドイツ内の銀行間エクスポージャ（Domestic Interbank

EAD) を用いている。本研究では、規模別にそれらの数値を採用し、Chen, Liu, Yao [CLY16] のモデルで規定していないそれ以外の勘定について、預金支払準備率と自己資本比率を考慮して作成した。また、バランスシートのタイプとしては、メガバンク、中規模銀行、小規模銀行の3タイプを考慮し、ネットワークモデルにおける各エージェントの次数 (degree) の数によって、各ノードがタイプ分けされるモデルとした。その時のバランスシートを表 5.6 に示す。ここで、次数はメガバンクは30以上、中規模銀行は6から29、小規模銀行は5以下としており、規模による各勘定の差異はドイツの銀行の2011 EBA stress report の各勘定を、銀行の規模別に分析して定義した。

表 5.6 メガバンク、中規模銀行、小規模銀行のバランスシートモデル。

銀行タイプ	自己資本	預金	内部留保利益	対外負債	合計負債	融資	流動性資産	非流動性資産	対外資産	合計資産	E/A	CAR	RR
メガバンク	60000	1840000	0	100000	2000000	380000	304000	1216000	100000	2000000	5.0%	15.0%	16.5%
中規模銀行	10000	215000	0	75000	300000	45000	36000	144000	75000	300000	25.0%	16.7%	16.7%
小規模銀行	3000	77000	0	20000	100000	16000	12800	51200	20000	100000	20.00%	15.00%	16.6%

また、本モデルでは単純化するため、各銀行ノードのバランスシートを銀行のタイプごとに固定し、タイプ内では同一としている。また、対外負債 (External liabilities) と対外資産 (External assets) は同額である。

5.4 金融機関の統合影響分析の検証

本章では、本研究で実施したエージェントベースモデルによる検証結果を説明する。

5.4.1 構築モデルにおける破綻連鎖数の検証

本研究では、1回に張る辺の数 (m) を3とした100ノードのスケールフリーネットワークを10個作成し、金融機関の資金取引ネットワークモデルとした。そのネットワークにおいて100個のノードは金融機関を表すが、そのノードのうち一つの金融機関で破綻が発生した場合を想定し、その時の金融機関の破綻の連鎖を測定した。ネットワークにおけるノード間の有向リンクは金融機関の資金取引を表す。また、そのときの破綻連鎖数の上位3位についての結果を表 5.7 に示す。ネットワーク毎の平均破綻数及び最大破綻連鎖数は比較的差異が大きく、ネットワーク特性に依存しやすい結果が観測できた。このなかで、破綻連鎖数上位3位に入ったノードはすべて、小規模銀行 (次数5以下) であった。

表 5.7 スケールフリーネットワークによる破綻連鎖数の検証結果.() 内はノード番号を指す.

No.	Average number of chain reaction of failures	Top three number of chain reaction of failures
1	3.940	17(93), 15(70, 73)
2	6.120	17(98), 13(54, 64, 73, 78, 83)
3	7.480	17(75,87), 15(64, 82, 86)
4	4.350	15(80), 12(74, 76)
5	7.110	21(93), 19(94), 17(92)
6	4.980	16(98), 14(97), 13(69)
7	3.400	9(76), 8(41, 92)
8	3.120	9(78), 8(79, 85, 91, 92)
9	7.740	18(75, 78, 95)
10	3.260	9(42, 73) 8(53, 77, 99)
Average	5.150	

5.4.2 金融機関の合併・統合による破綻連鎖数の変化の検証（1）

本研究の主課題である金融機関の合併・統合による破綻連鎖数の変化を検証する. 合併・統合にあたっては, 最も破綻連鎖数の多い金融機関ノードをその次に破綻連鎖数の多い金融機関ノードに統合し, 金融機関のリンクは維持するモデルとした. ここでバランスシートの各勘定は, 図 5.5 のようにそれぞれ合算することとし, 資産, 負債の部分とも合計した値にしている. 合併・統合については, 2 行だけではなく, 3 行による合併・統合も検証を行った. このような前提で検証した結果を表 5.8 と表 5.9 に示す. この中での破綻連鎖数上位 3 位に入ったノードもすべて小規模銀行 (次数 5 以下) であった.




図 5.5 金融機関 A が金融機関 B を合併・統合する概念図. 下段はバランスシートを表し, L は負債, A は資産を表す.

表 5.8 金融機関 2 行統合による平均破綻連鎖数の変化の検証結果. 括弧内の数字はノード番号を表す.

No.	平均破綻連鎖数	破綻連鎖数の Top3	合併・統合ノード (from -> to)	比率
1	3.48	19(70), 15(73), 13(44)	93→70	97.66%
2	6.090	21(54), 13(64, 73, 78, 83)	98→54	99.51%
3	7.444	23(87), 15(64, 82, 86)	75→87	99.52%
4	4.323	20(74), 12(76), 11(55)	80→74	99.38%
5	7.000	22(94), 17(92), 16(64)	93→94	98.45%
6	4.969	24(97), 13(69), 12(73)	98→97	99.78%
7	3.404	14(41), 8(92), 7(60, 64, 70, 77, 79, 87)	76→41	100.12%
8	3.131	15(79), 8(85, 91, 92)	78→79	100.35%
9	7.676	22(78), 18(95), 17(55, 93, 97)	75→78	99.17%
10	3.252	14(73), 8(53, 77, 99)	42→73	99.75%
Average	5.114			99.30%

表 5.9 金融機関 3 行統合による平均破綻連鎖数の変化の検証結果. 括弧内の数字はノード番号を表す.

No.	平均破綻連鎖数	破綻連鎖数の Top3	合併・統合ノード (from -> to)	比率
1	3.734	19(73), 13(44), 12(38)	70→73	97.04%
2	6.204	25(64, 90), 13(73, 78, 83)	54→64	101.87%
3	7.408	27(64), 15(82, 86)	87→64	99.52%
4	4.234	19(76), 11(55), 10(62, 65, 81, 98)	74→76	97.94%
5	6.887	21(92), 16(64), 15(69, 79)	94→92	98.39%
6	4.928	28(69), 12(73), 11(89)	97→69	99.17%
7	3.397	18(92), 7(60, 64, 70, 77, 79, 87)	41→92	99.79%
8	3.132	20(85), 8(91, 92)	79→85	100.03%
9	7.632	28(95), 17(55, 93, 97)	78→95	99.43%
10	3.224	16(53), 8(77, 99)	73→53	99.14%
Average	5.078			99.30%

平均破綻連鎖数の平均値を比較すると、金融機関を合併・統合前 5.150 に対して、2 行合併・統合後が 5.114、3 行合併・統合後が 5.078 と合併・統合した場合の方が破綻連鎖数が少なくなっているが、これは金融機関を表すノード数が少なくなっていることを考慮すると合併・統合効果は十分表れているとはいえない。また、表 5.10 のように合併・統合後の破綻連鎖数合算値を見ると、どのネットワークでも合併・統合前の破綻連鎖数を足し合わ

せた値よりは少なくなっているが、全てのケースで合併・統合したノードが最上位に来ている。これは、統合によりバランスシートの資産、負債の数値が合算されたにもかかわらず、財務的には効果が表れていないことを示しており、資産および負債を合算しているため、自己資本比率および外部資産への比率が改善しないことが原因であると考えられる。

表 5.10 金融機関の合併・統合による破綻連鎖数の Top3 の検証結果。括弧内は破綻連鎖数の合算値。

No.	合併・統合なし	2行合併・統合	3行合併・統合
1	17, 15, 15 [47]	19, 15 [34]	[19]
2	17, 13, 13 [43]	21, 13 [34]	[25]
3	17, 17, 15 [49]	23, 15 [38]	[27]
4	15, 12, 12 [39]	20, 12 [32]	[19]
5	21, 19, 17 [57]	22, 17 [39]	[21]
6	16, 14, 13 [43]	24, 13 [37]	[28]
7	9, 8, 8 [25]	14, 8 [22]	[18]
8	9, 8, 8 [25]	15, 8 [23]	[20]
9	18, 18, 18 [54]	22, 18 [40]	[28]
10	9, 9, 8 [26]	14, 8 [22]	[16]
average	40.800	32.100	22.100

次に、破綻連鎖が起こるノードの特性を分析すると、金融機関ノードの次数が関係していることが考えられる。2番目のネットワークでの金融機関ノードの次数と、その金融機関ノードが破綻したときの破綻連鎖数の散布図を図 5.6 に示す。




図 5.6 金融機関ノードの次数と破綻連鎖数の散布図. 上が統合・合併前, 下が統合合併後. 縦軸が金融機関ノードの次数, 横軸が平均破綻連鎖数.

図 5.6 から, 次数が大きいノードについては破綻の連鎖が起こらず, 破綻の連鎖が大きくなっているノードは次数の小さいノードであることが分かる. これは破綻するノードに接続するノードの次数が大きければ, 破綻のショックを複数の金融機関ノードの自己資本で分散して吸収できるが, 接続するノードの次数が小さい場合は, 自己資本で吸収しなければならないショックが大きくなり吸収しきれない状態になることを示唆している. 合併・統合前の破綻連鎖数の合算した値よりも, 合併・統合後の破綻連鎖数が少なくなっているのは, 分散して破綻のショックを吸収できることが理由であると考えられる.

また, 図 5.6 の下段の右下で四角で囲った部分では, 破綻連鎖数 25 のノードが 2 つ存在している. これは, 合併・統合を行わなかったノード (ノード番号 90 番) の破綻連鎖数が急激に増加したものであるが, 具体的には 2 行合併・統合時は, 破綻連鎖数が 11 であったものが, 3 行合併・統合時には 25 になった. これは, この 90 番のノードが合併・統合ノードに隣接していたためと考えられるが, 合併・統合は, このようなシステミックリスクを引き起こす可能性があるため, 慎重に行う必要がある. 2 番目のネットワークの 3 行合併・統合時の平均破綻連鎖数は, この急激な破綻連鎖数の増加により, 2 行合併・統合時より大きくなっている (6.090 → 6.204) .

ここで, この急激な破綻連鎖数の増加要因を調査するため, 3 行合併・統合ノードのり

リンク接続先ノード、およびそのノードの次数を表 5.11 にまとめた。この結果より、合併・統合金融機関ノードに向けたリンクが張られる場合において、発生しているという仮説を立てた。このことを検証するため、2 番目以外のネットワークにおいて、合併・統合金融機関ノードに向けたリンクを追加したところ、破綻連鎖数の増加が見られた。さらに比較のため、合併・統合ノードから出るリンクの追加も行ったが、この場合は破綻連鎖数の増加は表れなかった。合併・統合金融機関ノードに向けたリンクが張られているということは、合併・統合金融機関ノードが外部資産を保持していることになるため、その資産が失われることによって合併・統合金融機関ノードが連鎖破綻し、破綻の影響が大きくなったことが分かった。

表 5.11 金融機関の合併・統合を考慮した金融機関ノードの接続先の検証結果。括弧内の数字は次数を表す。No. はネットワークの識別番号を表す。from の領域が空白であれば、合併・統合ノードを表す。

No.	Merger or consolidation nodes	Nodes linked Merger or consolidation nodes (from → to)
1	73(9)	1(33), →5(32), →10(10), →10, →35(4), →38(5), →44(5), →44, →65(6)
2	64(10)	→1(58), →1, →4(13), →21(15), →21, →32(5), →34(6), →55(4), →78(4), 90(3)→64
3	64(9)	→0(45), →4(18), →12(8), →29(4), →30(10), →37(4), →43(6), →49(6), →78(4)
4	76(9)	→0(43), →3(32), →19(8), →26(4), →55(4), →64(4), →71(4), →76, →76
5	92(9)	→1(36), →3(20), →5(30), →63(5), →70(4), →82(6), →85(4), →92, →92
6	69(9)	→24(4), →33(6), →34(4), →39(5), →40(5), →43(4), →54(5), →63(5), →93(4)
7	92(9)	→3(39), →7(10), →10(7), →13(10), →22(11), →34(5), →36(5), →64(4), →69(4)
8	85(9)	→5(35), →8(7), →10(35), →20(5), →25(4), →31(10), →41(5), →67(4), →68(6)
9	95(9)	→1(27), →2(28), →8(12), →18(5), →22(10), →52(4), →70(5), →73(4), →76(4)
10	53(9)	→2(45), →12(24), →15(12), →17(11), →28(5), →31(6), →40(11), →48(4), →58(4)

5.4.3 金融機関の合併・統合による破綻連鎖数の変化の検証（2）

（1）の検証では、破綻の連鎖が大きいものから合併・統合させたが、実務的にはもっとも破綻の連鎖が大きくなる金融機関に対して、銀行間取引がある金融機関を合併・統合対

象とすることが考えられる。合併・統合先は、取引関係が少ないところよりも、既存の取引がある金融機関を選定することによって、業務の統合がスムーズに行われる、既存の業務形態を拡張する効果を期待できる等のメリットが考えられるためである。そこで、もっとも破綻の連鎖が大きかった金融機関を、10個のネットワークについてその銀行間取引の接続先と合併・統合させたときの破綻の連鎖の変化を表 5.12 に示す。もっとも破綻の連鎖が大きかった金融機関ノードは、前述のようにすべて小規模金融機関であり、その接続先はすべて3行であった。

表 5.12 銀行間取引の接続先と合併・統合したときの破綻連鎖数の検証結果。合併・統合ノードの括弧内の数字は前者が入次数、後者が出次数を表す。

No.	平均破綻連鎖数	合併・統合ノード	合併・統合先 1	合併・統合先 1 の破綻連鎖数	比率 1	合併・統合先 2	合併・統合先 2 の破綻連鎖数	比率 2	合併・統合先 3	合併・統合先 3 の破綻連鎖数	比率 3
1	3.94	93[3,0]	10[3,7]	4.83	1.23	44[3,2]	3.86	0.98	65[3,3]	4.22	1.07
2	6.12	98[3,0]	4([3,10]	12.27	2.00	55[3,1]	6.12	1.00	78[3,1]	6.04	0.99
3	7.48	75[3,0]	29[3,1]	7.42	0.99	37[3,1]	7.44	1.00	43[3,3]	7.68	1.03
4	4.35	80[3,0]	3[3,29]	4.38	1.01	71[3,1]	4.37	1.01	76[3,1]	4.26	0.98
5	7.11	93[3,0]	5[3,27]	7.14	1.00	82[3,3]	7.27	1.02	92[3,2]	7.03	0.99
6	4.98	98[3,0]	34[3,1]	4.95	0.99	54[3,2]	5.01	1.01	93[3,1]	5.01	1.01
7	3.40	76[3,0]	3[3,36]	3.42	1.01	7[3,7]	4.04	1.19	64[3,1]	3.35	0.99
8	3.12	78[3,0]	10[3,32]	3.15	1.01	67[3,1]	3.09	0.99	68[3,3]	3.18	1.02
9	7.74	75[3,0]	2[2,26]	7.18	0.93	22[3,7]	8.15	1.05	52[3,1]	7.66	0.99
10	3.26	42[3,0]	17[3,8]	3.69	1.13	28[3,2]	3.28	1.01	31[3,3]	3.40	1.04
平均値	5.15										

本検証結果では、合併・統合先の次数にバラつきがあり、小規模金融機関同士の合併・統合だけではなく、中規模金融機関やメガバンクとの合併・統合も発生した。そこで、その時の金融機関タイプ別の破綻の連鎖の変化を表 5.12 に示す。

表 5.13 銀行間取引の接続先と合併・統合したときの金融機関タイプ別の破綻連鎖数の検証結果。合併・統合後の破綻連鎖数を合併・統合後の値で除すことで合併前と合併後の破綻連鎖数の比率を表している。

銀行タイプ	small	medium	mega	Total
合併前後での破綻連鎖数の比率	0.99	1.18	0.99	1.05

表 5.13 のように、中規模金融機関の破綻の連鎖が増加し、小規模金融機関やメガバンクではほぼ破綻の連鎖が変わらなかった。中規模金融機関では、中でも次数が 10 以上のもの

については、破綻連鎖の増加が 1.32 倍にも増加した。中規模金融機関は、表 5.6 にあるように、E/A が小規模金融機関やメガバンクよりも 25% と高いため、合併・統合することで破綻の連鎖リスクが増加したことが考えられる。また、次数が 10 以上の金融機関で破綻連鎖の増加が大きかったのは、影響を及ぼす相手行が多いため、連鎖の範囲が広がったことが考えられる。このことから、合併・統合先として E/A の高い先は合併・統合先として選定すべきではないと言える。

5.5 金融機関の統合影響分析の評価

ここでは、資金取引ネットワークモデルに基づく金融機関の経営統合影響分析の評価を述べる。

5.5.1 資金取引ネットワークモデルに基づく金融機関の経営統合影響分析の考察

本章では、シンプルなバランスシートと預金準備率、自己資本率等の規制を考慮したエージェントベースモデルによるシステミックリスクの評価モデルを提案した。このモデルは、銀行間ネットワーク上の内生的なリスクの影響を考慮し、金融機関に対する規制の元での銀行間資金取引の動きをシミュレーション可能にする。さらに、このモデルを用いて、金融機関の合併または統合を行うことによって金融機関の破綻連鎖への影響がどのように変化するか検証を行い、最近の日本の中・小規模銀行に対する銀行再編の流れを考慮して、金融機関の合併・統合の影響を検証した。検証結果では、自己資本比率に加え E/A(デフォルト時貸出残高が資産に占める比率) が、合併・統合先を選定する指標として有効であることが分かった。

また、本研究では、次数の少ないノード（小規模銀行）において破綻の連鎖が多くなる傾向を示し、メガバンクを想定したノードでは破綻の連鎖が発生しなかった。しかし、この点は破綻の連鎖リスクだけを考慮した検証結果であるため、経済全体への影響を検証する目的で全金融機関のバランスシートの勘定を合算した数値も測定した。その結果を図 5.7 に示す。この結果は、小規模銀行 5 行破綻時のバランスシートの収縮よりも、メガバンク 1 行による収縮の方が 2 倍ほど大きいことを示している（小規模銀行 5 行で 927、メガバンク 1 行で 2009）。これは、メガバンク 1 行の破綻を吸収するための自己資本の減少が、金融機

関全体に拡散し、経済全体に影響を与えることを示している。本モデルのバランスシート設定では、メガバンクの破綻を自己資本で吸収できたが、破綻のショックが小規模銀行の自己資本を超過して吸収できないバランスシート設定であった場合、小規模銀行が連鎖破綻していわゆるドミノ倒しのような大規模連鎖破綻が発生することが予想される。

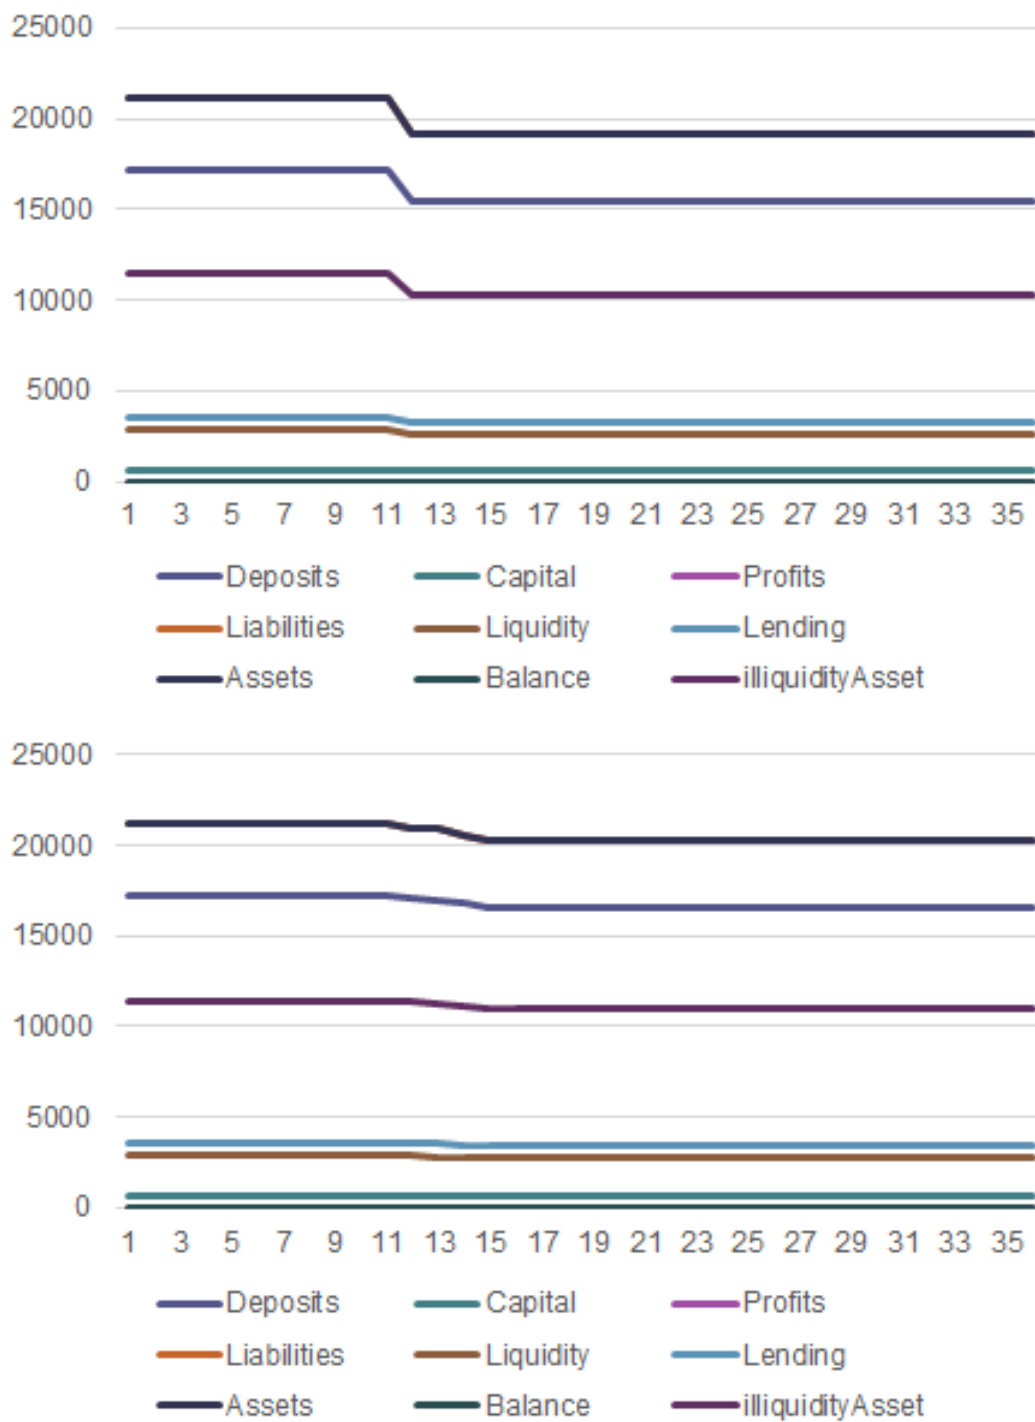


図 5.7 すべての金融機関のバランスシート合算値のグラフを示す. 上段は, メガバンクの破綻時のものを示し, 下段は小規模銀行の破綻時のものを示す. 縦軸は資金の合算値, 横軸は月数を示す. 本シミュレーションでは 12 月目に破綻が起きている.

5.6 まとめ

本章では、保有外部資産の目減りによる自己資本の毀損や金融市場の機能不全によって流動性資産が枯渇することによるシステミックリスクを考慮するため、内生的リスクを考慮したエージェントベースモデルを提案し、金融機関の合併・統合によるネットワークの変化が破綻の連鎖に与える影響を明らかにした。

まず金融機関の経営統合影響分析モデルで、内生的リスクを考慮するためのバランスシートのモデル化について述べ、次に経営統合影響分析モデルの検証で Chen, Liu, Yao [CLY16] のモデルの結果と比較し、 E/A (デフォルト時貸出残高が資産に占める比率)が高くなると破綻の連鎖リスク拡大に影響することを明らかにした。このモデルでは、バランスシートにおいて預金支払準備率 (Reserve Ratio) と自己資本比率 (Capital Adequacy Ratio) を考慮し、金融規制の影響を受けるが、自己資本比率が十分大きければ破綻が発生しないことも確認した。さらに、金融機関の統合影響分析で、最近の日本の中・小規模銀行に対する銀行再編の流れを考慮し、金融機関の合併・統合の影響について、(1) 最も破綻連鎖数の多い金融機関ノードをその次に破綻連鎖数の多い金融機関ノードに合併・統合するパターンと、(2) もっとも破綻の連鎖が大きくなる金融機関に対して、銀行間取引がある金融機関を合併・統合対象とするパターンを検証し、金融機関の統合影響分析の評価で金融機関の合併・統合による破綻の連鎖の影響を評価し、金融規制で求められる指標である自己資本比率に加えて、 E/A が合併・統合先を選定する指標として有効であることを発見した。

第6章

結論

6.1 本研究の結論

金融機関における資金取引の仕組みは複数の金融機関間の接続によるネットワークで実現されており、ひとつの金融機関の業務停止が連鎖的に他の金融機関の資金取引停止リスクにつながる。一般国民を含む預金者にとって、金融機関の資金取引停止は決済手段を失うことになるため、生活基盤への影響が大きい。政府は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整備しているが、金融危機が発生した場合には金融機関に対して公的資金を注入する可能性があり、国民負担になることもあることから社会的関心が高い。

そこで、本研究では金融機関の資金取引ネットワークにおいて、破綻の連鎖の仕組みを解明し、金融機関の救済において最小限のコストで破綻の連鎖リスクを低減するための方策を検証した。

本章では、第3章の「資金取引ネットワークを考慮したエージェントベースモデルによるシステミックリスクモデル」、第4章の「ランダムネットワーク (Erdos-Renyi モデル)」, 及び第5章の「資金取引ネットワークモデルに基づく金融機関の経営統合影響分析」の研究結果を総括し、本研究の結論と今後の展開を述べる。

6.1.1 資金取引ネットワークを考慮したエージェントベースモデルによるシステミックリスクモデルの結論

第3章の「資金取引ネットワークを考慮したエージェントベースモデルによるシステミックリスクモデル」では、金融機関の破綻連鎖モデルとして [MA10] のモデルを拡張し、

エージェントベースモデルを用いてネットワークの構成の変化が動的に銀行間取引に影響を与えるモデルを構築した。検証ではランダムネットワーク（Erdos-Renyi モデル）とスケールフリーネットワーク（Barabasi-Albert モデル）で構成した銀行間資金取引ネットワークモデルを使用し、ネットワークモデルの差異によって破綻の連鎖の仕組みがどのように影響を受けるかを検証した。その結果、破綻の連鎖を止める目的で実施する資本増強が、結果的に連鎖を増加させてしまう場合があるため、救済する金融機関の選定が重要であることを検証した。

これらの結果から、次の3点の貢献がある。

- 1). 金融機関を救済することによって、平均破綻連鎖数が増加する場合がある。
- 2). スケールフリーネットワーク（Barabasi-Albert モデル）では、破綻の連鎖リスクに資金援助を行う金融機関を表すノードの次数が影響する。
- 3). ランダムネットワーク（Erdos-Renyi モデル）において、資金援助を行う金融機関を表すノードのネットワーク指標の一つである媒介中心性で破綻の連鎖をある程度説明することができるが、精度が十分ではなく、とくに媒介中心性の値が大きい範囲において精度が下がる。

上記 1). については、ネットワーク構成の差異によって、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). および 3). については、Erdos-Renyi モデルと Barabasi-Albert モデルで、破綻の連鎖に影響するネットワーク指標を検証し、それぞれのネットワークモデルのネットワーク指標の説明力に差異があることを明らかにした。Barabasi-Albert モデルでは、金融機関を表すノードの次数で破綻の連鎖を精度よく説明することができたが、Erdos-Renyi モデルについては、ネットワーク指標のひとつである媒介中心性が破綻の連鎖の説明力が最も高かったが、Barabasi-Albert モデルに比べて説明力が十分ではなく、精度の向上を検討する必要があることを検証した。

さらに、他の研究に対する優位性には以下のとおりである。

- [GK10, NYA07, MA10, KKY⁺16a, KKY⁺16b] では、資金取引ネットワークにランダムネットワークもしくは完全ネットワークを使用しているが、本研究では日本の分析結果に基づきランダムネットワークに加え、スケールフリーネットワークで

の検証も行った。

- [CFS05, CLY16, KKY⁺16a, KKY⁺16b] は内生的リスクを考慮した研究であるが、金融機関数が少なく金融システム全体のモデル化になっていないが、本研究では日本の金融機関数を想定し、実データに即したネットワークを採用した。
- [CFS05, CLY16] は内生的リスクを数理モデルで表しているが、本研究ではエージェントベースモデルによりシンプルなエージェントの振舞いから創発的に起こる現象によってモデル化し、予測不可能な金融機関の破綻の連鎖をシミュレーションしているため、シミュレーション結果から影響を及ぼしたエージェントの振舞いを特定し、複雑な金融システムを解明した。

6.1.2 ランダムネットワーク (Erdos-Renyi モデル) によるシステムミックリスクの評価の結論

第4章の「ランダムネットワーク (Erdos-Renyi モデル) によるシステムミックリスクの評価」では、Barabasi-Albert モデルに比べて説明力が十分ではないランダムネットワーク (Erdos-Renyi モデル) で構成した銀行間資金取引ネットワークモデルにおいて、金融機関の破綻連鎖リスクを測る指標として、機械学習による平均破綻連鎖数の予測値を提案した。検証の中では、平均破綻連鎖数の予測を行うためには機械学習のひとつである Xgboost 法が有効であることを示した。また、リスクを測る指標として平均破綻連鎖数に加えて最大破綻連鎖数を提案し、複数の角度から分析を行った。さらに、ネットワーク特性の評価として有効な媒介中心性のような既存の指標だけではシステムミックリスクの評価には不十分であるため、媒介中心性を拡張した新しいシステムミックリスク指標を提案し、予測精度を向上させた。

これらの結果から、次の3点の貢献がある。

- 1). 破綻の連鎖リスクについて、もっとも説明力の高い媒介中心性だけでは十分な精度が得られないため、7つのネットワーク指標を加えて教師データとし、機械学習 (Xgboost) を行うことで精度が向上し、銀行間の資金取引ネットワーク構造が破綻の連鎖に影響を与えていることを明らかにした。
- 2). 平均破綻連鎖数に加え最大破綻連鎖数の特性が機械学習 (Xgboost) によって明らかになり、破綻の連鎖リスクの指標として有効である。

3). 媒介中心性を拡張した新しいリスク指標 (SRI) を使うことで、破綻の連鎖リスク評価の精度が向上する。

上記3つの手法を比較すると、1). および 2). は機械学習を行うことによって予測値を出し、破綻の連鎖リスクを表す手法であるため教師データが必要になるが、ABM を使って銀行間取引ネットワークを構築し、シミュレーションを行うことでリスク指標の設定が可能になる。リスクを測る尺度としては、今後の銀行規制の強化のような経済環境の変化や、金融機関の合併・統合のような資金取引ネットワークの変化による破綻の連鎖でどのネットワーク指標が説明力が高いかを検証する際には、1). および 2). は有効である。また、銀行間資金取引ネットワーク構造が破綻の連鎖に影響を与えていることを明らかにし、システムリスクの発生メカニズムの解明に貢献できた。それに対して、3). はネットワーク指標を拡張して破綻の連鎖リスクを表すことができるため、資金取引ネットワーク構造だけでリスク指標が設定可能になるが、財務状況や銀行規制の変化によるリスク指標の変化には適応できないため、これらの指標を目的に応じて使い分ける必要がある。

さらに、他の研究に対する優位性には以下のとおりである。

- [CFS05, CLY16, KKY+16a, KKY+16b] は内生的リスクを考慮した研究であるが、金融機関数が少なく金融システム全体のモデル化になっていないが、本研究では日本の金融機関数を想定し、実データに即したネットワークを採用した。
- [CFS05, CLY16] は内生的リスクを数理モデルで表しているが、本研究ではエージェントベースモデルによりシンプルなエージェントの振舞いから創発的に起こる現象によってモデル化し、予測不可能な金融機関の破綻の連鎖をシミュレーションしているため、シミュレーション結果から影響を及ぼしたエージェントの振舞いを特定し、複雑な金融システムを解明した。

6.1.3 資金取引ネットワークモデルに基づく金融機関の経営統合影響分析の結論

第3章および第4章では、システムリスクのベーシックモデルをエージェントベースモデルに拡張してモデル化しており、バランスシートをすべての金融機関で同一とし、ネットワーク構成の差異によるシステムリスクの影響をみることに焦点を当てていた

が、第5章の資金取引ネットワークモデルに基づく金融機関の経営統合影響分析では、金融機関のモデル化において以下の点を考慮し、より現実的な金融機関のシミュレーションを可能にした。このモデルを用いて、金融機関の合併または統合が金融機関の破綻連鎖にどのように影響するか検証を行い、最近の日本の中・小規模銀行に対する銀行再編の流れを考慮して、金融機関の合併・統合の影響を評価した。

- 金融機関の規模別にバランスシートを変更
- 金融規制の影響を考慮
- 内生的リスクの考慮
- 金融機関の合併・統合によるネットワークの変化

これらの結果から、次の3点の貢献がある。

- 1). 内生的リスクとして自己資本比率と預金支払準備率による平衡制約を考慮したバランスシートモデルによるエージェントベースモデルを構築した。
- 2). 金融機関の資金取引ネットワークによるエージェントベースモデルを使って、金融機関の合併・統合による破綻の連鎖への影響を明らかにした。
- 3). 金融機関が合併・統合することによる破綻連鎖数への影響を、ノードの次数とバランスシートの指標で説明した。

この手法については、金融機関の規模を3タイプに分けてバランスシートを設定することで、より現実的な検証が可能になった。ここでは、内生的リスクを考慮するためのバランスシートのモデル化について述べ、Chen, Liu, Yao [CLY16] のモデルの結果と比較し、 E/A (デフォルト時貸出残高が資産に占める比率)が高くなると破綻の連鎖リスク拡大に影響することを明らかにした。このモデルでは、バランスシートにおいて預金支払準備率(Reserve Ratio)と自己資本比率(Capital Adequacy Ratio)を考慮し、金融規制の影響を受けるが、自己資本比率が十分大きければ破綻が発生しないことも確認した。さらに、最近の日本の中・小規模銀行に対する銀行再編の流れを考慮し、金融機関の合併・統合の影響について、(1)最も破綻連鎖数の多い金融機関ノードをその次に破綻連鎖数の多い金融機関ノードに合併・統合するパターンと、(2)もっとも破綻の連鎖が大きくなる金融機関に対して、銀行間取引がある金融機関を合併・統合対象とするパターンを検証し、金融機関の合併・統合による破綻の連鎖の影響を評価し、金融規制で求められる指標である自己資

本比率に加えて、E/A が合併・統合先を選定する指標として有効であることを発見した。

さらに、他の研究に対する優位性には以下のとおりである。

- [GK10, NYYA07, MA10, KKY⁺16a, KKY⁺16b] では、資金取引ネットワークにランダムネットワークもしくは完全ネットワークを使用しているが、本研究では日本の分析結果に基づきランダムネットワークに加え、スケールフリーネットワークでの検証も行った。
- [EN01, GK10, NYYA07, MA10] では、内生的リスクを考慮した市場型システムリスクに対応できていないが、本研究では内生的リスクを考慮した。
- [CFS05, CLY16] は内生的リスクを数理モデルで表しているが、本研究ではエージェントベースモデルによりシンプルなエージェントの振舞いから創発的に起こる現象によってモデル化し、予測不可能な金融機関の破綻の連鎖をシミュレーションしているため、シミュレーション結果から影響を及ぼしたエージェントの振舞いを特定し、複雑な金融システムを解明した。

6.2 今後の展開

破綻の連鎖リスクについての今後の展開としては、リンクの考慮による検証が考えられる。本研究では、ノードのリンク削除の特性による分析にとどまっているが、リンク削除による破綻連鎖数の増減を考慮することは有効だと考えられ、実務的にも特定の金融機関のすべてのリンク（ノードのリンク先すべて）を削除するよりも、リンク毎に金融機関間の融資を解消、あるいは設定することの方が現実的だといえる。また、重要な取引についてリンクに重みを付けることも考えられ、実装できればさらに現実性が高まることが期待できる。

また、資金取引ネットワークについては、本研究ではランダムネットワーク（Erdos-Renyi モデル）もしくはスケールフリーネットワーク（Barabasi-Albert モデル）で検証を行い、設定パラメータは実データに基づき設定を行っている。しかし、実際の資金取引ネットワークは単一のランダムネットワークモデルもしくはスケールフリーネットワークでは表せないため、複数のネットワーク特性があるネットワークを混合して作成することが考えられる。さらに、資金取引ネットワークが多様な金融商品を取引していることを考慮す

ると、単一のネットワークではなく階層的なネットワークで表すことも考えられる。その階層的なネットワークに、流動性資産や債券等の取引を表現することで、金融市場の変化をネットワーク指標の一つとして表すことができる。その場合、ネットワークの規模についても、本研究では日本の金融機関数を前提としたが、近年ではグローバルに展開している金融機関が複数存在するため、規模を増やすことを検討する必要がある。

次に、経営統合モデルの今後の展開について述べる。本モデルでは金融機関を3タイプに分けてバランスシートを設定しているが、リンク数によるバランスシートの影響は考慮していない。今後、3タイプだけではなく各ノードとの接続状況によって、バランスシートも変化するモデルの構築が考えられる。バランスシートの各勘定を機械学習の教師データとすれば、今まで考慮していなかった新たな切り口から研究を進めることができる可能性がある。また、本モデルのベースとなる制約として自己資本比率の維持に注目して実装しているが、本モデルを使うことで、流動性カバレッジ比率制約（Liquidity Coverage Ratio）、ファイアセール（投売り）による非流動性資産の毀損等の考慮をモデルに組み込むことができる。これらの考慮を組み込むことで、金融市場の状況の変化や、資産価値の暴落による金融機関の破綻の発生等を表すことができる。むやみに指標を増やすことは、モデルの複雑化によって特性が薄れてしまうリスクもあり、モデルの構築には考慮が必要であるが、今後目的とする指標に焦点を当て、拡張を行っていきたい。さらに、投資意思決定についても本研究では自己資本を満たしているかどうかで、同じ先へ再融資を行うかどうかを判別するシンプルなモデルとしているため、状況に応じて投資先を動的に選択するような拡張を検討していきたい。

6.3 むすび

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。これは、[IS08]らによる金融機関の資金取引ネットワーク分析の特性を、公的資金の投入に対する確実性の向上を図るリスク指標を提言している意味で経済効果は大きい。

本研究の総括として、研究のメリットを以下の3点あげる。

- 機密性の高い銀行間取引の実データは中央銀行等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。開示されている財務データ等から矛盾のないシンプルな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て十分な検証を行うことが可能になった。
- 金融機関の取引が金融システム全体に及ぼす内生的リスクのような挙動を、シンプルなエージェントの振舞いから創発的に起こる現象によってモデル化し、予測不可能な金融機関の破綻の連鎖をシミュレーションした。
- 恣意的な仮説を立てずにシミュレーションを行うことができるため、汎用的な検証の結果から特徴的な振る舞いをするエージェントを特定し、演繹的に金融システムを説明した。

謝辞

本論文の作成にあたり、終始適切な助言を賜り、また丁寧に指導して下さった倉橋節也教授に感謝します。また、研究のアプローチや考察の方法などについて適切な助言をいただいた牧本直樹教授、吉田健一教授にも心より感謝申し上げます。

本当にありがとうございました。

参考文献

- [AB16] Tobias Adrian and Markus K Brunnermeier. Covar. *The American Economic Review*, Vol. 106, No. 7, pp. 1705–1741, 2016.
- [Ach09] Viral V Acharya. A theory of systemic risk and design of prudential bank regulation. *Journal of financial stability*, Vol. 5, No. 3, pp. 224–255, 2009.
- [Ada13] 足立一夫. 合併は収益力の向上, 強固な経営基盤構築をもたらすのか: 信用金庫, 信用組合の合併と「規模の経済性」. *社会科学論集*, No. 138, pp. 91–116, 2013.
- [AER12] Viral Acharya, Robert Engle, and Matthew Richardson. Capital shortfall: A new approach to ranking and regulating systemic risks. *The American Economic Review*, Vol. 102, No. 3, pp. 59–64, 2012.
- [AJ17] Gene Ambrocio and Esa Jokivuolle. Should bank capital requirements be less risk-sensitive because of credit constraints? 2017.
- [AOTS15] Daron Acemoglu, Asuman Ozdaglar, and Alireza Tahbaz-Salehi. Systemic risk and stability in financial networks. *The american economic review*, Vol. 105, No. 2, pp. 564–608, 2015.
- [APPR10] Viral V. Acharya, Lasse H. Pedersen, Thomas Philippon, and Matthew P. Richardson. Measuring systemic risk. 2010.
- [Ban10] European Central Bank. Financial networks and financial stability. *Financial Stability Review*, pp. 155–160, 2010.
- [BBCH17] Marco Bardoscia, Paolo Barucca, Adam Codd, and John Hill. The decline of solvency contagion risk. *Bank of England Staff Working Paper*, No. 662, 2017.
- [BBEHA17] Safae Badraoui, Khalid Bensaid, Ahmed Mouad El Haloui, and Rajae

- Aboulaich. Impact of qualitative characteristics on market equilibrium simulation with agent-based modeling. *Review of Pacific Basin Financial Markets and Policies*, p. 1750013, 2017.
- [BDS99] Allen N. Berger, Rebecca S. Demsetz, and Philip E. Strahan. The consolidation of the financial services industry: Causes, consequences, and implications for the future. *Journal of Banking & Finance*, Vol. 23, No. 24, pp. 135–194, 2 1999.
- [BE16] Christian Brownlees and Robert F. Engle. Srisk: A conditional capital shortfall measure of systemic risk. *The Review of Financial Studies*, Vol. 30, No. 1, pp. 48–79, 2016.
- [BGLP12] Monica Billio, Mila Getmansky, Andrew W. Lo, and Liorana Pelizzon. Econometric measures of connectedness and systemic risk in the finance and insurance sectors. *Journal of Financial Economics*, Vol. 104, No. 3, pp. 535–559, 2012.
- [BK15] Charles D. Brummitt and Teruyoshi Kobayashi. Cascades in multiplex financial networks with debts of different seniority. *arXiv preprint arXiv:1501.05400*, 2015.
- [CF13] Matteo Chinazzi and Giorgio Fagiolo. Systemic risk, contagion, and financial networks: a survey. *LEM Working Paper Series*, 2013.
- [CFS05] Rodrigo Cifuentes, Gianluigi Ferrucci, and Hyun S. Shin. Liquidity risk and contagion. *Journal of the European Economic Association*, Vol. 3, 2 - 3, pp. 556–566, 2005.
- [CLY16] Nan Chen, Xin Liu, and David D. Yao. An optimization view of financial systemic risk modeling: Network effect and market liquidity effect. *Operations research*, 2016.
- [CW17] Frank Cheng and Michael P Wellman. Accounting for strategic response in an agent-based model of financial regulation. In *Proceedings of the 2017 ACM Conference on Economics and Computation*, pp. 187–203. ACM, 2017.
- [CWL17] Xian Cheng, Ji Wu, and Stephen Shaoyi Liao. A study of contagion in the

- financial system from the perspective of network analytics. *Neurocomputing*, 2017.
- [CZ17] Eugenio Cerutti and Haonan Zhou. The global banking network in the aftermath of the crisis: is there evidence of de-globalization. Technical report, IMF Working Paper, 2017.
- [Davi07] David Liben - Nowell, Jon Kleinberg. The link - prediction problem for social networks. *Journal of the American Society for Information Science and Technology*, Vol. 58, No. 7, pp. 1019–1031, 2007.
- [DBH00] Olivier De Bandt and Philipp Hartmann. Systemic risk: a survey. *Working Paper*, No. 35, 2000.
- [DBPS17] Marco D’Errico, Stefano Battiston, Tuomas Peltonen, and Martin Scheicher. How does risk flow in the credit default swap market? *Journal of Financial Stability*, 2017.
- [DCG15] Andr Dias, Pedro Campos, and Paulo Garrido. An agent based propagation model of bank failures. Vol. 676, pp. 119–130, 01/01 2015.
- [DDG17] Benoît Desmarchelier, Faridah Djellal, and Faïz Gallouj. Economic growth, business cycles and products variety: exploring the role of demand satiety. *Journal of Evolutionary Economics*, pp. 1–27, 2017.
- [DH17] Stéphane Dees and Jérôme Henry. Stress-test analytics for macroprudential purposes: Introducing stamp. *SATELLITE MODELS*, p. 13, 2017.
- [DIC17] DICJ. 2017. <https://www.dic.go.jp/katsudo/shihonzokyo/index.html>.
- [DPB⁺09] Aikman David, Alessandri Piergiorgio, Eklund Bruno, Gai Prasanna, Kapadia Sujit, Martin Elizabeth, Mora Nada, Sterne Gabriel, and Willison Matthew. Funding liquidity risk in a quantitative model of systemic stability. *Bank of England Staff Working Paper*, No. 372, 2009.
- [DY14] Francis Diebold and Kamil Yilmaz. On the network topology of variance decompositions: Measuring the connectedness of financial firms. *Journal of Econometrics*, Vol. 182, No. 1, pp. 119–134, 2014.
- [EN01] Larry Eisenberg and Thomas H. Noe. Systemic risk in financial systems.

- Management Science*, Vol. 47, No. 2, pp. 236–249, 2001.
- [EVS10] Marco A. Espinosa-Vega and Juan A. Sol. Cross-border financial surveillance: a network perspective. *IMF Working Papers*, pp. 1–27, 2010.
- [F⁺17] Jose Figue, et al. Retrieving implied financial networks from bank balance-sheet and market data. Technical report, Bank of Canada, 2017.
- [Far17] Maryam Farboodi. Comment on network reactions to banking regulations by selman erol and guillermo ordonez. *Journal of Monetary Economics*, 2017.
- [FDI17] FDIC. 2017. <https://www.fdic.gov/bank/individual/failed/banklist.html>.
- [FLLO16] Gerardo Ferrara, Sam Langfield, Zijun Liu, and Tomohiro Ota. Systemic illiquidity in the interbank network. *Bank of England Staff Working Paper*, No. 586, 2016.
- [FOS17] Ester Faia, Gianmarco Iero Paolo Ottaviano, and Irene Sanchez. International expansion and riskiness of banks. 2017.
- [FPR00] Xavier Freixas, Bruno M Parigi, and Jean-Charles Rochet. Systemic risk, interbank relations, and liquidity provision by the central bank. *Journal of money, credit and banking*, pp. 611–638, 2000.
- [FSB16] FSB. *Peer Review of Japan*. Peer Review Reports, 2016.
- [Fuc10] 淵田康之. 市場型システミックリスクとセイフティ・ネット, 2010.
- [Fuj08] 藤井健司. 金融機関の総合的リスク・自己資本管理態勢. 金融財政事情研究会, 2008.
- [Fun16] International Monetary Fund. *GERMANY FINANCIAL SECTOR ASSESSMENT PROGRAM*. 2016.
- [GK10] Prasanna Gai and Sujit Kapadia. Contagion in financial networks. *Bank of England Quarterly Bulletin*, Vol. 50, No. 2, p. 124, 2010.
- [GLT15] Robin Greenwood, Augustin Landier, and David Thesmar. Vulnerable banks. *Journal of Financial Economics*, Vol. 115, No. 3, pp. 471–485, 2015.
- [GRPDG16] Julen Gonzalez-Redin¹², J Gary Polhill, Terry Dawson, and Iain James

- Gordon. Examining the impact of debt-based economic systems on natural resources: An agent-based modelling approach. *Social Simulation Conference 2016*, 2016.
- [Har09] 原和明. 米国における銀行破綻処理. 預金保険研究, 2009.
- [Hel12] Dirk Helbing. *Systemic Risks in Society and Economics*, pp. 261–284. Springer Berlin Heidelberg, Berlin, Heidelberg, 2012 edition, 2012.
- [HK02] 堀江康熙, 川向肇. 信用金庫の営業地盤と合併問題, 2002.
- [HM11] Andrew G Haldane and Robert M May. Systemic risk in banking ecosystems. *Nature*, Vol. 469, No. 7330, p. 351, 2011.
- [HORV17] Jonas Heipertz, Amine Ouazad, Romain Rancière, and Natacha Valla. Balance-sheet diversification in general equilibrium: Identification and network effects. Technical report, National Bureau of Economic Research, 2017.
- [HVHS12] Xuqing Huang, Irena Vodenska, Shlomo Havlin, and H. E. Stanley. Cascading failures in bi-partite graphs: model for systemic risk propagation. *arXiv preprint arXiv:1210.4973*, 2012.
- [Hyun15] Hyun S. Shin, 服部正純, 大橋和彦. リスクと流動性 : 金融安定性の新しい経済学. 東洋経済新報社, 2015.
- [HZZ09] Xin Huang, Hao Zhou, and Haibin Zhu. A framework for assessing the systemic risk of major financial institutions. *Journal of Banking & Finance*, Vol. 33, No. 11, pp. 2036–2049, 2009.
- [IBF09] IMF, BIS, and FSB. Guidance to assess the systemic importance of financial institutions, markets and instruments:initial considerations. 2009.
- [IDMP⁺08] Giulia Iori, Giulia De Masi, Ovidiu Vasile Precup, Giampaolo Gabbi, and Guido Caldarelli. A network analysis of the italian overnight money market. *Journal of Economic Dynamics and Control*, Vol. 32, No. 1, pp. 259–278, 2008.
- [INST03] 稲岡創, 二宮拓人, 清水季子, 高安秀樹. 金融機関の資金取引ネットワーク. 日本銀行金融市場局, ワーキングペーパー.(28 ページ), 2003.
- [IS08] 今久保圭, 副島豊. コール市場の資金取引ネットワーク. 金融研究, Vol. 27,

No. -, pp. 47–99, 2008.

- [Kan10] 菅野正泰. 入門金融リスク資本と統合リスク管理. 金融財政事情研究会/きんざい, 2010.
- [Kan13] 菅野正泰. グローバル金融危機における損害保険会社のシステミック・リスクの影響度分析: 銀行との対比検証. 損害保険研究, Vol. 74, No. 4, pp. 127–156, 2013.
- [KKY⁺16a] 菊地剛正, 國上真章, 山田隆志, 高橋大志, 寺野隆雄. エージェントシミュレーションを用いた金融規制が金融機関の連動的な破綻に与える影響の分析. 人工知能学会論文誌, Vol. 31, No. 6, pp. AG–G_1, 2016.
- [KKY⁺16b] 菊地剛正, 國上真章, 山田隆志, 高橋大志, 寺野隆雄. エージェントシミュレーションを用いた中央銀行の資金供給が金融機関の連動的な破綻に与える影響の分析. 経営情報学会誌, Vol. 25, No. 3, pp. 169–185, 2016.
- [KM10] 今野紀雄, 増田直紀. 複雑ネットワーク: 基礎から応用まで. 近代科学社, 2010.
- [KM⁺17] Ivo Krznar, Troy D Matheson, et al. Towards macroprudential stress testing: Incorporating macro-feedback effects. *IMF Working Paper: Towards Macroprudential Stress Testing-Incorporating Macro Feedback Effects*, Vol. 17, No. 149, 2017.
- [KN11] 鎌田康一郎, 那須健太郎. 早期警戒指標としての金融動向指数. 日本銀行ワーキングペーパーシリーズ』(日本銀行), No. 11, 2011.
- [Kob10] 小林襄治. 英国銀行危機とシステミック・リスク (サブプライムショック後のヨーロッパ金融・資本市場). 証券経済研究, No. 72, pp. 1–25, 2010.
- [Kob14] 小林照義. 金融ネットワーク・モデルとネットワーク理論: 現状と課題. 国民経済雑誌, Vol. 210, No. 6, pp. 91–101, 2014.
- [KS13] Setsuya Kurahashi and Muneyoshi Saito. Informative and normative effects using a selective advertisement. *SICE Journal of Control, Measurement, and System Integration*, Vol. 6, No. 2, pp. 76–82, 2013.
- [KT12] 加藤涼, 敦賀貴之. 銀行理論と金融危機: マクロ経済学の視点から. 金融研究, Vol. 31, No. 4, pp. 95–134, 2012.
- [Lau17] Eliana Lauretta. The hidden soul of financial innovation: An agent-based

- modelling of home mortgage securitization and the finance-growth nexus. *Economic Modelling*, 2017.
- [LM11] Webber Lewis and Willison Matthew. Systemic capital requirements. *Bank of England Staff Working Paper*, No. 436, 2011.
- [LW17] SW Li and SH Wen. Multiplex networks of the guarantee market: Evidence from china. *COMPLEXITY*, 2017.
- [MA10] Robert M. May and Nimalan Arinaminpathy. Systemic risk: the dynamics of model banking systems. *Journal of the Royal Society, Interface / the Royal Society*, Vol. 7, No. 46, pp. 823–838, 2010.
- [MA17] Adeel Mahmood and Bilal Aziz. Evaluating the systemic risk and its impact on profitability and liquidity; evidence from european countries. *Imperial Journal of Interdisciplinary Research*, Vol. 3, No. 2, 2017.
- [Mak11] 牧本直樹. 銀行間資金決済ネットワークにおける最適決済行動と流動性節約効果. *金融研究*, Vol. 30, No. 1, pp. 75–123, 2011.
- [ML15] Mattia Montagna and Thomas Lux. Hubs and resilience: towards more realistic models of the interbank markets. *Banking Integration and Financial Crisis: Some Recent Developments*, 2015.
- [MMHK12] Yoshiharu Maeno, Satoshi Morinaga, Matsushima Hirokazu, and Amagai Kenichi. Risk of the collapse of a bank credit network. *JSAI*, Vol. 27, No. 6, pp. 338–345, 2012.
- [MMMA12] 前野義晴, 森永聡, 松島宏和, 天谷健一. 銀行ネットワークの破綻リスク. *人工知能学会論文誌*, Vol. 27, No. 6, pp. 338–345, 2012.
- [MMNM14] Yoshiharu Maeno, Satoshi Morinaga, Kenji Nishiguchi, and Hirokazu Matsushima. Impact of credit default swaps on financial contagion. *Computational Intelligence for Financial Engineering & Economics (CIFEr), 2104 IEEE Conference on*, pp. 152–157, 2014.
- [MS94] 水谷直樹, 真田英彦. 決済ネットワークにおけるシステミック・リスク・モデル. *電子情報通信学会技術研究報告. OFS, オフィスシステム*, Vol. 94, No. 144, pp. 1–6, 1994.
- [N⁺13] 永田裕司ほか. システミック・リスクと金融の脆弱性. *福岡大学商学論叢*,

- Vol. 57, No. 3-4, pp. 253–272, 2013.
- [Nam13] Akira Namatame. Simulation models on systemic risks. *IEEE Series of Computational Intelligence*, pp. 16–19, 2013.
- [NBZZ04] Gianni De Nicoló, Philip Bartholomew, Jahanara Zaman, and Mary Zephirin. Bank consolidation, internationalization, and conglomeration: Trends and implications for financial risk. *Financial markets, institutions & instruments*, Vol. 13, No. 4, pp. 173–217, 2004.
- [NS13] 中島真志, 宿輪純一. 決済システムのすべて. 東洋経済新報社, 2013.
- [NS17] Sergey Nadtochiy and Mykhaylo Shkolnikov. Particle systems with singular interaction through hitting times: application in systemic risk modeling. *arXiv preprint arXiv:1705.00691*, 2017.
- [NYYA07] Erlend Nier, Jing Yang, Tanju Yorulmazer, and Amadeo Alentorn. Network models and financial stability. *Journal of Economic Dynamics and Control*, Vol. 31, No. 6, pp. 2033–2060, 2007.
- [OH12] 大橋和彦, 服部正純. 金融危機, 金融市場, 金融仲介機能に関する研究の潮流: 危機がもたらした視点・力点の変化の整理. *金融研究*, Vol. 31, No. 4, pp. 41–93, 2012.
- [OS03] 岡崎哲二, 澤田充. 銀行統合と金融システムの安定性: 戦前期日本のケース. *社会経済史学*, Vol. 69, No. 3, pp. 275–296, 2003.
- [PC17] Leonardo dos Santos Pinheiro and Flavio Codeco Coelho. An agent-based model of contagion in financial networks. *arXiv preprint arXiv:1703.07513*, 2017.
- [PR98] Joe Peek and Eric S Rosengren. Bank consolidation and small business lending: It’s not just bank size that matters. *Journal of Banking & Finance*, Vol. 22, No. 6, pp. 799–819, 1998.
- [RLK11] Garratt Rodney, Mahadeva Lavan, and Svirydzenka Katsiaryna. Mapping systemic risk in the international banking network. *Bank of England Staff Working Paper*, No. 413, 2011.
- [RLM12] Garratt Rodney, Webber Lewis, and Willison Matthew. Using shapley’s asymmetric power index to measure banks’ contributions to systemic risk.

- Bank of England Staff Working Paper*, No. 468, 2012.
- [RT96] Jean-Charles Rochet and Jean Tirole. Interbank lending and systemic risk. *Journal of Money, credit and Banking*, Vol. 28, No. 4, pp. 733–762, 1996.
- [S⁺05] 相馬亘ほか. 経済における複雑系ネットワーク: 日本の経済ネットワークは特殊か?(特集ネットワークが創発する知能). *人工知能学会誌*, Vol. 20, No. 3, pp. 289–295, 2005.
- [SKS17] Walmir Silva, Herbert Kimura, and Vinicius A. Sobreiro. An analysis of the literature on systemic financial risk: A survey. *Journal of Financial Stability*, Vol. 28, pp. 91–114, February 2017 2017. ID: 273210.
- [SMJG12] Kapadia Sujit, Drehmann Mathias, Elliott John, and Sterne Gabriel. Liquidity risk, cash-flow constraints and systemic feedbacks. *Bank of England Staff Working Paper*, No. 456, 2012.
- [Sug10] 杉田浩治. システムリスクの発生を如何にして防ぐか (sifma-米国証券業金融市場協会-の提案). *証券レビュー*, Vol. 50, No. 9, pp. 38–73, 2010.
- [Sup09] Basel Committee Banking Supervision. Principles for sound stress testing practices and supervision. *BIS publications*, 2009.
- [Tak12] 高橋正彦. 預金保険制度の歴史と基本的課題. *預金保険研究*, 2012.
- [Ter10] 寺野隆雄. なぜ社会システム分析にエージェント・ベース・モデリングが必要か. *横幹*, Vol. 4, No. 2, pp. 56–62, 2010.
- [TIMR16] Asena Temizsoy, Giulia Iori, and Gabriel Montes-Rojas. Network centrality and funding rates in the e-mid interbank market. *Journal of Financial Stability*, 2016.
- [Usu17] 碓井茂樹. リスクの把握と管理. 日本銀行金融機構局金融高度化センター, 2017.
- [Van17] David VanHoose. Macroprudential regulation and international policy coordination. In *The Industrial Organization of Banking*, pp. 281–303. Springer, 2017.
- [W⁺17] Ron Wallace, et al. The signature of risk: Agent-based models, boolean networks and economic vulnerability. *Economic Thought*, Vol. 6, No. 1, pp. 1–15, 2017.

- [Wat02] Duncan J Watts. A simple model of global cascades on random networks. *Proceedings of the National Academy of Sciences*, Vol. 99, No. 9, pp. 5766–5771, 2002.
- [Yos12] 吉田康志. 決済スキームの発展と流動性管理の観点から見たネット決済方式の効率性. 商大論集, Vol. 64, No. 1, pp. 1–28, 2012.
- [YY00] 山井康浩, 吉羽要直. バリュウ・アット・リスクのリスク指標としての妥当性について. 日銀金融研究所ディスカッションペーパーシリーズ, No. 2000-J-2, 2000.
- [ZC17] Stefano Zedda and Giuseppina Cannas. Analysis of banks’ systemic risk contribution and contagion determinants through the leave-one-out approach. *Journal of Banking & Finance*, 2017.

関連業績リスト

・ 学術論文（査読付き）

- Morito Hashimoto, and Setsuya Kurahashi: The Research of Bankruptcies' Succession by Systemic Risk Index, New Frontiers in Artificial Intelligence Springer(August 2017)
- 橋本守人, 倉橋節也: 資金取引ネットワークモデルに基づく連鎖破綻リスク分析, 人工知能学会論文誌, Vol. 32, No.5 (September 2017)

・ 国際学会論文（査読付き）

- Morito Hashimoto, and Setsuya Kurahashi: Effect Analysis of Systemic Risk Index in Fund Transaction Networks, Artificial Intelligence of and for Business (AI-Biz2016), Keio University, Kanagawa, Japan (November 2016)
- Morito Hashimoto, and Setsuya Kurahashi: Management integration impact analysis of financial institutions based on a fund transaction network model, The Social Simulation Conference 2017, University College Dublin, Dublin, Ireland (September 2017)

・ 国内シンポジウム, 研究会

- 橋本守人, 倉橋節也: 銀行間取引の構造を考慮したシステムリスクの研究, 計測自動制御学会第7回社会システム部会研究会, 小樽商科大学, 北海道小樽市 (September 2014)
- 橋本守人, 倉橋節也: 銀行間取引の構造を考慮したシステムリスクの研究, 人工知能学会ビジネス・インフォマティクス研究会第1回研究会, 慶応大学, 神奈川県横

浜市 (November 2014)

- 橋本守人, 倉橋節也: 銀行間取引の構造を考慮したシステミックリスクの研究, 金融ネットワーク研究会第3回研究会, 神奈川県横須賀市 (January 2015)
- 橋本守人, 倉橋節也: 銀行間取引を考慮したシステミックリスクの研究, 人工知能学会ビジネス・インフォマティクス研究会第2回研究会, 沖縄県宮古島市 (March 2015)
- 橋本守人, 倉橋節也: 資金取引ネットワークにおけるシステミックリスク指標の効果分析, 合同エージェントワークショップ&シンポジウム 2015 (JAWS2015), 石川県加賀市 (September 2015)
- 橋本守人, 倉橋節也: インターバンクネットワークによる資産損失の伝播, 人工知能学会ビジネス・インフォマティクス研究会第5回研究会, 岩手県立大学, 岩手県盛岡市 (August 2016)
- 橋本守人, 倉橋節也: 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, FIT2016 情報処理学会情報科学技術フォーラム, 富山大学, 富山県富山市 (September 2016)
- 橋本守人, 倉橋節也: 資金取引ネットワークにおける破綻連鎖リスクの研究, 計測自動制御学会システム・情報部門学術講演会, 滋賀県立体育館, 滋賀県大津市 (December 2016)
- 橋本守人, 倉橋節也: 資金取引ネットワークモデルに基づく金融機関の経営統合影響分析, 人工知能学会全国大会 (第31回), ウィンクあいち, 愛知県名古屋市 (May 2017)
- 橋本守人, 倉橋節也: 金融機関の合併・統合によるシステミックリスクの影響分析, 合同エージェントワークショップ&シンポジウム 2017 (JAWS2017), 千葉県鴨川市 (September 2017)