

# ニューラルネットワークアプローチによる経済分析 —— モデルの概要と金融政策への応用例 ——

副 島 豊

1. はじめに
2. ニューラルネットワークの概要
3. 中央銀行の政策判断への応用
4. 実証分析
5. 終わりに

## 補論

キーワード：ニューラルネットワーク、非線型性、中央銀行の総合判断、  
経済情勢の認識と政策決定、限定合理性、公定歩合操作

## 1. はじめに

近年、中央銀行の行動基準ないし政策反応関数を計測する様々な試みがなされている。しかし、現実の中央銀行の行動は、局面によって同じ情報に対し異なった反応をするなど単純な回帰式で計測された政策反応関数では表わせないことが多い。この点について、多くの中央銀行は「総合判断」の重要性を強調している。

本論文の目的は、総合判断に基づく意思決定という複雑な行為を分析するために、人間の脳内の情報処理機能を模したニューラルネットワークモデルの分析手法を紹介するとともに、こうした手法を用いることにより中央銀行の総合判断をどのように捉えることができるかを例示することである。

現在の標準的な中央銀行行動分析では、中央銀行の目的関数を設定し、あるマクロモデルの制約下でその現在価値を最大化するよう中央銀行が行動しているとみなす。こうした考え方は、中央銀行がマクロ経済の構造を完全に把握し、また金融政策の経済に与える影響を誤りなく予測でき、さらには景気循環のスパンを遙かに越えた時間的視野を持って行動しているという前提に基づいている。しかし、こうしたアプローチが中央銀行行動を分析するモデルとして現実をうまく近似しているかどうかは疑わしい。本論文

---

本論文の作成に当たっては釜 国男教授（創価大学）、馬場則夫教授（大阪教育大学）より有益なコメントを頂いたほか、解析ソフトウェアの入手に際し松田聡浩氏（三菱総研総合安全研究センター）にご協力頂いた。また、インターネット上で解析ソフトウェアや論文、資料等を配布して頂いている国内外の多くの研究者の助力を得ている。

では、政策決定過程を経済情勢の認識とそれに基づく政策決定として捉え、前者をパターン認識、後者を経済情勢パターンと政策行為のマッチング行為とみなす。実証分析では、ニューラルネットワークに中央銀行の認識・行動パターンを学習させ、学習済みのニューラルネットワークがどのような特性をもつか、また各時期の経済環境にどのように応答するかを観察することで中央銀行行動を捉えることを試みた。

実際の分析にあたっては1960年代以降の日本銀行の金融政策を取り上げた。与えたマクロ経済環境は、経済成長とインフレに関する情報（前年比四半期データ）である。公定歩合政策に政策の基本スタンスが現れているとみなし、公定歩合の引き上げ、引き下げ、据え置きという質的政策変数と、公定歩合の水準という数量的政策変数を同時に使用した。政策行動をニューラルネットワークに学習させた結果、利用したデータが二系列であるにもかかわらず公定歩合操作のタイミングや水準をかなり高い精度でトレースした。1980年代以降を学習させたニューラルネットワークから、公定歩合水準とインフレ率、実質成長率の関係をみると、公定歩合水準はインフレ率に比例していること、しかもインフレ率が低水準から高水準（あるいはその逆）へ移動する時期ほど公定歩合の変化幅が大きいようなS字型の非線型関係にあることがわかった。また、1991年からの景気後退期には成長率の低下に対してセンシティブになっていることが窺われた。次に、景気と政策の転換期について公定歩合の変更もしくは据え置きがニューラルネットワークでどのように捉えられるかをみた。その結果、足許のインフレ率、実質成長率の水準に加え、景気循環の過程において経済がどの方向にどの程度の加速度を持って動いているかが重要であることが確認された。特に、公定歩合操作はインフレ率、実質成長率の変化と比例的に対応しているのではなく、経済変動がある加速度を越えた場合に急激に公定歩合操作の可能性が高まるような臨界値があることがわかった。また、インフレ率と実質成長率のいずれにセンシティブであるかは時期によって異なること、景気の転換点には据え置きが継続される余地は小さくなり、比較的小さい経済変動にも政策反応しやすくなることなどが観察された。

本論文の構成は、以下の通りである。まず、2節ではニューラルネットワークの概要について説明する。ニューラルネットワークでは認識や判断という人間の情報処理機能がどのように捉えられるかを解説した後、モデル化の方法について紹介する。3節では、ニューラルネットワークを中央銀行の経済情勢認識と政策決定に適用する。また、従来の代表的な手法である政策反応関数と比較し、ニューラルネットワークによるアプローチの特徴を述べる。4節では、日本銀行に適用した実証分析の結果を示す。また、補論1ではファイナンスや産業分野における応用事例を紹介するとともに、ニューラルネットワークの開発環境やプログラムなど研究・実用化にあたって有用な情報の入手先を示す。補論2では、ニューラルネットワークモデルを具体的に示し、実証分析で用いたモデルの解説を行う。

## 2. ニューラルネットワークの概要

ニューラルネットワークは、人間の脳の神経細胞の特徴的な機能を模式化し、人間の柔軟な情報処理機能をコンピュータ上で再現することを試みたモデルである。人間の持つ知識や判断力をコンピュータに置き換える試みは、人工知能の応用として早くからエキスパートシステムで行われてきた。これは、専門家の持つ知識や経験を明文化したルールについて If, then のようなアルゴリズムを組み合わせたものであり、ルール化が可能な整合性を持った世界を対象とする限りでは有効なシステムであった。しかし、医者患者診察、鋼板のキズ・塗装検査、経済情勢の分析、金融ディーリングなど勘や経験が重要な分野では、曖昧さを許容する人間の脳の情報処理を模倣することができなかった。また、このような特殊事例だけでなく、字を読むとか顔・声を識別するという人間が日常行っている簡単な行為も、従来の手法では実現困難であった。

ニューラルネットワークは、脳神経科学や認知科学などの成果を取り込むことで曖昧さや冗長性、ゆらぎなどに対応し、パターン認識や類推、連想といった人間の脳独特の機能を再現しただけでなく、試行錯誤を繰り返して学習するという情報処理機能を持たせることに成功した。

本節では、ニューラルネットワークが認識や判断という人間の情報処理機能をどう捉えるか解説し、工学的にモデル化する手法について述べる。具体的な数理モデルは補論1で紹介する。

### (1) ニューラルネットワークの情報処理機能

ニューラルネットワークは、パターンやシンボルの変換システム、連想処理システム、概念形成システム、判断システム、記憶システムといった脳が持つ多様な情報処理機能を描写することができる。以下では、ニューラルネットワークで扱える代表的な情報処理機能を見てみよう。

まず、パターンやシンボルの変換システムとして応用する場合、入出力要素の組み合わせによって4タイプのシステムが考えられる(図表1)。パターン変換は、視覚や聴覚、触覚などの感覚器から得られた低次の情報の特徴パターンから、認識に適した高次

図表1 ニューロンによるパターン・シンボル変換

変換システム	入力	出力
パターン変換	パターン	パターン
パターン認識	パターン	シンボル
パターン生成	シンボル	パターン
記号処理	シンボル	シンボル

のパターンへ変換を行うことである。例えば、テレビの画面にノイズが入っていても元の画像を大まかに捉えることができるが、これは観察された視覚パターンから意味のある画像パターンに変換する機能が働いているためである。パターンからシンボルへの変換としては、「5, 5, 5, 5」という形状が異なる図柄をみても、すべて数字の5だと認識できる事例が挙げられる。ここでは、視覚パターンから文字というシンボルへの変換が行われている。逆に、シンボルや高次の特徴パターンから低次のパターンを生成する機能も存在する。例えば、ある言葉（シンボル）から多様な視覚イメージを生成することができよう。また、「110」に対して「警察」と反応するのは、シンボルからシンボルへの記号処理の一例である。

次に、連想処理や概念形成といったより高次の情報処理への応用をみよう。感覚器から入力され、高次の表現形式に変換されたパターンやシンボルは、さらに相互に関連性の強いもの同士や各種の概念と連結される。これを思考や内省といった情報の連想処理機能と考えることができよう。例えば、「5, ÷, π, f」という図柄をみた場合、「数学」という言葉が思い浮かぶかもしれない。数字や割算の演算記号などシンボルとして把握されたもの同士の関連性から「数学」という概念が想起されたのである。<sup>1)</sup> また、連想が既存の概念とパターンやシンボルの結合であるのに対し、観察された事例に共通して存在するパターンやシンボルの特徴を一般化することによって新しい概念を獲得する行為を描写するシステムとしても用いられる。<sup>2)</sup> さらに、連想や関連付けられる対象をあらかじめ与えておけば、分類や判断という情報処理システムとしても利用可能である。例えば、企業情報を入力値とし格付けを出力値とすれば企業の信用力判断システムを構築することができる。

以上は認識に関わる情報処理機能であったが、さらに、ニューラルネットワークの出力を認識や判断を踏まえたうえでの対応行為と置くと、外部環境への適応行動としても利用できる。<sup>3)</sup>

## (2) モデルの概要

人間のみならず生物の神経系は、ニューロンと呼ばれる神経細胞が複雑に連結し、こ

---

1) 「概念」をコンピューターによる認知科学の観点から定義すると、外延の意味での概念と内包的意味での概念に分別される。前者は様々な事例の集合によって、後者は様々な属性の集合によって定義された概念である（安西[1989]参照）。例えば、「好況」の外延の意味での概念は、かつて経験した好況の事例をすべて集めた集合によって定義される。一方、「好況」の内包的意味での概念は、「好況」が内包する属性（経済成長率の上昇、求人数の増加、タクシー空車率の低下等）を事前に定義し、これに合致することによって決定される。

2) これは、外延の意味での概念の獲得である。これとは別に、外部から定義として与えられる外延の意味での概念もある。


3) 認識・判断システムや適応行動システム、制御システムとしての応用は、1980年代末より工学、医学、ファイナンス等の分野で進展している。具体例は補論1参照。

れらが並列的に電気信号の入出力を処理している。図表2-1はニューロンの構造の概略を示したものである。主要な構成物は、出力端子である軸索、入力端子である樹上突起、核を含む本体の細胞体であり、軸索の枝が別のニューロンの樹上突起に付着し電気信号の伝達を行う。この付着部をシナプスと呼び、興奮系と抑制系の2タイプのシナプス結合があることが知られている。興奮系のシナプスにおいては、軸索から来た活動電位(インパルス)が樹上突起を通じて細胞体の電位を上昇させ、この総和がある値(閾値)を超えるとニューロンが発火し、軸索を通じて他のニューロンへ転移していく。<sup>4)</sup> この伝達は、軸索から樹上突起へと一方方向へのみ生じる。<sup>5)</sup>


ニューラルネットワークは、ニューロンの機能を模倣した人工ニューロンを複数連結させたものであり、連結の構造と個々の人工ニューロンの動作によって特徴づけられる。

図表2-2に示したように、人工ニューロンはある入力値に対し何らかの出力値を返す関数として定義される。多数のシナプスから入力された値  $x_i$  をウェイト  $w_i$  により評価して入力値の総和  $x$  を求め、この値が閾値  $\theta$  を越えた場合に出力値  $f(x)$  を返す。出力値は複数の人工ニューロンへ伝播し、入力値としてそれぞれ異なったウェイトで評価される。シナプス間の結合強度の差はウェイトによって表現されるため、このウェイトを結合荷重と呼ぶ。ニューラルネットワークの基本原理は、学習機能に関するヘップのシナ

図表 2-1 ニューロンの構造



図表 2-2 人口ニューロン



- 4) ニューロンは、細胞外との電位差によって非興奮状態と興奮状態に分けられる。非興奮状態の電位を静的電位と呼び、細胞膜のイオンポンプの働きで、細胞外に対して低い電圧状態となっている。細胞膜にある程度の正の電位が加わると、これを契機に細胞内の電位が一瞬だけ周囲より高い状態に跳ね上がる。この現象をニューロンの発火と呼び、ピークの正電位を活動電位と言う。人工ニューロンでは、興奮系シナプスと抑制系シナプスの相違を入力信号の正負で表現する。
- 5) シナプスには、軸索と樹上突起間の間隙(シナプス間隙)の伝達に化学物質を用いる化学シナプスと、シナプス間隙が狭く伝達化学物質を用いない電気シナプスがある。後者は下等生物で確認されており伝達の双方向性を持つが、前者は一方方向にしか伝達しない。

プス強化則仮説（シナプスは刺激が伝達される回数が多いほど結合強度が高まり、一段と伝達が容易になることで、記憶や認識パターンが形成される）に基づいている。一方、現実の神経系においては、入力信号の増幅機能があるわけではなく、軸索の太さの差によってシナプス間の伝達速度が異なっている。従って、ニューラルネットワークは、伝達速度の差を結合強度の差に置き換えてモデル化したものであり、人工ニューロンの連結構造とその結合強度で神経系の状態を模したものと見える。

図表3-1は単位ステップ関数を表し、最も単純な人工ニューロンの入出力関係を与えている。この場合、入力信号が閾値より小さいと発火せず出力はゼロであり、閾値を超えた場合のみ出力値1を示す。また、図表3-2のように、出力値が閾値近辺で非線型に変化するシグモイド関数や、単純な線型関数（図表3-3）、区分線型関数（図表3-4）が用いられる場合もある。特に、後述するBP学習法ではシグモイド関数が適用される場合が多い。これは、同関数がパラメータの値により非線形性の強い階段型関数から線形に近い関数まで近似できるという利点を持っているためである。

ニューラルネットワークは、人工ニューロンの連結の構造によって階層型ニューラルネットワークと相互結合型ニューラルネットワークに分別される。図表4に示したように、前者は、入力層、単数または複数の中間層、および出力層から構成され、情報は入力層から出力層まで順方向に伝達される。<sup>6)</sup> 一方、後者では特別な構造はなく、各人工ニューロンが相互結合し情報を伝達し合う。<sup>7)</sup> ニューラルネットワークが脳が持つような高度な情報処理機能を模倣できるのは、非線型動作をする人工ニューロンを階層状もしくは相互結合に組み合わせた並列処理型の情報処理システムとなっていることによる。<sup>8)</sup>

所与の構造を持ったニューラルネットワークが、適切な結合強度の値を得る過程を学習と呼ぶ。<sup>9)</sup> 学習方式には教師あり学習と教師なし学習の2タイプがある。前者では、入力値に対する理想的な出力値（教師信号）が与えられた環境で、結合強度に基づいて得た出力値と教師信号を比較し、結合強度が修正されていく。後者では、教師信号がな


6) ニューラルネットワークの外界からは入出力値しか観察されず、中間層の動きは隠されている。このため中間層は隠れ層とも呼ばれる。

7) 以下では階層型ニューラルネットワークのみを扱う。


8) 例えば、文字を見てから発音するまでの反応速度と、生理学的に計測されたニューロン単体の伝達速度から、入力から出力まで介在するニューロンの階層数は高々100程度であることが判明している。にもかかわらず人間の脳が複雑な情報処理を行うことができるのは、無数のシナプスの連結パターンが多様な並列処理回路を形成しているためと考えられている。

9) ニューラルネットワークにおける学習とは、入出力関係に合わせて結合係数を修正していく行為を指す。


図表 3-1 単位ステップ関数型




図表 3-2 シグモイド関数型





図表 3-3 線型関数型



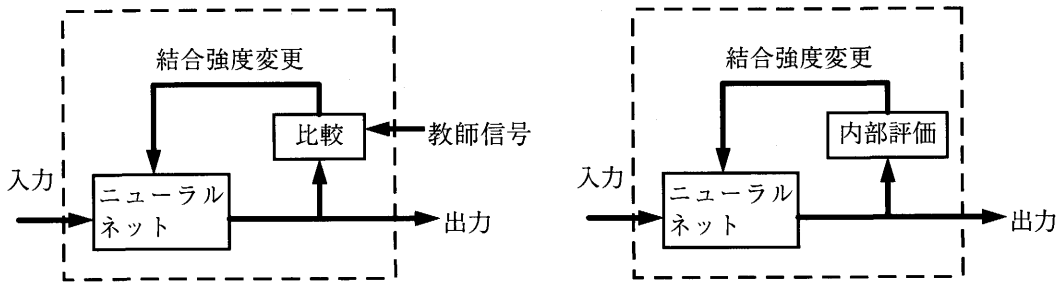
図表 3-4 区分線型型



図表 4 階層型ニューラルネットと相互結合型ニューラルネット



図表5 教師あり学習と教師なし学習



いため、得られた出力値を予め与えられた内部評価基準を照合し結合強度を修正する(図表5)。<sup>10)</sup> 連結構造のタイプや教師信号の有無により様々な学習方法が考案されているが、現在、最も活用されている代表的なニューラルネットワークは階層型の教師信号付き学習タイプであり、本論文の分析でもこれを用いている。

### (3) 誤差逆伝播法による学習

以下では、階層型ニューラルネットの代表的な学習法である誤差逆伝播法 (Back Propagation、以下ではBP法と呼ぶ)の基本的な考え方について説明する。<sup>11)</sup> BP法は、図表6に示したアルゴリズムによる結合荷重の決定法である。まず、初期値として与えられた結合荷重に基づいて出力値を得る。次に、出力値と教師信号の誤差を求め、これが小さくなるよう結合荷重を修正する。修正後の結合荷重に基づいて同じ過程を繰り返し、出力値が教師信号にできるだけ近づくような結合荷重を最終的に求める。このアルゴリズムでは、入力信号が順方向へ伝播するのに対して、結合荷重の修正が信号の伝達方向とは逆方向に向けて行われるため、誤差逆伝播法と呼ばれる。

一般に、隠れ層の多層化やユニット数の増加によって、学習データ内での当てはまりが向上することが知られているが、得られた結合荷重が学習データ以外に対しどの程度汎用性をもっているかは別途確認する必要がある。この汎用性の程度をニューラルネットワークの汎化能力という。<sup>12)</sup> 汎化能力は、与件として与えられるニューラルネット

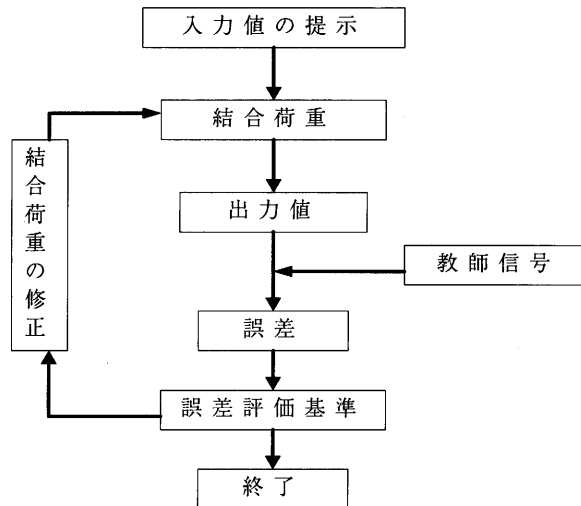
10) 教師なし学習の代表例としてはコホーネンの自己組織化アルゴリズムが挙げられる。同アルゴリズムでは、入力信号の統計的性質がニューラルネットの構造編成に利用され、学習課程でモデル内部の構造が変化していくという特徴を持つ。

11) 近年のニューラルネットワークの隆盛は、Rumelhart, et al [1986]が優れた学習法であるBP法を提案したことが契機となっている。

12) 汎化能力のチェックには、学習データの一部を学習に利用し残りを予測テストに用いる方法が考えられる。また、予測テストが学習データの選択に依存しないよう、一組だけデータを除いた学習による予測テストを全組について行う leave-one-out 実験などが用いられている。



図表6 BP法のアルゴリズム



の階層構造と強く関連している。シグモイド関数のように非線型動作をするユニットを高度に組み合わせれば、線型の回帰分析に比べ極めて優れたフィットが得られる。それゆえ、学習を丁寧に行い過ぎると、本来求めたい因果関係のみならずデータに含まれる誤差まで学習してしまうという問題が生じる。これを過学習という。汎化能力が高いニューラルネットを得るには最適な階層構造を選択する必要があるほか、学習法の選択や、シグモイド関数の非線型性、誤差関数の収束基準など学習過程に関する調整が求められる。<sup>13)</sup>

### 3. 中央銀行の政策判断への応用

本節では、ニューラルネットワークを中央銀行の政策判断へ応用するにあたっての基本的な考え方を示す。最初に、中央銀行の政策判断を分析した先行研究のうち代表的なアプローチを解説し、その問題点を指摘するとともにニューラルネットワークの利点を述べる。

#### (1) 先行研究の展望

中央銀行の政策判断を客観的に実証する方法としては、政策反応（目標）関数を推計

13) 階層構造の選択に AIC などの情報量基準を利用する試みがある。時系列分析で頻繁に利用される AIC は最尤推定法に基づく情報量基準であり、BP 法と必ずしも整合的ではないが、実用的有効性がいくつかの実例で確認されている。

するのがふつうである。政策反応関数の推計には、短期金利のような変数を政策目標に直接回帰させる方法（回帰モデル・アプローチ）と、公定歩合の変更のような政策スタンスの変更を定性的に捉え、離散選択モデルで推計する方法の二つのタイプが有力である。以下では、両者の手法と問題点を簡単に説明する。

政策反応関数の最もナイーブな推計法は、短期金利をインフレ率や GDP の伸び率といった複数の政策目標に回帰し、係数の符号や有意性、大きさについて解釈するタイプである。一本の回帰式による推計は簡便な方法だが、説明変数であるインフレ率等はマクロ経済全体の動向によって決定される内生変数である。このため、政策反応関数の背後には政策変数から政策目標へ影響が波及するマクロ構造が隠れており、推計結果のパラメーターが直ちに中央銀行の政策反応関数に対応しているとは解釈できない。こうした問題を解決するための一つの方法としては、マクロ経済モデルに中央銀行の目標関数を組み込み、中央銀行がマクロ構造の制約下で目標関数の現在価値の最大化を図っていると考えるアプローチがある。<sup>14)</sup>

次に、離散選択モデルを用いた手法を紹介する。短期金利のように連続して変化する変数に対して、公定歩合操作のように引き上げ・引き下げ・据置といった定性的変化に大きな意味があるものを扱う手法が離散選択モデル（質的選択モデル）である。<sup>15)</sup> 離散選択モデルを用いた分析では、中央銀行は観察された政策目標をシグナルとして政策変数の選択を行うと考える。政策変数に公定歩合を用いる利点として政策変数の外生性が仮定できる点が挙げられる。

金利水準を説明変数に回帰するモデルは、引き締め局面と緩和局面における同一の金利水準を無差別に取り扱ったり、高度成長期の景気のボトムにおける金利水準と安定成長期の景気ピーク時の金利水準を判別できないという問題を抱えている。金融引き締め・緩和の方向性だけに注目した離散選択モデルでは、この問題を避けることができるが、逆に水準に関する情報を捨象している。引き締め局面初期における低水準金利からの引き上げと、引き締め局面最終期の比較的高金利水準からの引き上げは意味合いが異なるし、一回の引き上げでどの水準まで公定歩合を上昇させるかは重要な情報である。この他、金利の階差を回帰する手法が考えられるが、この場合政策変更の方向とその変化幅の情報は含まれるものの足許の水準に含まれる情報が捨象される。いずれにせよ、被説明変数を一つとする伝統的な計量経済学的手法では、この問題は同時に解消できない。本論文で用いたニューラルネットワークモデルは、このような制約がないため公定歩合政策の時期、方向、変化幅とその結果決まる水準をすべて考察できる利点を持つ。

14) 吉野・義村[1993]は、実体経済部門を外生とし貨幣需給の制約下で中央銀行の損失関数を最小化する方法を採っている。一方、Broadbent and Barro[1995]ではマクロの総需要・総供給関数が加えられ、実体経済部門を含めたマクロ構造下での最適化が考察されている。

15) 浅子・加納[1989]、渡辺[1995]が同モデルを日本の金融政策に応用している。

また、4節でみるように、景気循環における上昇・下降局面や金融政策の引き締め・緩和局面には非対称性が存在するが、線型の回帰モデルではこうした問題に対応できない。前述したようにニューラルネットワークは非線型問題の扱いに優れており、本論文では、中央銀行が直面している経済環境として経済の状態だけでなく変化の方向（加速度）も加味し、金融政策の非対称性について分析を試みた。

最後に、経済理論モデルとの本質的な相違点を挙げよう。回帰モデルで現在主流となっているアプローチは、中央銀行が自らの目的関数の現在価値を最大化するよう政策決定を行うという手法であるが、理論モデルでは経済主体が無限の視野をもって合理的に行動する仮定を前提とするものが多い。しかし、中央銀行がマクロ経済へ与える影響を完全に把握したうえで、景気循環のスパンを遥かに越えた将来を見通して合理的に行動しているというモデルが中央銀行の意思決定を近似するモデルとして妥当かどうかは疑問である。本論文では、中央銀行は経済に関する知識と収集した情報を基に、限られた情報処理能力と時間の制約の下で探索的に政策決定を行っているという立場をとる。ニューラルネットワークは、こうした意思決定における合理性の限界に対応するアプローチとして有用なモデルとして注目されている。<sup>16)</sup>

## (2) 政策判断への応用

ここでは、中央銀行の行動を経済情勢の認識と政策決定という二つのステージで捉え、ニューラルネットワークの応用を考える。

第一段階においては、まず、中央銀行は経済がどのような状態にあるかを認識するため、数値化されたデータや記述された情報を観察もしくは自ら作成することによって収集する。次に、中央銀行は、経済構造や経済変動の原理に関するマクロ経済の知識と、企業・家計の行動原理や各産業界の事情に関するミクロ的な知識を基に、収集した様々な一次情報から経済情勢を認識しようと試みる。この過程では、断片的な一次情報は抽象化された概念に変換される。例えば、「経済は景気回復局面にある」「企業マインドは好転している」「物価上昇圧力が強まっている」等の表現は中央銀行の公式ステートメントにしばしば見かけられる。中央銀行は、こうした経済情勢のある側面を捉える概念を事前を持っており、現状の経済がどのパターンにあたるのかを検討している。これ

---

16) 「限定された合理性」(bounded rationality)は、Simon[1957]によって提唱された概念である。サイモンは合理性を限定する要素をいくつか指摘しているが、このうち、(1)合理的な判断の前提条件である「世界の状態」(state of world)の完全な把握が不可能なこと、(2)非常に複雑な「世界の状態」を完全に捕捉できても、最適な選択を求めるには計算能力が不足していること、が関連する。すなわち、前者は、中央銀行が経済の構造と現在の状態を完全に把握することはできないこと、後者は、これに成功したとしても政策効果があらゆる方面に及ぼす影響を正確に予測できないことに相当する。

は、一次情報の特徴を分析することによる概念への変換であり、パターン認識と呼べよう。また、既存のパターンでは捉えきれない現象に直面した場合には、新たな概念が形成、記憶され、以降の経済情勢の認識に生かされる。例えば、戦後以降1970年代初頭まで日本経済は急激なインフレ進行とマイナスの経済成長が共存する状況を知らなかった。こうした状況は「スタグフレーション」と命名され、このような経済情勢が存在しうることが認知されるようになった。また、1980年代末には一般物価が比較的安定している下で資産価格の急激な上昇を経験したが、これも既存の物価動向を捉える概念にはなかったものである。いわゆる「経済情勢の総合判断」は、上記のようなパターン認識過程を指すものと考えられよう。

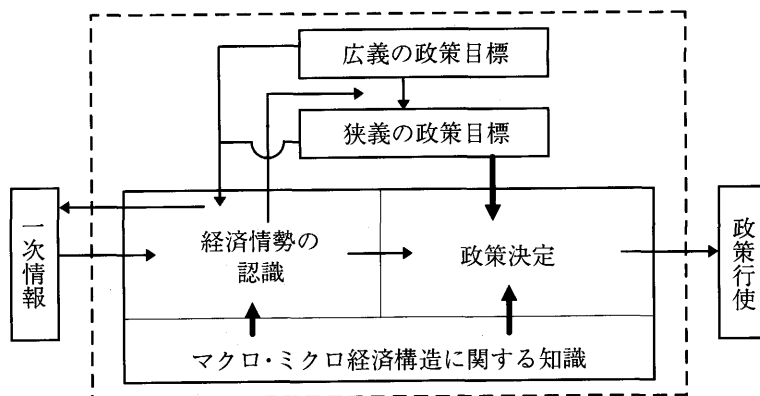
第二段階は、認識された経済情勢に対して政策対応が決定される過程である。この政策決定プロセスでは、どのような経済情勢をより望ましいと考えるかという中央銀行の選好が存在することが前提となる。中央銀行は、政策の種々の選択肢について、実行した場合に現在の経済情勢がどのような方向に向かうかについて何らかの知識を有しており、その選好に沿うような結果をもたらす政策が選択されるのである。こうした考え方に立てば、望ましい経済情勢を概念として表現したものが広義の政策目標であり、定量化可能な具体的指標として表現したものが狭義の政策目標とみなすことができよう。「通貨価値の安定」という広義の政策目標に対応して、例えば「消費者物価指数の上昇率を1～3%内に抑える」という狭義の政策目標が考えられる。狭義の政策目標は時々の経済環境に応じて変化するため、その決定は第一段階での経済情勢認識に係わってくる。例えば、同じ広義政策目標でも高度成長期と安定成長期では異なった狭義政策目標を指すことがありうる。

判断情報の処理プロセスは経済情勢の認識から政策決定へと一方向に進むのではなく、逆方向へのフィードバックも働く。どの様な観点で経済情勢を捉えるかは、政策目標の決定によって影響され、収集すべき一次情報の選択へも波及する。<sup>17)</sup> 以上の過程を模式図として示すと図表7のようになる。

本論文の実証分析では、上記のような中央銀行の政策決定過程分析への第一次的接近として経済情勢の認識にあたる第一段階を捨象したアプローチを採る。すなわち、分析では政策目標として経済成長とインフレを考察するが、目標達成にあたり中央銀行が利用する情報を政策目標の現在値に限定する。

17) 中央銀行の目標もまた、経済環境の長期的な変化に応じて変遷する可能性がある。

図表7 政策決定過程の模式図



#### 4. 実証分析

本節では、1960年代以降の日本銀行の政策行動パターンをニューラルネットワークに学習させ、ニューラルネットワークが関数としてどのような特性をもつか、また、各経済環境にどのように対応するかを計測することにより、日本銀行の政策行動を分析する。まず、分析に用いたデータの解説を行った後、ニューラルネットワークの学習精度を示し、次に1980年代以降の金融政策を考察する。なお、モデルの解説と学習手法の詳細は補論2に示し、ここでは結果のみを記す。

##### (1) データの選定

金融政策の基本的なスタンスを示す公定歩合操作を分析対象とする。このほかにも日本銀行が直接操作可能な政策変数として短期金融市場金利があるが、ここで扱った経済成長とインフレという政策目標が主に金利変動の中長期的趨勢に影響されるものであることや、公定歩合変更が政策スタンスのベーシックなシグナルであったことから公定歩合のみを考察する。<sup>18)</sup> 図表8は公定歩合が変更された時期と変更前後の水準である。同表より、まず質的データ  $d_{it}$  を構築する。一般に、公定歩合政策の発動は、緩和・引き締め政策が採られた場合に注目されるが、公定歩合を据え置いたことにも日本銀行の判断が反映されている。そこで、当該四半期に公定歩合の引き上げがあった場合を

18) 例えば、為替レートや株価を政策目標として考察する場合には、短期金融市場における日次や月次単位での金融政策が重要となる。

金融研究

図表8 公定歩合政策

年 月 日	公定歩合	変更幅	年 月 日	公定歩合	変更幅
55 Aug 10	5.84 → 7.3	1.46	75 Jun 7	8.5 → 8	-0.5
57 Mar 20	7.3 → 7.67	0.37	75 Aug 13	8 → 7.5	-0.5
57 May 8	7.67 → 8.4	0.73	75 Oct 24	7.5 → 6.5	-1
58 Jun 18	8.4 → 7.67	-0.73	77 Mar 12	6.5 → 6	-0.5
58 Sep 5	7.67 → 7.3	-0.37	77 Apr 19	6 → 5	-1
59 Feb 19	7.3 → 6.94	-0.36	77 Sep 5	5 → 4.25	-0.75
59 Dec 2	6.94 → 7.3	0.36	78 Mar 16	4.25 → 3.5	-0.75
60 Oct 24	7.3 → 6.94	-0.36	79 Apr 17	3.5 → 4.25	0.75
61 Jan 26	6.94 → 6.57	-0.37	79 Jul 24	4.25 → 5.25	1
61 Jul 22	6.57 → 6.94	0.37	79 Nov 2	5.25 → 6.25	1
61 Sep 29	6.94 → 7.3	0.36	80 Feb 19	6.25 → 7.25	1
62 Oct 27	7.3 → 6.94	-0.36	80 Mar 19	7.25 → 9	1.75
62 Nov 27	6.94 → 6.57	-0.37	80 Aug 20	9 → 8.25	-0.75
63 Mar 20	6.57 → 6.12	-0.45	80 Nov 6	8.25 → 7.25	-1
63 Apr 20	6.12 → 5.84	-0.28	81 Mar 18	7.25 → 6.25	-1
64 Mar 18	5.84 → 6.57	0.73	81 Dec 11	6.25 → 5.5	-0.75
65 Jan 9	6.57 → 6.21	-0.36	83 Oct 22	5.5 → 5	-0.5
65 Apr 3	6.21 → 5.84	-0.37	86 Jan 30	5 → 4.5	-0.5
65 Jun 26	5.84 → 5.48	-0.36	86 Mar 10	4.5 → 4	-0.5
67 Sep 1	5.48 → 5.84	0.36	86 Apr 21	4 → 3.5	-0.5
68 Jan 6	5.84 → 6.21	0.37	86 Nov 1	3.5 → 3	-0.5
68 Aug 7	6.21 → 5.84	-0.37	87 Feb 23	3 → 2.5	-0.5
69 Sep 1	5.84 → 6.25	0.41	89 May 31	2.5 → 3.25	0.75
70 Oct 28	6.25 → 6	-0.25	89 Oct 11	3.25 → 3.75	0.5
71 Jan 20	6 → 5.75	-0.25	89 Dec 25	3.75 → 4.25	0.5
71 May 8	5.75 → 5.5	-0.25	90 Mar 20	4.25 → 5.25	1
71 Jul 28	5.5 → 5.25	-0.25	90 Aug 30	5.25 → 6	0.75
71 Dec 29	5.25 → 4.75	-0.5	91 Jul 1	6 → 5.5	-0.5
72 Jun 24	4.75 → 4.25	-0.5	91 Nov 14	5.5 → 5	-0.5
73 Apr 2	4.25 → 5	0.75	91 Dec 30	5 → 4.5	-0.5
73 May 30	5 → 5.5	0.5	92 Apr 1	4.5 → 3.75	-0.75
73 Jul 2	5.5 → 6	0.5	92 Jul 27	3.75 → 3.25	-0.5
73 Aug 29	6 → 7	1	93 Feb 4	3.25 → 2.5	-0.75
73 Dec 22	7 → 9	2	93 Sep 21	2.5 → 1.75	-0.75
75 Apr 16	9 → 8.5	-0.5	95 Apr 14	1.75 → 1	-0.75


(注) 1969年9月に年利建て表示に移行。それ以前は日歩建て表示の年利換算値。

$d_{it}=0.5$ 、引き下げがあった場合を  $d_{it}=-0.5$ 、据え置いた場合を  $d_{it}=0$  とし、四半期データを作成した。また、四半期末の公定歩合の水準を量的データ  $d_{2t}$  とし、二つのタイプのデータを扱うことにより3節で指摘した水準と方向性の問題の解決を図った。


次に、日本銀行が直面する経済情勢としてCPIで測ったインフレ率と実質GDPの成長率を用いる。<sup>19)</sup> 両変数を軸とした平面上に  $d_{it}$ 、 $d_{2t}$  をプロットしたものが図表9である。静学的に考えれば、成長率とインフレ率がともに低ければ緩和、逆ならば引き締めとなるから、図表9-1の右上方では引き締め、左下方では緩和政策が取られ、その結果、図表9-2では右上方ほど高い公定歩合水準を示すはずである。ところが、そのような関係は読み取れない。そこで、時系列でみた政策対応を4サンプル期間に分割してみたものが図表10である。図表10-1, 2は、第一次・二次石油危機、図表10-3は円高不況、図表10-4は平成景気前後の政策対応を示している。最初の2サンプルは金融緩和から始まり、景気が持ち直すにつれ据え置きに転じている。第一次石油危機は景気が過熱したところへの外生ショックであったため急激なインフレが進行し、これに対応するため3四半期の間に5回計4.75%の引き上げがなされている。景気は急速に後退しマイナス成長に落ち込んだが高金利政策は継続され、インフレ率が低下傾向を見せ初めてようやく緩和政策に転じ、その後成長率が5%近傍へ回復するまで引き下げが続いている。一方、第二次石油危機では早めの引き締め対応が採られ、成長率の低下が顕著になる頃にはインフレが沈静化に向かっていったため、最後の引き締めから1四半期おいて緩和に転じたが、成長率が4%に届かぬうちに公定歩合は据え置かれている。次の円高不況期は、4サンプル期間のうち唯一反時計周りに回転していない。これは、好況期においてインフレ圧力が高まっていなかったこと、デフレを伴うショックであったことによる。成長率の急速な低下に対応して引き下げが行われ、景気の反転とともに据え置きに戻っている。続く平成景気では、前2回の引き上げ局面が成長率の低下を伴っていたのに対し、引き締め期間中は成長率の急速な低下は観察されず、景気後退の始まりとはほぼ前後して緩和政策へ転換している点が異なる。図表11は、景気のピーク・ボトムと政策の転換点のラグを示したものである。景気がピークを越えてから緩和政策が開始されるまでの期間は、残存するインフレ圧力や景気後退の速度などに応じて様々な長さを取っている。また、引き締め開始からピークへ到る期間も循環局面毎に異なっており、予防的引き締め措置が取られた平成景気では、引き締め局面下での好景気が2年近く続いている。景気がボトムを打ってから引き下げが据え置きに転じるまでの期間も、景気の立ち上がりの速度などに影響されている。例えば、円高不況からの急激な回復過程では3カ月と最

19) 日本銀行は両変数の水準を重視しており、最適な成長経路もしくは潜在成長力に沿った経路からの乖離に注目していると考えられる。

図表9-1 公定歩合政策と成長・インフレ率

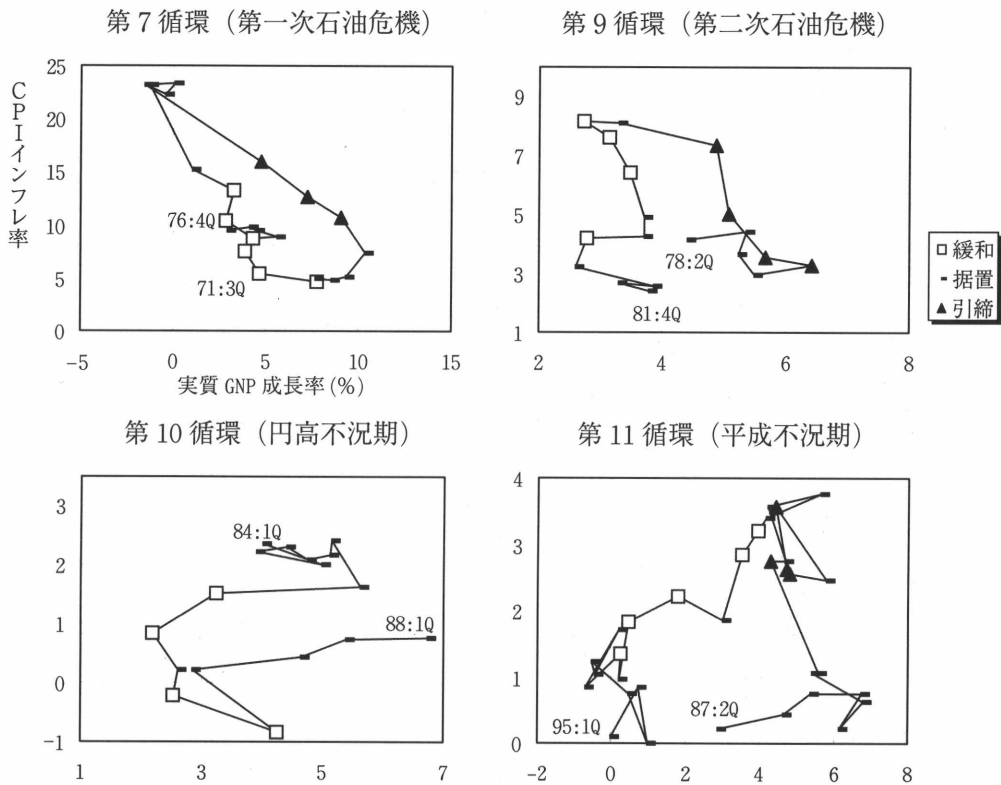


図表9-2 公定歩合の水準



(注) サンプル期間はともに1971:1Qから1995:1Q

図10 景気循環局面での政策変更





図表 11 景気のピーク・ボトムと政策転換点 (月次)

	ボトムから最終引下げまで			引き締め開始からピークまで			ピークから緩和開始まで	
	ボトム	最終引下げ	期間	引き締め開始	ピーク	期間	引下げ開始	期間
第7循環	71:12	72: 6	6か月	73: 4	73:11	7か月	75: 4	17か月
第8循環	75: 3	75:10	7か月	-	77: 1	-	77: 3	2か月
第9循環	77:10	78: 3	5か月	79: 4	80: 2	10か月	80: 8	6か月
第10循環	83: 2	83:10	8か月	-	85: 6	-	86: 1	7か月
第11循環	86:11	87: 2	3か月	89: 5	91: 4	23か月	91: 7	3か月
第12循環	93:10	(95: 9)	(23)					

も短くなっている。<sup>20)</sup>

以上簡単に四つの局面をみたが、いずれにおいても金融政策は機械的には発動されず、その時々「総合判断」に基づいて発動されているようにみえる。

## (2) 分析結果

日本銀行が直面している経済環境をCPIインフレ率 $\pi_t$ 、と実質GNP成長率 $y_t$ 、及び両変数の階差値 $\Delta \pi_t$ 、 $\Delta y_t$ で表す。階差値を利用するのは、上でみたように足許の経済変動の方向性が政策決定に重要な役割を果たすためである。公定歩合政策は、質的データ(公定歩合の変化方向) $d_{it}$ 、量的データ(公定歩合水準) $d_{2t}$ で表現する。<sup>21)</sup>ここでは日本銀行を4変数の観察値に対して2変数の反応を返す主体とみなす。<sup>22)</sup>


学習にあたってはサンプル期間を3分割し、1960年第1四半期から1970年第3四半期、同年第4四半期から1981年第4四半期、1982年第1四半期から1995年第1四半期とした。これは高度成長期と高インフレ期・安定成長期では日本銀行が指向する最適な経済状態が変化している可能性を考慮したためである。各期間ごとにニューラルネットワークの学習を行い、最終的に得られた結合荷重に基づきインサンプルでの精度をみたものが図表12である。経済情勢を表すのに用いた情報が成長とインフレに関する2系列のデータしかないにも拘わらず、公定歩合操作のタイミングやその水準 $d_{2t}$ がかなり高い精度で求められている。

20) 景気のピーク・ボトムは事後的にしか判別しない。従って、ピーク・ボトムと政策転換期のずれは、政策行使ラグも含んでいることになるが、循環局面毎の大幅な相違は上述の要因によるところが大きい。

21) 分析にあたって、入力4変数は0から1までの値をとるよう変換しており、0が最小値、1が最大値を表す。なお $\pi_t$ と $y_t$ には原計数前年比の3期移動平均値を用いている。出力値 $d_{2t}$ は原計数を-0.5から0.5までの値を取るよう変換している。変換(スケーリング)の方法と必要性については補論2参照。

22) ここで中央銀行の意思決定過程はブラックボックスとなっているが、中央銀行内部での情報処理過程を分析したい場合は3節の模式図表7で解説したような多段階型モデルを用いればよい。

図表 12 公定歩合政策の推計



(注) シャド一部が実現値、実線が  $d_{1t}$   $d_{2t}$  の推計値。

図表 13-1 公定歩合操作の予測精度

	サンプル数	正答数	正答率	誤答の選択		
				据置	引き上げ	引き下げ
合計	141	119	84%			
引き上げ	16	15	94%	1	-	-
引き下げ	36	35	97%	1	-	-
据え置き	89	78	88%	-	4	7

図表 13-2 同期間別


	1960:1Q~70:3Q		1970:4Q~81:4Q		1982:1Q~95:1Q	
	サンプル数	誤答数	サンプル数	誤答数	サンプル数	誤答数
合計	43	4	45	5	53	4
引き上げ	5	0	7	0	4	1
引き下げ	8	0	17	1	11	0
据え置き	30	4	21	4	38	3

公定歩合操作の方向を表す  $d_{it}$  について、分布範囲-0.5~0.5を3等分割し、推計値が域内に入った場合を正解とした結果を図表13に示した（実際の分布状況は図表14）。この評価方法では、引き上げ・下げの場合9割を超す正答率が得られている。据え置き措置の正答率は9割をやや下回るが、これは、引き締め・緩和局面では過去の政策効果をみながら段階的に公定歩合が変更されるため、その間の据え置き期間を誤答する傾向がみられたためである。特に緩和局面でその傾向が強いため、据え置きを引き下げと誤答するケースがあった。<sup>23)</sup>

公定歩合水準  $d_{it}$  の予測誤差の分布を図表15に、基礎統計量を図表16に示した。誤差の標準偏差は全サンプル期間で0.3%弱である。期間別に見ると1960年代が0.14%と最も精度が高くなっている。誤差項に統計的仮定を用いていないにも拘わらず、いずれの期間でも平均はほぼゼロとなっている。また、直近のサンプル期間以外の予測誤差は、歪度、尖度ともゼロからの乖離が概ね小さく、正規分布に近い分布をしていることがわかる。

次に、学習したニューラルネットワークが関数形としてどのような特性を持っているかを観察し、その形状から各時点における日本銀行の意思決定パターンを把握しよう。直近のサンプル期間を学習したニューラルネットワークについてみてみよう。<sup>24)</sup>

図表 14 公定歩合操作の予測分布（全期間計）




(注) 分布頻度は0.05刻み。表示値-0.5は-0.5から-0.45の範囲を示す。

23) この点に対する一つの対応策として、まず公定歩合操作の方向のみを学習させ、次に変更幅を学習させるという2段階アプローチも考えられる。補論2(3)参照。

24) 直近のサンプル期間を選択した理由は、図表17に示した関数曲面の形状が固定した階差値に比較的依存しておらず観察が容易であったことによる。他のサンプル期間は階差値が平均値から乖離した場合、フィットのズレが非常に大きくなり、 $\Delta y_t$ 、 $\Delta \pi_t$ を固定した $d_{2t}$ 、 $y_t$ 、 $\pi_t$ の3次元空間で関数を表現することが困難であった。

図表15 公定歩合予測水準誤差の分布 (全期間計)



(注) 分布頻度は0.05刻み。表示値0は0から0.05の範囲を示す。


図表 16 公定歩合水準予測誤差 (単位%)

	全サンプル	1960:1Q~70:3Q	1970:4Q~81:4Q	1982:1Q~95:1Q
平均	$-7.1 \times 10^{-5}$	$1.2 \times 10^{-3}$	$-6.9 \times 10^{-3}$	$-4.6 \times 10^{-3}$
標準偏差	0.29	0.14	0.39	0.31
最大値	0.87	0.30	0.87	0.67
最小値	-1.13	-0.32	-0.71	-1.13
歪度	-0.15	-0.22	0.42	-0.96
尖度	2.13	0.61	0.25	2.60

図表17は、インフレ率 $\pi_t$ と実質成長率 $y_t$ に対してニューラルネットワークの関数の全体の形状を示したものである ( $y_t$  <real GNP growth rate>と $\pi_t$  <CPI inflation>は0と1の間をとるようスケーリングしてある)。インフレ率と成長率の加速度を表す階差値 $\Delta \pi_t$ 、 $\Delta y_t$ はサンプル期間中の平均値で固定してあるため、図中にプロットした実際の公定歩合水準と関数曲面間には若干乖離が生じているが、曲面の形状は3変数の関係をだまかに捕捉している。この関数曲面から、1980年代以降の公定歩合水準は全体としてみればインフレ率に比例するよう変動していることが読みとれる。もっともインフレ率と公定歩合水準は単純に線型比例しているのではなく、インフレ率が高水準から低水準へ(あるいはその逆)移動する時期に公定歩合水準の変化幅が大きくなるようなS字型の非線型関係になっている。また、曲面手前の部分はインフレ率と実質成長率の両者に比例する形状になっており、特に1991年からの景気後退局面では成長率の低下が公定歩合水準の低下に強く寄与していることがわかる。

実際に公定歩合政策の意思決定を下すにあたっては、このような曲面が明示的にイ

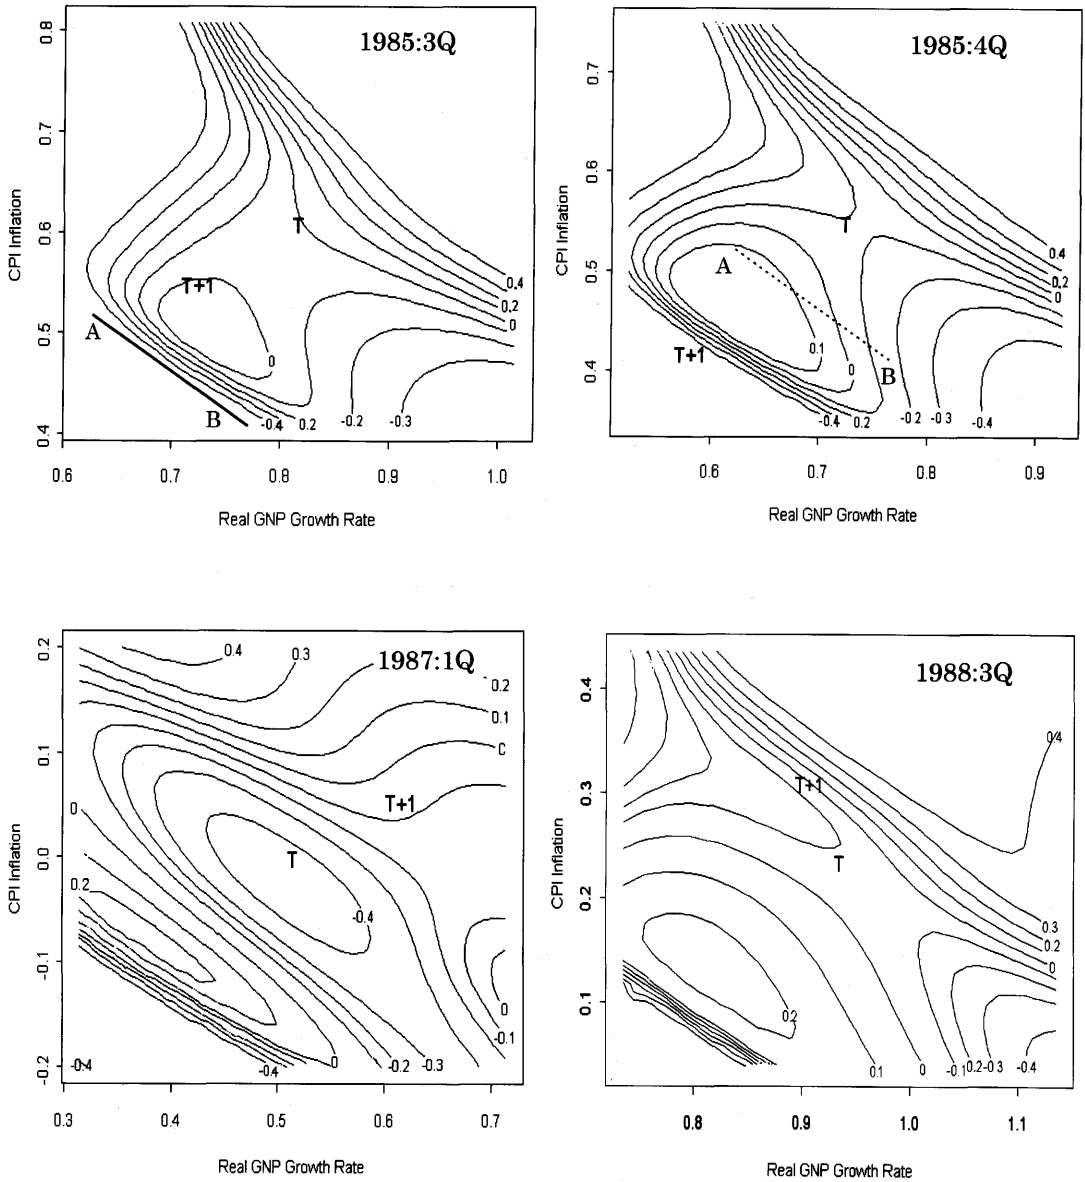
図表17 インフレ・実質成長率と公定歩合水準



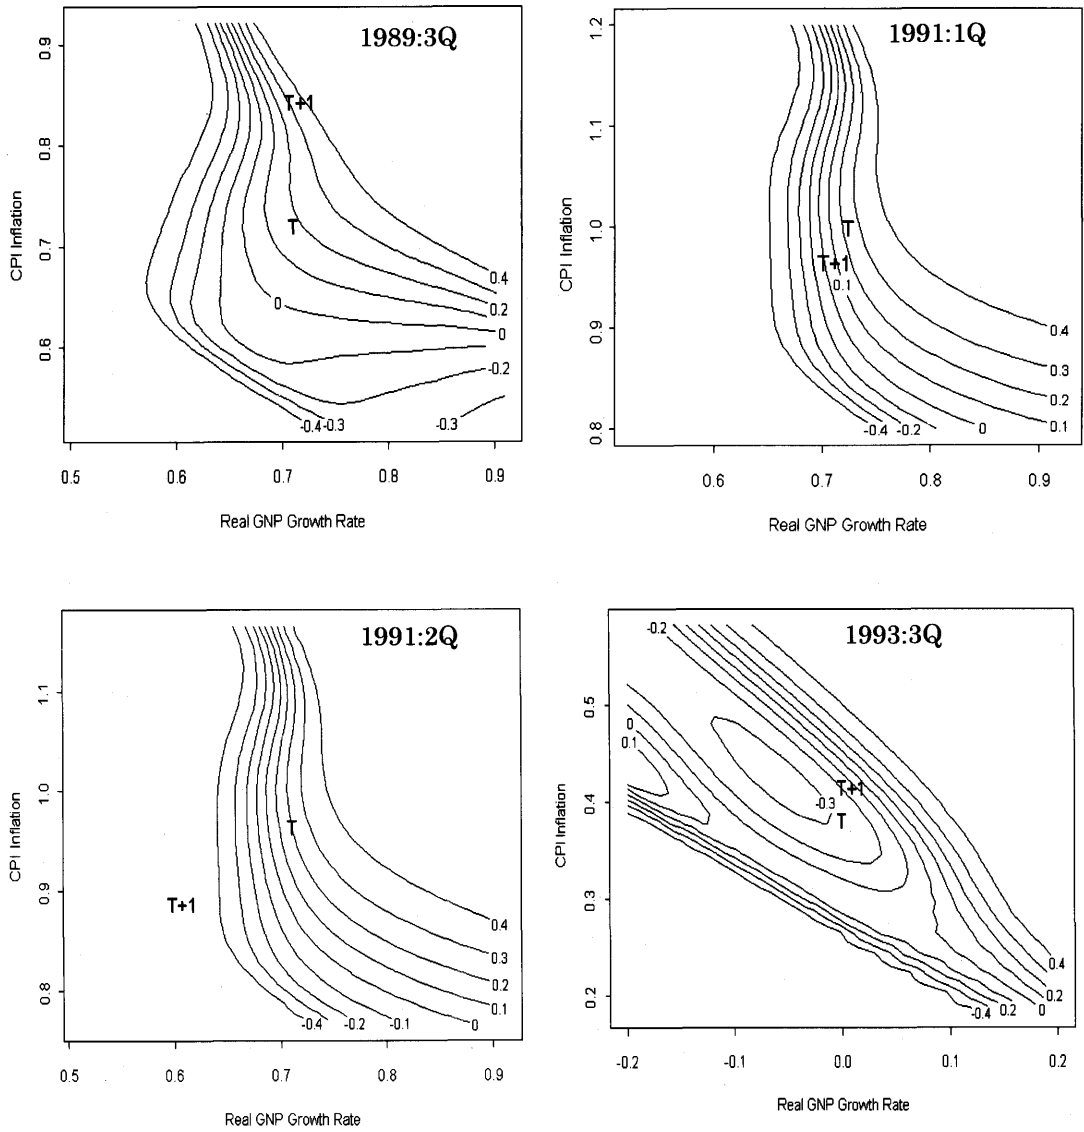
メージされているわけではなく、「今、公定歩合を上げる（下げる）か据え置くか」、また「上げる（下げる）なら何%幅か」という観点から検討がなされると考えられる。そこで、公定歩合操作の方向を示す  $d_{it}$  を各時点毎にみてみよう。図表18上段は、景気がピークを越えた直後の1985年第3、4 四半期の様子である。第3 四半期では、経済はTで示した地点 ( $y_t=0.82, \pi_t=0.61$ ) に位置している。等高線 ( $d_{it+1}$ ) の形状は、翌T+1期の状況（2変数  $y_{t+1}, \pi_{t+1}$  の水準）に応じてT+1期時点でどのような政策が採られるかを示したものである。T+1で示した点が実現値であり、このとき  $d_{it+1}$  はゼロ、すなわち据え置き政策が採られることを意味している。<sup>25)</sup> インフレ率や実質成長率の低下幅がもう一段大きかった場合には、 $d_{it+1}$  は急速に減少しており引き下げの可能性が高まることを示唆している。従って、等高線が左下方に向けて突出した密な部分（線 AB）は、デフレショックに対する公定歩合引き下げの臨界値と解釈することができよう。一

25) T地点の  $d_{it+1}$  の値は、T期における公定歩合変化の方向ではなく、翌期にかけて変化がなかった場合の値を示している。 $d_{it}$  は、T-1期とT期の変化量およびT期の水準値より求まる。

図表18 公定歩合の変化方向



図表18 公定歩合の変化方向（続き）



方、第4四半期では、翌年第1四半期に臨界値を越えた低下が生じたため引き下げが実施されている。点線 AB は第3四半期の線 AB の位置を示したものであるが、この線上では引き下げのサインは出ていない。これは、公定歩合変更のきっかけはインフレ率や実質成長率の水準のみではなく、足許の変化の大きさ（景気循環の加速度）も重要な要素になっていることを示唆している。大きいショックや急激な景気の方角転換は認知されやすく政策対応も早い、漸進的な変化が積み重なった場合、集計した変化幅が同じになっても政策対応は遅れがちになると考えられよう。

以下、景気循環の特徴的な局面を順にみてみよう（時系列変動は図表10、図表17参照）。1987年第1四半期は、円高不況期の緩和政策から据え置き政策に転じた時期である。1987:1Q 図からは、翌期よりインフレ率の若干の上昇を伴った本格的な回復過程に入っている様子が窺える。図中には引き上げを示す範囲はほとんどなく、特に T で示した点より右側では実質成長率の上昇に対して非感応的になっていることが判る。<sup>26)</sup> この後、実質成長率の上昇が続き、好況下でインフレ率も徐々に上昇する傾向をみせ始めていたが、インフレ率の水準が依然低かったため据え置き政策が継続されている（1988:3Q 図）。関数の形状より公定歩合引き上げの余地が広まってきたことがわかる。次の1989:3Q 図は、引き締め政策へ転換した時点の様子を表している。インフレ進行の加速度が増したことが政策転換の契機となっていることが読みとれる。また、1988:3Q 図に比べて据え置き政策を示す範囲が狭くなり、公定歩合政策が経済変動に対して感応的になっていることを示している。次の2図は1991年第3四半期に緩和政策が採られる直前の様子を表している。1991:1Q 図では、据え置きのエリアが一段と狭く、かつ等高線が垂直に変化しており、実質成長率の変動にセンシティブになっている様子が窺える。1991:2Q 図にみられるように景気後退とともに左下方へ向かい、段階的な緩和政策が採られている。次図は1993年第3四半期の最終緩和直後の状況を示している。据え置きを示す範囲が広がり始めており、等高線の傾きも垂直から右下がりへ戻っている。サンプル期末にかけての据え置き措置は実際の経済が据え置きのエリアを右下方向へ移動するなかで採られている。

## 5. 終わりに

本論文では、インフレと経済成長に対する中央銀行の反応をニューラルネットワークにより分析した。日本銀行を対象とした実証分析では、非線型動作の分析に優れたニューラルネットワークの特性が発揮され、僅かな情報量で高い学習精度が得られたほ

26) T地点の下方、特に左下方ではやや解釈が難しくなっている。これは、縦軸目盛りが示すように、当期がサンプル期間中のインフレ率のほぼ最低点であり、教師データによる学習がなされていないことによると思われる。



か、景気変動下の様々な経済局面に対応する政策行動の複雑さが捉えられた。すなわち、公定歩合水準とインフレ率、実質成長率は単純な比例関係ではなく非線型の関係にあること、また、公定歩合操作には足許のインフレ率、実質成長率の水準に加え、経済の変化方向とその加速度が重要であること、インフレ率と実質成長率に対する感応性は時期によって大きく異なることなどが観察された。

本論文では、中央銀行の経済情勢認識と政策決定を分離して取り扱わなかったため、内部の意思決定過程はブラックボックスのままとなっているが、両者を個別に分析すれば意志決定過程を明示的に扱うことができる。しかし、経済情勢に関する中央銀行のステートメントは抽象化された概念として語られることが多く、各種統計値など一次情報との対応には曖昧さや解釈の余地が残る。こうした人間の判断や推論にともなう曖昧さを扱う有用な手法としてファジー理論が挙げられる。近年は、ファジー理論にニューラルネットワークの学習能力の高さを組み合わせたハイブリッドモデルの応用が盛んになっており、こうした手法の適用が今後の課題の一つとして考えられる。

本論文で紹介したニューラルネットワークは、経済主体の合理性の限界に着目したアプローチでもある。近代経済学の礎である合理的経済主体の仮説に対する批判は古くからあり、実験経済学や経済心理学の発展により様々な仮説が挙げられている。確かに、埋没費用効果や機会費用効果<sup>27)</sup>、準拠点効果<sup>28)</sup>、代表性効果<sup>29)</sup>などの仮説は、現実に観察される不合理な行動の一部を指摘している。こうした点を考慮すると、本論文で試みたような認知科学や情報工学などの関連分野からのアプローチは、経済理論からのアプローチを補完するものとして大いに有効である可能性が指摘できよう。

## 補論 1. ニューラルネットワークの応用事例と開発ツール

### (1) 主な応用分野と金融関連での応用事例

1980年代にはBP法やさらに優れた学習アルゴリズムが登場し、多分野への応用が急速に進展した(図表A-1)。文字認識(OCR)や機械翻訳など人間の情報処理を代替するシステムは早くから実用化され、既にパソコン上で動くソフトとして市販されている。また、産業界においても、専門家の知識やノウハウをルール化したエキスパートシステムなどに、If, then型のルールでは表現できないような勘や経験を取り込む手法とし

27) 自ら支出する金銭的な費用は同じ大きさの機会費用よりも過大評価される効果。

28) 個人の効用は消費量の絶対額ではなくある準拠点を基礎に評価される効果。例えば昨年の消費額80から今年に90になったほうが100から90になった場合より効用が高い。

29) 予測や可能性を判断するとき、情報を均等に評価せず一部のサンプルを代表例として受け取りやすい効果。例えば、ある個人投資家は身近な人の失敗事例を他の市場参加者各々の収益率より重視するかもしれない。

図表 A-1 ニューラルネットワークの応用分野

<p>生体の情報処理の模倣 文字認識、顔認識、音声認識・合成、話し手識別、機械翻訳、味覚判別、感情認識等</p>
<p>応用分野による分類 家電製品、各種ファクトリーオートメーション、ポートフォリオ運用支援、診断システム（企業診断、医療診断、融資診断）、製品市場需要予測、交通機関自動運行システム、気象予測、地震予測、資源探索、ゲームの戦術学習、航空最適経路選択、データベース検索、ひらがなの漢字変換等</p>

図表 A-2 金融関連の開発事例

企業名	概要	開発段階	稼働環境	その他
日興証券	債券格付けシステム「BRAINZ」。学習後のネットを解析して格付けの背景を説明。	92年9月から運用(予定)	パソコン	富士通との共同開発
	東証株価指数のリターン予測。1カ月以上の長期的な売買が対象。現在はファンドの運用アドバイスに利用。	91年2月から運用	ワークステーション	同上
大和証券	株式売買システム「NEURO-PORT」。株式相場指標を基に。株式売買のタイミングを予測。	90年3月から運用	ワークステーション	米 Nestor 社製のツールを利用
大和総研	株価予測システム。過去の株価変動パターンの学習に基づく予測。騰落率に変換して入力。	試作済み	ワークステーション	日本電気と共同開発
日本長期信託銀行	債権格付けシステム。社債未発行の企業の格付けを行う。12種の定量的データを入力。	91年5月から運用	パソコン	長銀システム開発と富士通が共同開発
	米国企業格付け予測システム。上記国内企業向けシステムがベース。財務計数を入力。	92年4月より米国で運用	パソコン	長銀システム開発と共同開発
第一勧業銀行	債権先物相場予測システム。10数項目のデータから1～5日後の相場利回りを予測。	91年始めから運用	パソコン	富士通と共同開発。富士通は製品化して販売。
	米国先物(CBT)利回り予測システム。先行き3日間の終値と上げ下げを予測。	試用段階	パソコン	富士通と共同開発

(注)日経インテリジェントシステム1992年夏号より(一部改正)。内容は出版時点のもの。表中パソコンで稼働するものは、ワークステーションやスーパーコンピュータで事前に学習したニューラルネットワークを端末機で利用するシステムを採るものが多い。

て活用されている。例えば、製鉄業では高炉操業管理システムや冷延鋼板の表面検査システムに熟練者のスキルを学習させたニューラルネットワークを利用している先がみられる。この他、金融業における開発も盛んである。

金融関連で製品化されているシステムとしては、債券格付けシステム、株価予測システム、株式売買システム、為替レート予測システム、債券先物相場予測システム、ポートフォリオ運用システム、クレジット審査等貸付評価システム、企業倒産予測モデルなどがある。やや古い事例になるが国内での開発例を図表 A-2 に示した。

このうち、第一勧業銀行の債券先物相場予測システムを簡単に紹介する。同行では、「ディーリング業務には理論かが困難な経験やひらめきに基づく判断が必要な、ロジックのはっきりしない勘の世界をサポートする新しいコンピュータ技術が要求される」<sup>A-1)</sup>として1989年10月に実用化プロジェクトを発足、91年より実用化に成功している。システムで予測するのは、先行き1～5日間の日々の上げ下げ、利回りそのもの、相場のピークボトムの時期の3種類である。入力値は、円ドル為替相場、CD 3カ月のレート、FF レート、公社債売買高、景気動向指数など10数種のデータを加工したものを用いている。評価テストでの3カ月間の予測パフォーマンスでは、上げ下げが正答率72%、ピークボトムが80%、実現値との誤差平均0.0359%と人間のディーラーに比べても良好な成績を示したと評価している。また、当初のシステムは、学習サンプルに用いた相場が現在の相場と異質である場合には正答率が低下する点、超短期予測やリアルタイム予測ができない点など問題点を抱えていた。これらの問題は次世代のシステムで改善され、相場つきを判断して最適なモデル・学習サンプルを随時構築・選択するようになり、また、学習速度の向上によって数分後の予測が可能になっている。

## (2) 開発ツール等リソース

近年インターネットの発達に伴いニューラルネットワークに関連するリソースの入手が非常に容易になってきた。例えば、Usenet Newsgroup での意見交換や ftp サイトや WWW サーバーによる研究論文、開発ツール、シュミレーターの配布が盛んに行われている。このような方法で公開される情報は、研究開発途上のものを含めて玉石混淆であり取捨選択が必要になる。図表 A-3、A-4 では、定評があるソフトウェアや情報源について現時点で利用可能なものの一部を紹介する。図表 A-4 に示したソフトは実際にテストしたもののみであり、このほか多くのフリーソフト、商用ソフトが [www.ipd.iru.uka.de/~precht/FAQ/neural-net-faq.html](http://www.ipd.iru.uka.de/~precht/FAQ/neural-net-faq.html) の 5、6 章で紹介してある (1996年1月現在)。

A-1) 日経インテリジェントシステム1992年夏号に掲載された第一勧業銀行事務企画部(当時)中田氏の解説を引用。

図表 A-3 インターネット上のリソース

メーリングリスト、ニュースグループ

<p>Neuron Digest neuron-request@cattell.psych.upenn.edu へ、“Subscribe Newron Diegest”というメッセージに自分のE-mailアドレスを添付し送付するとメーリングリストに参加できる。研究報告や学会の開催、ニューラルネットワークに関する議論の要約等が定期的に送信される。</p>	<p>comp.ai.neural-nets 意見交換や質問等が交換されているニュースグループ。メーリングリストと異なり登録する必要がなく、アクセスしたホストがサポートしていれば記事を読める。最寄りのホストにない場合は、rtfm.mit.edu/pub/usenet/ から ftp できる。</p>
<p>NNCM (Neural Networks in the Capital Market) 債券株式為替等の変動予測やアセットアロケーション、デリバティブへの応用など資本市場関連のメーリングリスト。yaser@caltech.edu へ、E-mail アドレス、住所、Fax 番号を送付し参加できる。ホームページも提供している。 www.cs.caltech.edu/~learn/nncm.html</p>	<p>INTCON (Intelligent Control) ニューラルネットワークのほかファジーロジック等人工知能に関連した議論、ニュースのためのメーリングリスト。購読申し込みは intcon-request@phoenix.ee.unsw.edu.au。</p>

WWW サイト

<p>www.lab.kdd.co.jp/bibliography/index.html 人工知能やニューラルネットワークなどコンピュータサイエンス全般の文献33万超を分類収録。ドイツ Karlsruhe 大学が作成したものを KDD の研究所がミラーリングしている。</p>	<p>www.cs.cmu.edu/Web/Groups/AI/html/repository.html 人工知能研究で著名なカーネギーメロン大学が提供するフリーソフトウエア、ニュースグループ等を収録したりポジトリ(倉庫)。</p>
<p>ai.iit.nrc.ca/ai_point.html カナダの研究機関 Institute for Information Technology が作成した、書籍、学会、研究グループ、ニュースグループ等のリソースを展示。検索システム WAIS を備える。</p>	<p>www.emsl.pnl.gov:2080/docs/cie/neural/neural/homepage.html 米エネルギー省が管轄する Pacific Northwest Laboratory での研究や多くのソフト・ハードを紹介。</p>
<p>www.neuronet.ph.kcl.ac.uk/ ヨーロッパの共同研究プロジェクト ESPRIS が提供するホームページ。研究活動や論文を紹介するほかニューズレターNEuroNews を配布。</p>	<p>www.eeb.ele.tue.nl/neural/neural.html 数多くの WWW サーバー、ftp サイト、ニュースグループへリンクされているほか、FAQ (Frequently Asked Questions) や専門紙等が展示・紹介。</p>
<p>www.sccs.chukyo-u.ac.jp/jcss.html 日本認知学会のホームページ。関連する WWW サーバーへのリンクが張られている。</p>	<p>www.ieee.org/nnc IEEE (米国電子電気技術者協会) 中のニューラルネットワーク・カウンシルのホームページ。</p>
<p>www.ai.mit.edu/ 人工知能研究の盛んな MIT の AI laboratory ホームページ。</p>	<p>www.idiap.ch/index.html スイスの人工知能関連の研究機関 IDIAP のホームページ。</p>

(注) 1996年1月現在。

図表 A-4 フリーのシュミレーターソフト

稼働環境	名前	入手先	特徴
UNIX 1 2 3 4 5	NevProp	ftp.scs.unr.edu/pub/goodman/ nevpropdir	本論文で利用したソフト。通常のBP学習法のほかQuickProp法を利用可能。
UNIX 1 2 3 6 7 8 9 10	SNNS	ftp.informatik.uni-stuttgart. de/pub/SNNS	グラフィカルなインターフェースを備えたシュミレーター。様々な学習タイプを持った階層型ニューラルネットワークのほか、ホップフィールドなど多様な相互結合型のネットワークを扱える。
UNIX 1 2 6 7 10 11	GENESIS	genesis.bbb.caltech.edu/pub/ genesis	汎用性が高いニューロンシュミレーター。神経生理学の解析にも利用される世界的に有名なソフト。
DOS	The Brain	ftp.tu-clausthal.de/pub/ msdos/science	簡単に利用できる入門用ソフト。ニューラルネットワークやBP法を知るのによい。
Windows	WinNN	ftp.cc.monash.edu.au/pub/win3/ programr/	同上（シェアウェア）。

(注) 稼働環境のUNIX添付番号は、1 SunOS, 2 Solalis, 3 HP-UX, 4 Convex, 5 CRAY, 6 DEC (Ultrix), 7 IRIX, 8 IBM (AIX), 9 NextStep, 10 Linux, 11 FreeBSDを示す。

## 補論2. モデルの詳細

本節では、ニューラルネットワークの数理モデルと学習法について解説した後、実証分析で用いたモデルの詳細を述べる。また、公定歩合操作の方向のみをニューラルネットワークに学習させた場合、精度が一段と向上することを示す。

### (1) ニューラルネットワークの数理モデルと学習法

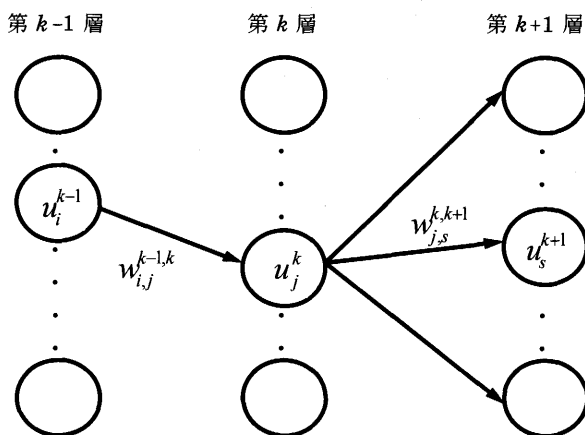
ニューラルネットワークの最小構成要素であるシグモイド関数は次のような数式で表現される。

$$f(x) = \frac{1}{1 + \exp(-\alpha(x - \theta))}$$

$\alpha=1$ 、 $\theta=0$ の場合、シグモイド関数は、計量経済学の質的選択モデル（ロジットモデル）で用いられる累積ロジスティック関数と等しくなる。また、隠れ層がなく出力層のユニットが1つしかないニューラルネットワークは、ロジットモデルそのものに相当する。<sup>A-2)</sup>  $\alpha$ が大きいほど非線型性が強まり、無限大の場合には単位ステップ型関数になる。

A-2) ロジットモデル等の質的選択モデルとニューラルネットワークの予測パフォーマンスの比

図表 A-5 n 個の階層を持つニューラルネットの第 k-1, k, k+1 番目の層



次に、ニューラルネットワークの構造を定義する。入力層が  $N_1$  個、出力層が  $N_n$  個 (添字は入力層から数えた階層数) のユニットを持つ  $n$  層の階層構造ニューラルネットを考えよう (図表 A-5)。第  $k$  層を構成する  $N_k$  個のユニットのうち  $j$  番目をユニット  $u_j^k$  と呼び、入力値  $I_j$  ベクトル ( $j=1,2,\dots,N_1$ ) から構成される入力パターン  $p$  を第 1 層に与えた時のユニット  $u_j^k$  への入力値を  $i_{pj}^k$ 、出力値を  $o_{pj}^k$ 、入出力関数 (ここではシグモイド関数) を  $f_j^k$  で表す。最終出力層からの出力値  $o_{pj}^n$  と教師信号  $t_{pj}^n$  の誤差の 2 乗和を、入力パターン  $p$  に対する誤差関数  $E_p$  で定義する。また、すべての入力パターンに対する総誤差関数  $E$  は、 $E_p$  の和として定義する。総誤差関数  $E$  は、結合荷重  $w$  の関数になっており、誤差関数を小さくするよう結合荷重の修正を繰り返すことで学習が行われる。

$$i_{pj}^k = \sum_{i=1}^{N_{k-1}} w_{i,j}^{k-1,k} o_{pi}^{k-1} + \theta_j^k$$

$$o_{pj}^k = f_j^k(i_{pj}^k)$$

- $n$  : ニューラルネットの階層数
- $N_k$  : 第  $k$  層のユニット数 ( $k=1,2,\dots,n$ )
- $o_{pj}^k$  : パターン  $p$  に対する第  $k$  層  $j$  番目ユニット  $u_j^k$  ( $j=1,2,\dots,N_k$ ) の出力値
- $i_{pj}^k$  : パターン  $p$  に対する第  $k$  層  $j$  番目ユニット  $u_j^k$  ( $j=1,2,\dots,N_k$ ) の入力値
- $w_{i,j}^{k-1,k}$  : 第  $k-1$  層  $i$  番目ユニット  $u_i^{k-1}$  ( $j=1,2,\dots,N_{k-1}$ ) から第  $k$  層  $j$  番目ユニット  $u_j^k$  ( $j=1,2,\dots,N_k$ ) への結合荷重

較を行ったものに、釜[1994]がある。

- $f_j^k$  : 第  $k$  層  $i$  番目ユニット  $u_j^k$  ( $j=1,2,\dots,N_k$ ) における入出力関数  
 $\theta_j^k$  : 第  $k$  層  $j$  番目ユニット  $u_j^k$  ( $j=1,2,\dots,N_k$ ) における入出力関数の閾値

$$E = \sum_{p=1}^{NP} E_p$$

$$E_p = \frac{1}{2} \sum_{j=1}^{N_n} (t_{pj}^n - o_{pj}^n)^2$$

- $NP$  : パターンの総数  
 $E$  : 総誤差関数 (各パターン  $NP$  個について求められた  $E_p$  の総和)  
 $E_p$  : パターン  $p$  に対する誤差関数 (パターン  $p$  の出力値と教師信号の誤差の 2 乗和)  
 $t_{pj}^n$  : 出力層  $j$  番目ユニット  $u_j^n$  ( $j=1,2,\dots,N_n$ ) からの出力値  $o_{pj}^n$  に対応する教師信号

学習法は、 $w$  の修正タイミングと修正方法で分類される。まず、修正のタイミングの観点からは、入力パターン毎に  $E_p$  を最小化するよう  $w$  の修正を繰り返す逐次修正法と、すべての入力パターンに対する  $E$  を最小化するよう修正を繰り返す一括修正法に分けられる。逐次修正方法のうち最も基本的なものが最急降下法の考え方をういた BP 法である。これは、 $w$  で誤差関数を微分して得られた勾配ベクトルの逆方向に  $w$  を修正する手法であり、誤差関数曲面上の点において、勾配ベクトルの逆方向へ進むとき誤差関数値が最も大きく減少することを利用している。結合荷重の変化幅  $\Delta w_{i,j}^{k-1,k}$  は、勾配ベクトルの負値に比例定数  $\eta$  を乗じて決定される。

$$\Delta w_{i,j}^{k-1,k} = \eta \left( - \frac{\partial E_p}{\partial w_{i,j}^{k-1,k}} \right)$$

BP 法のアルゴリズムはシンプルで高速計算に向いているため、工学、医学、ファイナンス等幅広い分野で利用されているが、いくつかの欠点を持っている。誤差関数曲面が複数の谷を持つ場合、初期値の与え方によっては局所的最小値へ収束する危険性がある点、勾配法では一回当たりの修正量は微量な方が良いが、修正ステップ幅を小さくすると学習速度が遅くなってしまいう点などである。<sup>A-3)</sup> 特に、実際の学習では結合係数の初期値を乱数で発生させるため、局所的収束を回避することが重要となり、結合荷重修

A-3)  $\eta$  値が小さいとアルゴリズムのループ 1 回あたりの修正幅が小さくなり学習速度が低下する。また、評価関数の最小化プロセスにおいて局所的最小値から抜けだしにくくなる。一方、大きい場合には大域的最低点を飛び越したり、振動を繰り返すことにより学習が収束しにくくなる。

正法の改善を工夫することで問題を解決するような方向で進展している。比較的簡単なものには、前回の修正幅に一定数を乗じたものを勾配ベクトルによる修正分（上式右辺）に追加したモーメント法や、学習の進行に応じて両者の効き具合を変化させる修正モーメント法、記憶の忘却にヒントを得たウエイト減退法などがある。モーメント法では、勾配ベクトルによる修正が大きいときは谷（大局的最小点）をジャンプして通り越してしまうことを防ぐ効果が、勾配が小さく学習速度が遅いときには学習を促進する効果がある。修正モーメント法では学習初期には関数の様々な方向に対する誤差関数の減少具合を試すため勾配ベクトルによる修正が強く効き、学習が進行した段階では前回の修正幅が効くよう、モーメント項のパラメーターを学習の進行とともに変化させる。ウエイト減退法は、記憶が薄れるのはシナプスの結合強度が低下するためと考えた仮説を応用し、アルゴリズム 1 ループ毎に結合荷重の絶対値を一定値だけ減少させる項を勾配ベクトルの項の他に付け加える手法である。

## (2) 実証分析に用いたモデル

学習モデルには中間層を 1 つ持つ階層型ニューラルネットワークを用いた。入力層は実質 GNP、CPI の前年比とその階差値の 4 ユニットから、出力層は公定歩合の変更方向と水準の 2 ユニットからなる。個々の人工ニューロンにはシグモイド関数を適用し、パラメーターは  $\alpha = 1$ 、 $\theta = 0.5$  とした。<sup>A-4), A-5)</sup> また、シグモイド関数の出力値が 0.05 ~ 0.95 の範囲になるよう入力値に制限をかけている。これは、教師信号が 0 や 1（ここでは  $\pm 0.5$ ）である場合、出力層からの出力値が教師信号に一致するには出力層への入力値が非常に大きく（小さく）なることが求められ、学習に悪影響が生じるためである。学習アルゴリズムは学習速度が速くなるよう最急降下法を改善したクイックプロップ法を逐次修正型で適用した。<sup>A-6)</sup> 具体的には次式に示したように、最急降下法に 1 ループ前の修正値を可変乗数倍したモーメント項を加える。これは、慣性項の係数が変動するため修正モーメント法の 1 種である。<sup>A-7)</sup>  $\eta$  は試行錯誤により 0.1 を選択した。

A-4) 第  $k$  層が常に定数値を出力するユニットを持つとき、 $k+1$  層のユニットは  $\theta = 0$  とすることができる。これは、定数値にウエイトを乗じた値が中間層ユニットにおける  $\theta$  値の役割を果たすためである。この定数値ユニットをバイアスニューロンとよび、定数値には通常 1 が用いられる（回帰分析の定数項に相当）。ここでは、バイアスニューロンを用い  $\theta$  値を 0 としている。

A-5)  $\alpha$  値は 0.7 ~ 5 の範囲が一般に適切であることが経験的に知られている（市川[1993]）。

A-6) 一括修正法のほうが修正回数が少なく学習速度が速いが、修正量が平均化されて微妙な修正ができないため複雑な問題の学習には向かない。

A-7) クイックプロップはカーネギーメロン大学のフォールマンによって提案された学習アルゴリズムである（Fahlman[1988]）。 $S(t)$  が前期値と同符号でかつ小さくなっているときには谷の底へ向かっており、そのまま同方向へスピードを上げて進む。逆符号の時は谷を飛び越しているため中間に戻る。一方、同符号だが今期の  $S(t)$  が大きい場合には谷を登ってしまう。そのため、第一項の効果より大きくならないようモーメント項の係数には上限が設定される。ここではフ



$$\Delta w_{i,j}^{k-1,k}(t) = \eta(-S(t)) + \frac{S(t)}{S(t-1) - S(t)} \Delta w_{i,j}^{k-1,k}(t-1)$$

但し、 $t$  はループの回数、 $S(t)$ は勾配ベクトル

推計に用いた入力値、出力値は、スケールリングを行っている。入出力値についてはスケールリングを行わないと学習が困難になることが知られている。主に以下の二つがデータの性質によって使い分けられる。ここでは、原データの分布を比例的に0～1にスケールリングする下方の式を適用した。なお、公定歩合の引き上げ、据え置き、引き下げを表す $d_{it}$ のみ、-0.5から0.5に分布させるため同式から0.5引いたものを用いた。

$$x_t = \frac{1}{1 - \exp(-(X_t - \text{ave}(X_t)))}$$

$$x_t = \frac{X_t - \min(X_t)}{\max(X_t) - \min(X_t)}$$

結合荷重の初期値は乱数によって発生させるが、シグモイド関数の一次導関数が大きい部分からスタートするほうが結合荷重修正の進行が速いため、各ユニットからの出力値が閾値近傍となるよう-0.1～0.1の間で発生させている。

次にニューラルネットワーク構造の決定に関する問題を述べる。中間層の層数や各層のユニット数は人工ニューロンの動作関数と同様、ニューラルネットワークの学習能力に影響する。一般に、中間層がない状態から1層にした場合、学習能力が飛躍的に向上するが、2層以上にしても学習時間が長くなる割に学習能力の向上が小さいことが知られている。また、1層でもユニット数の調整により任意の関数を近似できることが証明されているため、1層構造を採用した。問題はユニット数の決定である。中間層のユニット数を増やすとより複雑な関数を近似することができるが、過学習に陥る危険性がある。現実的には、入力層ユニットの2倍程度を与え学習能力の低下具合をみながら減らしていく手法が簡便な方法として利用されている。本論文ではこの手法に従った結果、6～8ユニットを選択している。このほか情報量基準を用いる方法や、結合係数の安定性に注目しユニット数の冗長性を調べる方法がある。<sup>A-8)</sup> また、時系列データの場合、中間層からの出力データをプロットし類似した変動やトレンドを持つものがないか確

---

オールマンのシミュレーション結果で最適とされた1.75を採用した。

A-8) 中間層ユニットが必要以上に加えられたとき、1つのユニット間に合っていた入出力値の変換が複数のユニットで処理されるようになるため、ニューラルネットワークの動作は同一であるにもかかわらず結合荷重が不定となる。従って、結合荷重の大きさや符号を解釈しようとする場合、冗長性が存在するリスクに十分配慮せねばならない。

認することで冗長性のチェックができる。さらに、中間層が1層で出力層が非線形動作をしない場合、ニューラルネットワークは次のような回帰式で表現されるため、中間層数の決定や結合係数初期値の算定に回帰分析が利用できる。

$$y_t = \sum_{j=1}^q \frac{1}{1 + \exp(-x_t \gamma_j)} \beta_j + \varepsilon_t$$

但し、 $y_t$ ：出力値

$x_t$ ：入力値ベクトル

$\gamma_j$ ：入力値から中間層への結合係数


$\beta_j$ ：中間層から出力層への結合係数

バイアスニューロンは含まず  $\theta=0$ 、 $\alpha=1$

$\gamma_j$ を与えることで通常回帰分析が可能になるため、次のような推計法が考えられる。まず、中間層の数が異なる回帰式  $q$  本について、様々な  $\gamma_j$  を与え最もよい平均平方誤差を示したものをそれぞれ選択する。次に  $q$  個の結果を誤差自乗和などで比較することにより最適な  $q$  の数を決定する。しかし、全数調査的なこの手法は、入力層や中間層の数が非常に少なくない限りパラメータ  $\gamma$  の組み合わせが極端に増大するため実用的でない。

直近のサンプル期間を分析したニューラルネットワークについて、学習過程における総誤差関数の減少の様子を表したものが図表 A-6 である。学習アルゴリズムのループが 0 回から 60 回までの状況を左に、500 回から 20,000 回までを右に示した。学習開始後、10 数回目から急速に減少し 40 回弱でゆっくりした減少に転じている。その後、緩やかな減少が続き 5,000 回を越えた辺りで更に減少速度が低下している。30,000 回でほぼ減少が観察されなくなったため、学習を打ち切った。総誤差関数の収束値は 0.095 である。他のサンプル期間についても、収束値を事前に設定せず、総誤差関数の減少状況をみな

図表 A-6 総誤差関数の減少



図表 A-7 結合荷重

		入 力 層				
		1ユニット	2ユニット	3ユニット	4ユニット	バイアス
		$y_t$	$\pi_t$	$\Delta y_t$	$\Delta \pi_t$	定数1
隠 れ 層	1	-1.00	2.19	1.68	1.53	-2.37
	2	-2.67	-4.94	1.73	11.57	-2.43
	3	-9.86	2.36	-14.28	-25.83	7.15
	4	-2.99	-7.06	8.79	-0.02	6.82
	5	-7.87	-4.41	1.13	-2.17	2.83
	6	-1.19	-3.99	7.64	8.36	-7.07
	7	7.03	4.10	-7.29	-3.36	-0.30
	8	0.50	4.73	3.92	1.46	-3.57

		隠 れ 層								
出 力 層		1	2	3	4	5	6	7	8	バイアス
	1	$d_{1t}$	11.72	-3.33	-1.09	7.61	7.83	10.68	9.39	-7.68
2	$d_{2t}$	13.32	-4.60	-3.29	-0.96	-7.18	0.32	-0.82	-7.27	-0.95

から収束条件を決定する方法を採った。学習で得られた結合荷重が図表 A-7である。上段が入力層から隠れ層への、下段が隠れ層から出力層への結合荷重を示している。

### (3) 公定歩合操作のみの推計

本文では、公定歩合操作の方向と水準を一つのニューラルネットワークで推計したが、連続変数（量的データ）と離散変数（質的データ）を同時に扱うという困難な学習を試みたため、学習精度は極めて高いとは言い難い水準に止まった。そこで、公定歩合の操作方向のみの学習を試みた。まず、出力ユニットを3変数( $D_{1t}$ 、 $D_{2t}$ 、 $D_{3t}$ )とし、公定歩合の引き上げ、据え置き、引き下げをそれぞれ(1, 0, 0)、(0, 1, 0)、(0, 0, 1)で表す。ニューラルネットワークの構造は入力層から順に4-8-3のユニット構成とし、同様な学習法で推計を行った。直近のサンプル期間の結果が図表 A-8である。濃淡のシャド一部は実際に引き上げ、引き下げがあった時期を表している。サンプル53期中、1990年第2四半期の据え置きと翌第3四半期の引き上げを正しく判別できなかったが、その他の時期は教師データにほぼ等しく、本文中の推計にくらべ精度が著しく向上していることが判る。従って、始めに変更か据え置きかを決定し、次に変更幅を決定するという

図表 A-8 推計精度

	出力値			教師データ				出力値			教師データ		
	$D_{1t}$	$D_{2t}$	$D_{3t}$	$D_{1t}$	$D_{2t}$	$D_{3t}$		$D_{1t}$	$D_{2t}$	$D_{3t}$	$D_{1t}$	$D_{2t}$	$D_{3t}$
82:1Q	0.00	1.00	0.00	0	1	0	89:1Q	0.01	0.94	0.00	0	1	0
	0.00	1.00	0.00	0	1	0		0.97	0.05	0.00	1	0	0
	0.00	0.95	0.02	0	1	0		0.00	0.99	0.00	0	1	0
	0.02	1.00	0.00	0	1	0		0.99	0.03	0.00	1	0	0
83:1Q	0.00	1.00	0.00	0	1	0	90:1Q	0.89	0.21	0.00	1	0	0
	0.00	1.00	0.00	0	1	0		0.58	0.37	0.00	0	1	0
	0.00	1.00	0.00	0	1	0		0.45	0.47	0.00	1	0	0
	0.00	0.03	0.96	0	0	1		0.01	0.98	0.00	0	1	0
84:1Q	0.00	0.98	0.03	0	1	0	91:1Q	0.00	1.00	0.00	0	1	0
	0.00	1.00	0.00	0	1	0		0.06	0.99	0.00	0	1	0
	0.00	1.00	0.00	0	1	0		0.00	0.01	0.98	0	0	1
	0.01	0.97	0.00	0	1	0		0.00	0.00	1.00	0	0	1
85:1Q	0.00	1.00	0.00	0	1	0	92:1Q	0.00	0.99	0.00	0	1	0
	0.00	1.00	0.00	0	1	0		0.00	0.00	1.00	0	0	1
	0.00	1.00	0.00	0	1	0		0.00	0.00	1.00	0	0	1
	0.01	0.97	0.00	0	1	0		0.00	1.00	0.00	0	1	0
86:1Q	0.00	0.00	1.00	0	0	1	93:1Q	0.00	0.00	1.00	0	0	1
	0.00	0.00	1.00	0	0	1		0.00	1.00	0.00	0	1	0
	0.00	0.97	0.01	0	1	0		0.00	0.05	0.98	0	0	1
87:1Q	0.00	0.01	0.98	0	0	1	94:1Q	0.00	0.99	0.00	0	1	0
	0.00	0.09	1.00	0	0	1		0.00	0.99	0.03	0	1	0
	0.00	1.00	0.00	0	1	0		0.00	1.00	0.00	0	1	0
	0.00	1.00	0.00	0	1	0		0.00	0.96	0.00	0	1	0
88:1Q	0.00	0.95	0.01	0	1	0	95:1Q	0.00	1.00	0.00	0	1	0
	0.00	1.00	0.00	0	1	0							
	0.00	1.00	0.00	0	1	0							
	0.00	1.00	0.00	0	1	0							
	0.00	1.00	0.00	0	1	0							

(注) 濃いシャドー部分が引き上げ、薄いシャドー部分が引き下げの時期を示す。

二段階決定方式が採られているとみなし、段階毎に推計する手法も精度の点で有効なアプローチと考えられ、今後の検討課題と思われる。<sup>A-9)</sup>

以上

[日本銀行金融研究所研究第1課(現人事局)]

A-9) この際、公定歩合の変更幅が0.25刻みの離散変数であるため、上記の手法が応用可能。

【参考文献】

- 浅子和美・加納 悟、「日本の財政金融政策の政策目標と制御可能性：1968-1986」『フィナンシャル・レビュー』第11号、大蔵省財政金融研究所、1989年、pp.43-81
- 安西祐一郎、『認識と学習』、岩波書店、1989年
- 市川 紘、『階層型ニューラルネットワーク、非線形問題解析への応用』、共立出版、1993年
- 釜 国男、「質的選択行動のニューラルネットワークモデルによる分析」『創価経済論集』Vol. XX , No.2、1994年9月
- サイモン・ハーバート、『人間行動のモデル』、同文館、1970年（原文：Simon, A. H., “*Models of Man*,” John Wiley & Sons, 1957.）
- 下平丕作士、「ニューラルネットワークによる時系列予測における相関係数を用いた学習用類似データ選定方法」『情報処理学会論文誌』Vol.36, No.2, 1995年 pp.266-274
- 中野 馨、飯沼一元 他、『ニューロコンピューター』、技術評論社、1989年
- 日経新聞社、『日経インテリジェントシステム』、別冊夏号、1992年
- 馬場則夫・小島史男・小澤誠一、『ニューラルネットの基礎と応用』、共立出版、1994年
- 宮川公男、『政策科学の基礎』、東洋経済新報社、1994年
- 吉野直行・義村政治、「金融政策反応関数の変化とマネーサプライコントロール」、1993年度秋季金融学会報告
- 渡辺 努、「免責条項付き金融政策ルールの推計」、本多佑三（編）、『日本の景気』、有斐閣、1995年
- Azoff, M., *Neural Network Time Series Forecasting of Financial Markets*, John Wiley & Sons, 1994.
- Broadbent, B. and R. J. Barro, “Central Bank Preferences and Macroeconomic Equilibrium,” Presented at the NBER Summer Institute, National Bureau of Economic Research, 1995.
- Fahlman, S. E., “An Empirical Study of Learning Speed in Back-Propagation Networks,” CMU (Carnegie Mellon University)-CS-88-162, Sep. 1988.
- Gately, E., *Neural Networks for Financial Forecasting*, John Wiley & Sons, 1996.
- Honkapohja, S., “Bounded Rationality in Macroeconomics: A Review Essay,” *Journal of Monetary Economics* 35, 1995, pp.509-518.
- Kuan, C.M. and H. White, “Artificial Neural Networks: An Economic Perspective,” *Econometric Reviews* 13 (1), 1994, pp.1-92.
- Maasoumi, E., A. Khotanzad, and A. Abaye, “Artificial Neural Networks for Some Macroeconomic Series: A First Report,” *Econometric Reviews* 13 (1), 1994, pp.105-122.
- Refenes, A.P., *Neural Networks in the Capital Markets*, John Wiley & Sons, 1995.
- Rumelhart, E.D., L.J. McClelland, and the PDP Research Group, *Parallel Distributed Processing*, MIT Press, 1986.
- Sargent, T.J., *Bounded Rationality in Macroeconomics*, Oxford University Press, 1993.
- Simon, A. H., *Economics, Bounded Rationality and the Cognitive Revolution*, Edward Elgar, 1992.