

〈論 文〉

## 経済統計学におけるニューラルネットワークの導入 (II)

——複雑系・生命系としての経済現象を想定して——

深 瀬 澄

(目次)

- I. はじめに
- II. 近畿経済の短期予測に関する既存統計
  1. 実測による経済統計
  2. 感覚的な判断に基づく経済統計
- III. ニューラルネットワークを用いた短期予測の方法
  1. 基本的なアイデア
  2. 足元の景気に関する基準統計の設定
    - 2-1. 候補となる基準統計
    - 2-2. 基準統計の絞り込み
  3. 景気変化の前兆シグナルを發する経済統計の探索
    - 3-1. 探索方法
    - 3-2. 検討の余地を残す経済統計
    - 3-3. 予測に利用する経済統計
    - 3-4. 前兆シグナルの経済学的解釈
    - 3-5. 前兆シグナルの感応度比較
- IV. 近畿経済(水準)の短期予測についての結果比較
  1. 計量経済モデルによる予測
  2. 経済時系列モデルによる予測
  3. トレンド延長による予測
  4. 多層型ニューラルネットワーク (MLP) による予測
- V. ニューラルネットワークモデルの改良の試み
  1. マルチエージェント化により専門教育した予測
  2. 変化率の学習と多変量時系列 (VAR) モデル化
- VI. むすびに代えて———今後の課題

I. はじめに——経済統計学への導入の試み

前号では、経済現象において数学や工学的な手法で未だ解明されていない、複雑系・生命系としての領域が残されていることを確認し、従来の経済統計学の手法と発想を異にするニューラルネットワークの可能性を探るとともに、これを用いた経済学研究の事例について国内外の文献を研究した。

今回は、実際にニューラルネットワークを用いたモデルを構築し、現実の経済現象の解明や予測のツールとしてのパフォーマンスを検証することを試みる。経済統計学分野の実証分析の手法としては、現時点では計量モデルや時系列モデルなどを用いることが圧倒的に多く、ニューラルネットワークは未だ市民権を獲得していない状況にある。このような試みを積み重ねていくことによって、露呈してくるであろうニューラルネットワークの問題点等も含め、経済統計学の分野における分析手法として導入することの是非を検討したい。

その最初の試みとして、不透明といわれている「近畿経済の先行き」を複雑系現象と仮定し、既成の経済学理論からの制約を緩めて統計学的に接近する。特に、短期予測における精度を高め、実用化の可能性を探りたい。なお、短期予測に絞った動機は「仮定①」に示される考察を背景としている。<sup>1)</sup>

注1) 仮定①

将来予測の情報についての任意の消費者の効用関数 $U$ が、予測期間 $t$ を変数とする可微分関数 $U(t)$ として与えられるとき、 $U$ は少なくとも、予測情報への対応に必要な期間 $T$ の近傍に1つの変曲点をもつ漸増的増加関数と仮定される。すなわち、

$$\frac{\partial U}{\partial t} \geq 0, \text{ かつ、} \begin{cases} \frac{\partial^2 U}{\partial t^2} > 0 & (0 \leq t < T) \\ \frac{\partial^2 U}{\partial t^2} = 0 & (t = T) \\ \frac{\partial^2 U}{\partial t^2} < 0 & (T < t < \infty) \end{cases}$$

(導出過程)

一般に遠い将来を予測しようとするほど信頼性が低下する。この最大の原因は、予測を行った時点からそれが観測される時点までの期間が長期化するほど、予測の前提となる状態構造が変化してしまう確率が高まるからである。これに対応するには高度な予測技術が要求されるものの、必ずしも予測情

## Ⅱ. 近畿経済の短期予測に関する既存統計

将来の経済の行方を短期的に見通すことを主たる目的とする経済統計には、①経済に関する事象の実測値をベースとするタイプのもの、②景気に敏感な人を対象にアンケートを行い、感覚的に判断してもらうタイプのものがある。

近畿地区の経済見通しに関連して現在公表されている統計にも、両方のタイプのものがある。それぞれのタイプの代表格である、近畿地区景気動向指数(通称、近畿地区DI、大阪府立産業開発研究所)と、近畿地区短期経済観測調査(通称、短観(近畿)、日本銀行大阪支店)について検討する。

### 1. 実測による経済統計

近畿地区景気動向指数は、複数の実測値に基づく月次の1次統計をベースとして、これらを計算処理することによって得られる2次統計である。すなわち、景気に敏感な複数の経済統計を、それぞれ3か月前との比較による数値変化から評価し、これらの結果を合成することによってDI値を計算し、総合的に景気をとらえるものである。DI値は、半年先の景気をみる先行系列、現在の景気をみる一致系列、半年遅れの景気をみる遅行系列にわけて算出される。国内の経済を対象にしたこれと同様のものが経済企画庁から公表されており、その近畿地区版とみられる。

なお、近畿地区のものは、最近2か年分程度の数値のみ公表されているが、

---

報の重要度が高まるとは限らない。すなわち、当事者にとっては、予測情報への対応のために最低限の対応期間が確保できればこと足りるのであって、この期間を越えて長期の予測を行っても、コストの割に貢献度の低下が懸念される。

例えば、学生にとって「夏休み明けに宿題を提出しなければならない」という情報についての、7月時点での現在割引価値と、8月時点での現在割引価値とに大差はない。対応期間を越える余暇時間があるために、事前に情報を得たとしても着工開始時期には大きく影響しにくい。ところが、対応期間の近傍における情報の時間割引率は大きく増大し、「明日出席を取る」という情報については前日と当日とで価値が著しく変化する。

季節変動のある1次統計に対して季節調整をかけてから計算しているため、年が新まるとD I値が過去に遡りして変更される。このため、長期の時系列的な分析には利用しにくい、経済企画庁が公表している全国のD Iについては長期のデータを入手できる。

森一夫教授（同志社大学）の研究によれば、D Iの一致指数の値が50%を下回る月が3か月連続すれば、80%の確率で景気は後退局面を迎えている、と報告されている（『日本の景気循環』東洋経済新報社1998）。事実、我が国の景気の転換点は景気動向指数をもとにヒステリカルD I法によって分析され、基準日付が公式に判定されている。

このように景気動向指数は景気判断に関する重要な情報を示唆する経済統計であるものの速報性の点で問題がある。1次統計が出揃った後に算出される2次統計であるため公表の時期がリアルタイムより2か月遅れとなり、D Iの一致系列の数値をもって景気のニューメレールとみなすならば、足元の景気が把握できないことになる。また、景気の転換点について基準日付が設定されるのは、従来はリアルタイムから2年6か月後であった。平成不況の谷（平成5年10月）の設定は「基準日付の迅速化」の努力によって1年半も短縮されたものの、それでもリアルタイムよりも約1年遅れている。

また、D Iの先行指数は半年先の景気を予測することになっている。しかし、大阪経済法科大学で私のクラスの受講生が、過去5年間の時系列データを用いて、一致指数とのラグ期間を1か月づつずらしながら相関係数を計測するという手法で先行期間を調査した結果、1か月のラグをピークにラグ期間を長くするほど相関係数が減少することを指摘している。すなわち、統計学的には、先行指数が示す数値は、たかだか1か月先の景気であって、半年後の実際の景気を示すものではないというのである。

また、嶋中雄二主任研究員（三和総合研究所）は、景気動向指数について景気の谷についての先行性が短いことを指摘している。景気の転換点を判断する簡易な手段として累積D Iをグラフ化して評価したところ、特に平成不況の谷（93年10月）に対しては、93年12月を示し、最近のD Iの数値が示す景気は、現実の景気に比べて2か月遅行していることを指摘している（複合循環 P.60）。

## 2. 感覚的な判断に基づく経済統計

短期経済観測調査は、企業経営者の景況感および先行きをアンケートで質問し、「上昇」「好転」とする企業割合（%）から「下降」「悪化」とする企業割合（%）の差をとった判断DIを用いて評価したものである。

一般的に、この種の景気予測にははかかなり経営者の感情的な判断が入ってしまい、景気が下降しているときには「好転」への期待的観測からDI数値が高めに、上向いているときには「下降」への不安からDI数値が低めに出ることが指摘されている。

これと同じ形式で大阪の中小企業を中心に実施されている「大阪府景気観測調査」（大阪府立産業開発研究所実施）について、景気予測のパフォーマンスを統計学的（多変量時系列共通変動要因分析を用いた）に検証した結果、将来の景気見通しにはこのような経営者の心理要因が反映されていることが確認された。さらに、これ以上に10～12月期の見通しには明るさが、1～3月期の見通しには懸念が強まり、経営者の景気判断には季節変動が強く作用していることも検証された。

すなわち、この種の景気見通しに関するアンケート調査では、経営者の景気判断に関しての癖といったノイズを含んでいるため、これを修正するフィルターとして機能する分析モデルを開発して調査結果を変換してやるとかなり精度の高い経済予測が可能となることが確認できたが、集計データをそのまま利用して景気見通しを判断してしまうと危険を伴うという結論を得たのである（拙著1997『府内経営者の景気判断構造の解明——多変量時系列共通変動要因分析を用いた景気予測モデルの開発』）。

### Ⅲ. ニューラルネットワークを用いた短期予測の方法

#### 1. 基本的なアイデア

先に吟味したように、近畿地区において経済についての短期見通しを目的とする統計は公表されているものの、速報性と予測信頼度との両方を兼ね備えたものがない。近畿地区の中心となる大阪府では、府内企業の経営不振などから深刻な財政危機に陥っているが、もしもこのような状態を事前に確実に予知できていたら、政策的な対応を発動し、事態を幾分なりとも緩和できたかもしれない。

そこで、以下では、ニューラルネットワークを用いて近畿地区の経済予測を試みる。この作業は4つの段階を経て達成される。まず、第1段階では、足元の経済状況をリアルタイムで把握するためのニューメーラールとなる経済統計を決定する必要がある。これが確立されなくては、将来における経済変化を評価できないからである。次の段階では、将来の変化に対して事前にその兆候を示すシグナルを発する経済統計を探すのである。さらに、第3段階では、これらのシグナルの発し方と経済状況の変化との間の秩序をみつけ、体系的に整理して予測精度を高めていくのである。このようなパターン認識の作業は、ニューラルネットワークが最も得意とするところでもある。そして、第4段階は、予測精度を向上させるためにモデルを改良するのである。

#### 2. 足元の景気を反映する基準統計の設定

##### 2-1. 候補となる基準統計

今回の試みでは、将来の経済の動きを一刻も早く把握することをテーマとしている。将来の経済活動の変化を評価するためには、現時点の状況がどうか基準が確立されていなければ整理が難しいが、経済状況をリアルタイムで示せるようなニューメーラールとなる経済統計を設定すれば単純明解となる。しかし、経済状況という概念は曖昧であり、個々の経済主体間や産業間でもバラツキが大きく、評価が難しい。

## 経済統計学におけるニューラルネットワークの導入(Ⅱ)

一般的な景気を反映する経済統計としては、①国内総生産(経済企画庁発表)、②景気動向指数(経済企画庁発表)、③短期経済観測調査(日本銀行発表)、④鉱工業生産指数(通商産業省発表)が知られており、エコノミストの間では、これらを総称して”景気の4大統計”と呼んでいる。まずはこれらのなかから、ニューメレールとなる経済統計の候補を吟味する。

ところで、本稿では、複雑系・生命系としての経済現象を想定し、ニューラルネットワーク・モデルの導入を検討するという立場にあることから、観察される経済現象についての歴史的特異性を尊重したい。このため、経済現象の一般的な運動法則を導き出そうとする計量経済学と考え方を異にする可能性もある。例えば、計量経済学モデルでは、経済を一般的化してとらえようとするため、石油ショックや消費税導入などの特殊要因や経済構造変化に対して、ダミー変数を用いるなどの調整によって例外的に取り扱おうとする。これに対してここでは、ニューラルネットワークにこのようなレアケースを多く学習させるために、できるだけ長期のデータを入力し、修正しないで取り扱っていくというポリシーをもっている。<sup>2)</sup>

---

(注2) ニューラルネットワーク・モデルで突発的事象などのレアケースも学習させたいというこの発想は、中岡哲郎先生(大阪経済大学)著の『仕事の経済学』に負う。

中岡先生は、職場(工場)における仕事の熟練の過程について、専門工程→ライン→プラントと段階を経て体系的に分析している。この過程の中で、学習蓄積は構造変化に対応するものとして捉えられている。

塩沢由典先生(大阪市立大学)は、業務について、複雑系経済学の立場から”揺らぎのある定常性”を主張している。すなわち、日常業務は大部分が定型化されたものでルーチンワークとして処理できるが、低い確率で特殊な対応に迫られる問題が発生する。定型化された業務では、経験の浅い従業員と熟練者との大差はつきにくい、年期を積むことでレアケースへの対応を経験する確率が高くなり、学習蓄積が増加することになる。職場におけるベテランが信頼される根拠は、定常部分への習熟もあるが、それよりもむしろ業務における揺らぎの部分にあるとしている。

ニューラルネットワークによる予測も、歴史的に特異な状況を予測できるように訓練させていきたい。

### 2-3. 基準統計の絞り込み

ニューラルネットワークでは、入力用の時系列データが3つの区間に分割(アロケーション)して割られることから、十分に時点数の多い時系列データを利用したい。なお、3つの区分とは、①パターン認識するための学習用データ、②学習のし過ぎによって判断が過度に画一的になっていないかを確認するためのヴァリディーション用データ、③予測結果のパフォーマンスを検討するためのテスト用データであり、あまりサンプル数が少ない時系列データではこのアロケーションが厳しくなるのである。

いわゆる景気の4大統計のうち、国内総生産については、直接に近畿地区の数値が公表されているわけではないが、経済企画庁がまとめている『県民経済計算年報』から近畿2府5県を抜き出して集計すれば入手可能である。ただ、年報に数値がまとめられるまでにかかなりのタイムラグがあるため、地域経済予測には用いにくい。

残る3統計は、近畿地区の数値が公表されており、連続した時系列データとして利用できる。ただ、短期経済観測調査は四半期ベースのデータであり、速報性という点で弱く、また、先にも指摘したように経営者の癖が含まれるため、客観的な景気のニューメーテルとして扱いが難しいかもしれない。

景気動向指数および鉱工業生産指数は、ともに月次ベースの統計であるが、景気動向指数は、多数の経済統計が公表された後にこれらを総合判断して算出されるため、公表時期がやや遅くなるという問題がある。

以上の選択基準やデータ制約を考慮し、鉱工業生産指数を経済活動のニューメーテルとして採用したい。これの3か月先の水準を予測し、景気の先行きを判断するための目安としたい。

## 3. 景気変化の前兆シグナルを発する経済統計の探索

### 3-1. 探索方法

前節で景気の判断材料として決定した鉱工業生産指数の動きについて、そのことを暗示するシグナルを3か月前に発信するような、景気の先行性を示す何らかの経済統計が存在するものと仮定する。もしもこのような経済統計の系列





をいくつか発見できれば、ニューラルネットワークを用いて学習させることにより、シグナルの変化と3か月先の鉱工業指数の変化との対応関係を直結させることができる。経済現象のメカニズムの解明にまでは至らなくても、経験的にこのようなパターン認識が確立できれば、何も情報がないときよりも高い確率で3か月先の経済の動きを言い当てることを期待することができる。

ここでは、将来の景気を複雑系の現象と仮定し、統計学のツールを用いて手探りの探索を試み、初めにモデルを構築し、後から演繹的に理論的な考察を行う。

幸いにも、近畿通商産業局および関西情報センターのご協力により、鉱工業生産指数以外の近畿地区に経済に関する月次の時系列データを可能な限り収集することができた。これらの時系列データと3か月先の鉱工業生産指数と相関係数行列を計算し、この数値を基準に景気の先行性を示すと思われる系列を選定した。なお、事前に、時間的推移から季節性があるとみられる系列については米国センサス局X-11法により季節調整をかけている。相関関係の強さの結果は図表Ⅲ-1のとおりであった。

### 3-2. 検討の余地を残す経済統計

先行性を示す経済統計の選定に関連して、嶋中雄二主任研究員（三和総合研究所）は、景気の先を読むための14の先行指標を主張しており、これらを用いて、経済企画庁の景気動向指数よりも1か月早く景気の高谷を判断できる「景気先行指数S L I (Sanwa Leading Index)」を開発している（「複合循環」(東洋経済1995、第5章pp.74-98)。中嶋氏の14の先行指標では、加工された2次統計を7つ、外国統計を1つ含むところが注目される（図表Ⅲ-2）。

これらの経済統計のうちの表中の統計番号、6、7、13については先行性を検討したが、7については近畿地区においても先行性が示されたものの、6の新設住宅着工戸数よりも公共工事請け負い面積の方が高い相関を示した。13の大口電力バランスについても契約電力で除して指数化するよりも電力使用量の水準で用いた方が相関は高かった（図表Ⅲ-1参照）。

今回の試みでは、この情報が入手できた時期が比較的最近であるため、統計番号の1、2、3、4、5、8、9、10、11、12、14については検討が間

経済統計学におけるニューラルネットワークの導入（Ⅱ）

に合わず、今後、相関を検討する余地および予測の精度の向上の可能性を残している。

図表Ⅲ-2 景気の先行きを読むための14の先行指標

部 門	指 標 名
金 融	1. 実質マネーサプライ(前年比、%) 2. イールド・カーブ(長短金利の差、%)
株 価	3. TOPIX/名目鉱工業出荷指数(水準、季調)
市 況	4. 日経商品指数17種(前年比、%)
住宅投資	5. 首都圏マンション契約率(契約率、%、季調) 6. 新設住宅着工戸数(水準、戸、季調)
自 販	7. 新規登録・届け出台数(乗用車)(水準、台、季調)
企業収益	8. 交易条件(輸出物価/輸入物価、相対比水準) 9. 単位労働コスト (製造業名目賃金/生産指数、前年比、%、逆サイクル)
在庫投資	10. 鉱工業生産者製品在庫率指数(水準、季調、逆サイクル) 11. 鉱工業用生産財生産(季調)/ 最終需要財生産(季調)(比率、水準)
出 荷	12. 非鉄金属鉱工業生産者出荷指数(水準、季調)
稼 働	13. 東京電力大口電力バランス(販売量(季調)/ 契約電力(季調)、水準)
米 国	14. 米国製造業稼働率(Federal Reserveboard)

3-3. 利用する経済統計

現時点で学習用の入力データとして採用することにしたのは、①鉱工業生産指数(季節調整済、自己回帰説明変数として)、②新規求人数(季節調整済)、③製造業所定外労働時間(サービス業を除く、季節調整済)、④乗用車新規登録手続き台数(季節調整済)、⑤建築着工床面積(2府5県、季節調整済)の5つの時系列データである。

なお、建築着工床面積については、兵庫県で平成7年の阪神・淡路大震災後

の復興需要の影響を強く受け、特殊要因が働いたために近畿経済との相関が低くなることも考えられた。念のため兵庫県を除外した2府4県との相関を比較した上で2府5県の方を採用した。

### 3-4. シグナルの経済学的解釈

5系列の先行指標のうち、①鉱工業生産指数については、例えば部品などの生産が動き出し、完成品が動くというように、部門により稼働時期の時間差が存在するために先行性を示しているのかもしれない。②新規求人数、③製造業所定外労働時間は家計の所得に関わり、④乗用車新規登録台数、⑤建築着工床面積は最終需要の変化によって、中間投入財の生産に波及したり、最終財そのものの在庫投資にも影響することから、先行性を示すのかもしれない。

### 3-5. 前兆シグナルの感応度比較

これらの先行性を示す経済統計の現在の数値が1%変化した場合に、3カ月前の鉱工業生産指数の数値が何%変化するかを示す弾力性を調べ、各経済統計が発するシグナルの重みを計測した。この計測方法は以下のとおりである。

説明変数、被説明変数を  $x$ 、 $y$  とする。

これらを自然対数変換し、 $X = \ln x$ 、 $Y = \ln y$  と置換する。

置換変数の間に、計量経済モデルが成立して、

$$Y = a + bX + e$$

(ただし、 $a$ 、 $b$  はパラメータの定数、 $e$  は誤差項)

の関係があるとする。両辺を時間  $t$  で変微分すれば、

$$\frac{\partial Y}{\partial t} = b \frac{\partial X}{\partial t}$$

$$\therefore \frac{\partial \ln y}{\partial t} = b \frac{\partial \ln x}{\partial t}$$

$$\therefore \frac{\partial y / \partial t}{y} = b \frac{\partial x / \partial t}{x}$$

経済統計学におけるニューラルネットワークの導入 (II)

$$\frac{\frac{\partial y / \partial t}{y}}{\frac{\partial x / \partial t}{x}} = b$$

すなわち、変数を対数変換をしてから、回帰分析を行って求めたパラメータ b の値が、弾力性に他ならない。

この結果は、図表Ⅲ-3のとおりであり、鉱工業生産指数、製造業所定外労働時間（サービス業を除く）の発するシグナルが予測に重要であることがわかる。

〔図表Ⅲ-3 3か月先の鉱工業指数に対する各経済統計の弾力性〕

概要 建築物着工 床面積(季調)

回帰統計			
重相関 R	0.339504		
重決定 R <sup>2</sup>	0.115263		
補正 R <sup>2</sup>	0.105541		
標準誤差	0.043232		
観測数	93		
係数	標準誤差	t	
切片	3.547974	0.315016	11.26285
X値1	0.13448	0.039057	3.443174

概要 新規求人数

回帰統計			
重相関 R	0.800243		
重決定 R <sup>2</sup>	0.640389		
補正 R <sup>2</sup>	0.636427		
標準誤差	0.027562		
観測数	93		
係数	標準誤差	t	
切片	1.516402	0.244803	6.194369
X値1	0.276712	0.021737	12.72993

概要 乗用車新規登録・届出台数(季調)

回帰統計			
重相関 R	0.577557		
重決定 R <sup>2</sup>	0.333572		
補正 R <sup>2</sup>	0.326248		
標準誤差	0.037521		
観測数	93		
係数	標準誤差	t	
切片	0.756513	0.574322	1.317226
X値1	0.34973	0.05182	6.748989

概要 鉱工業生産指数

回帰統計			
重相関 R	0.795772		
重決定 R <sup>2</sup>	0.633254		
補正 R <sup>2</sup>	0.629224		
標準誤差	0.027834		
観測数	93		
係数	標準誤差	t	
切片	1.082378	0.283231	3.821535
X値1	0.765728	0.061087	12.53507

概要 製造業所定外労働時間(サービス業除く(季調))

回帰統計			
重相関 R	0.591701		
重決定 R <sup>2</sup>	0.35011		
補正 R <sup>2</sup>	0.342968		
標準誤差	0.037052		
観測数	93		
係数	標準誤差	t	
切片	2.971021	0.237331	12.51848
X値1	0.690591	0.096632	7.001585

注: 太字は弾力性を示す。

#### IV. 近畿経済（水準）の短期予測についての結果比較

先に決定した5系列の経済統計データを用いて、鉱工業生産指数の3か月先の水準を予測する。①計量経済学モデル、②経済時系列モデル、③多項式近似によるモデル、④多層型ニューラルネットワークモデル、を用いて予測を行い、予測パフォーマンスの違いを比較する。

##### 1. 計量経済学モデルによる予測

当月の経済統計5つを説明変数とし、3か月先の鉱工業生産指数の水準を予測する。

すなわち、次のように定式化される。

$$Y = a X_1 + b X_2 + c X_3 + d X_4 + f X_5 + e$$

ただし、Y：鉱工業生産指数（季節調整済、3か月先の値）

X<sub>1</sub>：鉱工業生産指数（季節調整済、自己回帰変数として）

X<sub>2</sub>：新規求人数（季節調整済）

X<sub>3</sub>：製造業所定外労働時間（サービス業を除く、季節調整済）

X<sub>4</sub>：乗用車新規登録手続き台数（季節調整済）

X<sub>5</sub>：建築工事着工床面積（2府5県、季節調整済）


e：残差項

予測結果は図表IV-1-(1)のとおりで、YとX<sub>1</sub>との系列相関は比較的小さく、決定係数も0.74とそこそこ良好であった。しかし、経済企画庁の景気動向指数でも採用されている変数であるにもかかわらず、X<sub>4</sub>の乗用車新規登録手続き台数、X<sub>5</sub>の建築工事着工床面積のt値が1にも及ばず小さいという問題がある。しかし、ここで中心になる議論ではないので、グラフでみる限り3か月先の鉱工業生産指数の推移の輪郭はフォローしていることを確認するにだけにとどめる。

また、残差項を予測誤差とみなせば、そのグラフは図表IV-1-(2)のようになり、非常に不規則なノイズを示している。


〔図表IV-1-1 (1) 計量経済学モデル(自己回帰変数を含む)を用いた予測〕

鉱工業生産指数(100を引いた数値、季節調整)



[図表Ⅳ-1 - (2) 計量経済学モデル (自己回帰変数を含む) の予測誤差]

予測誤差の変動





## 2. 経済時系列モデルによる予測

自己回帰モデルにより、鉱工業生産指数の過去の実績から1か月先を予測し、この予測結果を用いて逐次的にさらに1か月先を予測し最終的に3か月先を予測することを試みる。適切なラグの長さについて2期と3期とで微妙なところであるが、後にニューラルネットワークを導入する際の準備として、パターン認識におけるスキーマの強度を考慮して3期のラグを採用することにした。

すなわち、以下のようなモデルである。

$$\text{STEP.1} \quad Y^*(-1) = Y(0) + Y(+1) + Y(+2)$$

$$\text{STEP.2} \quad Y^*(-2) = Y^*(-1) + Y(0) + Y(+1)$$


$$\text{STEP.3} \quad Y^*(-3) = Y^*(-2) + Y^*(-1) + Y(0)$$

これらの3ステップのうち、STEP.1の予測結果は図表Ⅳ-2-(1)のとおりである。説明変数間に強い系列相関があり、 $Y(+2)$ のt値は低いものの、相関係数は0.75で、1か月先の鉱工業生産指数の水準について輪郭はフォローできている。また、このSTEP.1の予測誤差は図表Ⅳ-2-(2)のように分布し、先に試みた計量モデルの時と酷似した形状となった。


しかし、このままステップを継続すれば、予測誤差が累積されていき精度がかなり低下してしまうことは明らかである。そこで、ニューラルネットワークを用いて、予測誤差を考慮し、逐次出力を修正するフィルターを開発して制御する手法も今後の課題として考えられる。

〔図表IV-2- (1) 時系列モデル (AR3) を用いた予測〕

鉱工業生産指数 (100 を引いた数値、季節調整)



[図表IV-2 - (2) 時系列モデル (AR3) の予測誤差]



$$y = 2E-09x^6 - 5E-07x^5 + 5E-05x^4 - 0.0023x^3 + 0.0544x^2 - 0.6264x + 2.3089$$

$$R^2 = 0.0793$$

### 3. トレンド延長による予測


経済状況の大きな趨勢をみるために、鉱工業生産指数のグラフから多項式近似によってトレンドを抽出すると、図表IV-3になる。この曲線だけでも相関係数は0.78とそこそこの値が得られる。

実務における売上予測などでは、トレンドの延長を中心として、周期性、季節性、特殊要因などを考慮して修正することによってかなり精密な予測ができる場合もある。

しかし、この手法ではトレンドは所与のものとして仮定されており、トレンド自体の変化が予測に含まれていない。これに対して本稿ではトレンドを不確定なものと考えており、ニュートラルネットワークモデルを用いてトレンドの変化を予測しようと試みている点で、トレンド延長による予測と根本的に異なる。

〔図表IV-3 トレンド延長による予測〕

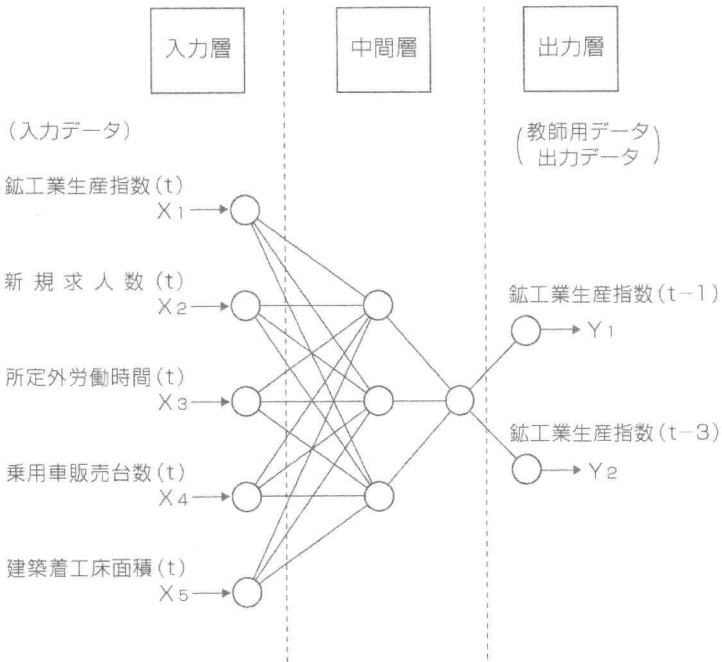
近畿地区鉱工業生産指数(季調)



4. 多層型ニューラルネットワーク (MLP) による予測

図表IV-4のように、入力層に5ユニット、中間層(2層より成る)の第1層に3ユニット、第2層に1ユニット、出力層に2ユニットを配置した多層型ニューラルネットワークを組織した。5つの入力データのパターンから、1か月先および3か月先の鉱工業生産指数の水準を学習させ、過剰学習のチェック(ヴァリデーション)を行い、予測結果をテストした。ニューロン間の伝達関数にはシグモイド関数を用いられることが多いがここでは緩やかな勾配をもつアークタングェント関数(傾きのきついタンジェント関数を横に寝かせたもの)を用いた。

図表IV-4 予測に用いた多層型ニューラムネットワーク




## 経済統計学におけるニューラルネットワークの導入（Ⅱ）

利用した統計データは、平成3年1月から10年9月までの93カ月分のデータである。これらのうち、3年1月から8年2月までを学習に、8年3月から8年12月までをヴァリデーションに配分し、残りの9年1月から10年9月までの21カ月分は全く未学習のデータとして残した。1500回の反復学習を経て、これらの未学習データから3か月先および1か月先を予測させた。結果は図表Ⅳ-5に示される。例えば、3か月先予測、1か月先予測のグラフをみると、14カ月目、16カ月目がそれぞれ落ち込んでいるが、ともに17カ月目を予測している。先に示した計量経済モデルや経済時系列モデルと比較して、グラフでみる限り予測精度の点では大差はみられないが、全てのデータを利用してモデルが構築されているこれらと直接の比較はできない。

1か月先予測に比べ、3か月先予測のパフォーマンスは判断がやや慎重過ぎるきらいもあるが、景気変化を大局的に判断している。今後、モデルの組織編成、伝達関数の変更、学習回数の調整などの試行錯誤を経て予測精度を向上させる余地は残されている。

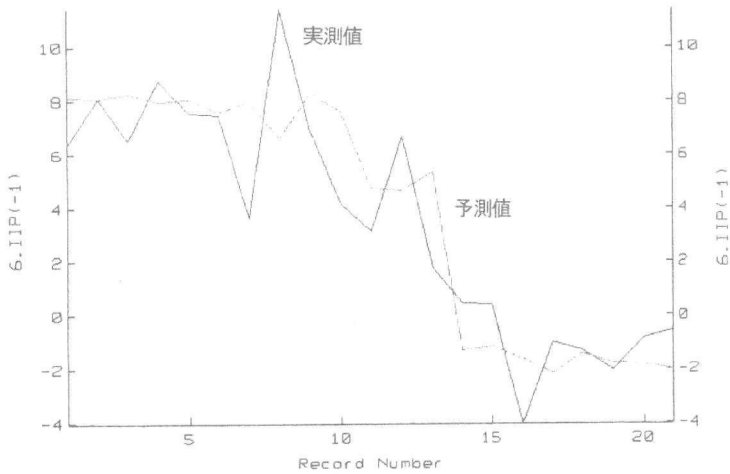
〔図表Ⅳ-5 (1) 多層型ニューラルネットワークによる3か月先予測の結果〕

3ヶ月先の鉱工業生産指数水準(100を引いた数値)の予測結果  
階層型(中間層3、1)型ニューラルネットワークで1500回学習



〔図表Ⅳ-5 (2) 多層型ニューラルネットワークによる1か月先予測の結果〕

1ヶ月先の鉱工業生産指数水準(100を引いた数値)の予測結果  
階層型(中間層3、1)型ニューラルネットワークで1500回学習





## V. ニューラルネットワーク・モデルの改良の試み


### 1. マルチエージェント化による専門教育を行った予測

ニューラルネットワークは、複数の演算素子(ユニット)を並列に配置し、入力信号を分散処理できることが特徴の1つとなっている。先の試みでは、5つの先行系列のデータを1セットの階層構造型ニューラルネットワーク(シングルエージェントモデル)で処理したが、今回は先行系列をグループに分けて、それぞれについてニューラルネットによる学習を行わせた後に、学習成果を統合して予測を行うという、いわば異なる専門教育を受けたエージェントを寄せ集めたプロジェクトによる共同作業を試みる。先行系列のグループ化については、第3章-5節(シグナルの経済学的解釈)に従い、A. 家計の所得変化に関わるグループ(新規求人数、製造業所定外労働時間)、B. 最終需要の変化に関わるグループ(乗用車新規登録手続き台数、建築着工床面積)、C. 鉱工業生産指数の自己回帰変数の変化に関わるグループに分け、これらと1か月、3か月先の鉱工業生産指数との関係を専門的に学習させた。なお、学習装置として、グループAでは、入力層2、中間層2、出力層2のユニットから構成される階層構造型ニューラルネットワークを、グループB、Cでは、学習期間が短いラジアル基底関数型ニューラルネットワークを用いた。

これらの学習結果を統合して、3か月先、1か月先の将来予測を行った結果は、図表V-1-(1)、V-1-(2)に示される。学習過程においては、個別グループについての予測誤差は全系列を学習したときよりも小さくできた。しかし、全体を統合して試みた予測結果については、上がり下がりの特徴をよくつかんではいるものの必ずしも期待したほどのパフォーマンスが得られなかった。とはいえ、先に予測をした結果の図表IV-5-(1)と比べてみると、予測精度が向上したとは認め難いものの、きめこまかな動きを示している。また、1か月先予測では、実績値に比べ予測値のグラフの位相が1か月遅れている。この位相の遅れを1か月だけシフトさせることができれば、景気の山谷を的確に予測している。この問題については、時系列モデルを組み込み1か月先を予測することで解決できる可能性がある。


図表V-1-(1)

3カ月前の鉱工業生産指数(100を引いた数値)の予測結果  
 階層型ニューラルネット1基、ラジアル基底型ネットワーク2基による並列分散処理



図表V-1-(2)

1カ月前の鉱工業生産指数(100を引いた数値)の予測結果  
 階層型ニューラルネット1基、ラジアル基底型ネットワーク2基による並列分散処理



## 2. 変化率の学習と多変量時系列 (VAR) モデル化

### 2-1. 多変量時系列モデルとは

多変量時系列モデル (Vector Auto Regressive Model) は、モデルを構成する変数がベクトルとして与えられ、1変量の自己回帰モデルの拡張として以下の形式で表現できる。

$$A = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix}$$

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$

として  $k$  次のラグを伴い、

$$X(t+1) = \sum_{m=0}^k AX(t-m)$$

ただし、ここでは、ニューラルネットモデルに用いているため、定常性の仮定を吟味しておらず、誤差項に関するホワイトノイズの仮定などは問題にしていらない。

このモデルでは、1変量の時系列モデルに比べ、複数のデータ系列の影響を加味していることから予測精度の向上が期待される。

### 2-2. 経済予測に用いるニューラルネットワーク・モデルの詳細設計

ここでは、多層型のニューラルネットワーク・モデルを用いた景気水準の予測についての精度をどこまで高められるか調べるために、多変量時系列モデルを用いて構造方程式体系に改めるとともに、ニューラルネットそのものについても、あらためてデザインし直した。

#### A. 階層フォーメーションの決定

MLPは、ニューラルネットワークの最も典型的なモデルであり、入力層、中間層（隠れ層）、出力層から構成され階層構造をなす。それぞれの層は、複数の演算素子（ユニット）が並列に配列され組織される。隣接しあう層の間の相互連絡については、1つの層を構成する各ユニットと、次の層を構成する全ユニットとを連絡するネットワークを通じて、信号が伝達される。

ここで入力される信号は、鉱工業生産指数、新規求人数、製造業所定外労働時間（サービス業を除く）、新車登録台数、建築着工面積、の5つの経済統計系列である。一方、出力される信号は、これらの系列の1か月先の値と、鉱工業生産指数の4か月先の値である。したがって、入力層および出力層は、それぞれ、5個のユニット、6個のユニットで構成される。残りの中間層については、試行錯誤を繰り返して、パフォーマンスが最良になるようにフォーメーションを決定しなければならない。

#### （結果）

当初の予想では、中間層の数を増やすほどフィットは改善されるものの、あまり増やし過ぎると入力信号のパターンを判断するスキーマ（認識強度）が低下しまい、再び誤差が増大しはじめるのではないかと考えられた。すなわち、多過ぎず少な過ぎず適度な数のユニットから構成される中間層が見つけられると期待された。

結果は図表V-2（1）に示したとおりで、まず、中間層を単層としてユニット数を1個ずつ増やしながらパフォーマンスの変化をみた。このとき中間層を2つのユニットで構成する場合が最も良好であり、それ以外では良い結果は得られず、いずれの場合も大差は認められなかった。

さらに、中間層を複層にして、予測精度を向上させようと試みた。第1層のユニット数を2個に固定したまま、第2層のユニットの数を1つずつ増やしてみたが、結果は図表V-2（2）に示すとおりで、第2層は設定しない方が良好な結果となった。

図表V-2(1) 中間層(第1層)のユニット数を変化させた時のパフォーマンスの違い

ユニット数	1	2	3	4	5	6	7	8	9
的中率	25%	54.2%	25%	25%	25%	25%	25%	25%	25%
誤差率	116.78	64.29	118.3	115.7	117.96	110.39	117.34	111.79	120.37

図表V-2(2) 中間層(第2層)のユニット数を変化させた時のパフォーマンスの違い  
(ただし、第1層のユニット数は2とした)

ユニット数	0	1	2	3	4	5
的中率	54.2%	25%	25%	25%	25%	25%
誤差率	64.29	115.59	115.41	115.7	117.96	117.38

## B. 信号伝達関数の特定化

フォワード・プロパゲーションの計算過程では、入力層、中間層、出力層の順に信号が送られてそれぞれの層で処理される。まず、入力層の各ユニットで処理された出力信号は、ウェイトを介在して、次の中間層の各ユニットに配分される。同様に中間層から出力層への信号伝達についても出力信号がウェイトを介在して配分される。出力層の各ユニットは、中間層の全ユニットから送られてきた信号を集計し、さらに集計データに対して処理を行ってから結果を出力する。この値がネットワーク全体の出力結果の初期値となる。

そこで、フォワード・プロパゲーションの計算過程で、各ユニットで集計された入力信号の合計値を、どのような信号伝達関数によって処理すれば良いか具体的に特定化する必要がある。ここでは、1次関数、シグモイド関数、ハイパボリック・タンジェント関数のそれぞれについて検討した。

(結果)

信号伝達関数についても結果は図表V-3のとおりで、データ系列によって、最適な信号伝達関数が一致しなかった。全体的には線形関数が良いとみられた。しかし、この関数を用いるとしばしばコンピュータがハング・アップしてしまい計算が停止したため、採用できなかった。

図表 V-3 伝達関数の違いによるパフォーマンスの差

	Liner	Tanh	Sigmoid
的中率 %	25.0	54.2	66.7
誤差率 %	116.83	64.29	69.81

C. 学習規則の制定1（「逐次学習」か「通し学習」か）

このモデルでは、各時点（月次）の5つの入力信号と、それぞれについての来期（1か月後）および3期（3か月後）の教師信号とが時系列データとして与えられ、両者の関係の秩序をみいだそうとしている。このような時系列信号の学習方法には、①各時点ごとにパターンを学習し、逐次ウェイトを修正する「逐次学習」と、②初めの期から末期までの期間を通して学習し、ウェイトを修正する「通し学習」とがある。これらの学習ルールの違いがニューラルネットワーク予測のパフォーマンスにどのように反映されるか検討した。

（結果）

結果は、図表 V-4 のとおりで、大部分のデータ系列については「通し学習」させてからウェイトを修正させるルールにした方が的中率、誤差率ともに良好な結果となった。

図表 V-4 学習ルールの違いによるパフォーマンスの比較

	逐次学習	通し学習
的中率 %	8.33	25.00
誤差率 %	116.86	128.87

D. 学習規則の制定2(「最急降下法」か「共役勾配法」か)

ニューラルネットワークモデルでは、学習過程が計算において最大のウェイトを占める。フォワード・プロパゲーションの計算過程を経た出力信号に対して、目標値となる教師信号が与えられており、両者の差異を縮めるべく試行錯誤による学習を反復する過程が、バック・プロパゲーションである。

バック・プロパゲーションのアルゴリズムでは、誤差の平方和を複数のウェイトの値による多変数関数として与え、微分を用いて、中間層、入力層へと遡って少しずつウェイトの値を調整し、予測誤差を最小にするウェイトの組み合わせを探索するのである。ウェイトは層と層の間に介在するので、植木算の論法で $n$ 層の構造のネットワークならば、 $n-1$ 組のウェイト集合があることになる。それぞれのウェイト集合の成分の数についていえば、前の層を構成するユニットの数が $a$ 、後の層のユニット数が $b$ とすれば $a \times b$ の次元をもつマトリックスを構成することになる。このモデルでは、入力層、中間層(単層とする)、出力層のユニットの数を、それぞれ、5、2、6とすれば、2組のウェイト・マトリックスがあつて、第1マトリックス、第2マトリックスのウェイトの数は、それぞれ、10個、12個となる。

したがって、バックプロパゲーションの計算過程ではこれら合計22個のパラメータの値を決定することになるが、これらの最適な値を探索する基準、すなわち、学習規則をルール化してやる必要がある。

1つのルールとして、マトリックスのうち、変化させても誤差が改善されない(微係数が0の)ウェイトは動かさず、改善効率の高い(微係数が大きい)ウェイトを一定量ずつ調整する「最急降下法」がある。

今一つのルールは、入力信号のパターンが与えられるたびに、最急降下法によってウェイトを修正しつつも、この基準に完全に従うのではなく、逐次、前回調整した分を考慮しつつ部分的な調整を行う「共役勾配法」である。これらの異なるルールを制定することにより、結果にどのような差が生じるか検討した。

(結果)

「最急降下法」と「共役勾配法」を比較した結果は図表V-5のとおりである。「最急降下法」を用いた結果は、予測精度が低下してしまった。

なお、この方法を用いての学習では、全てのウェイトの組み合わせについて検討したわけではないので、誤差が最小になるウェイトのマトリックス（局所的最適解）が発見できたとしても、探索されていない組み合わせの中に、さらに当てはまりのよいウェイトのマトリックスを見落としている可能性があるという欠点をもつ。予測精度が低下した原因として、この問題による影響も考えられる。そこで、後の細目決定で慣性係数を調整してみた。

図表V-5 学習規則の違いによるパフォーマンスの差

	共通勾配法	最急降下法 (逐次学習)	最急降下法 (通し学習)
的中率 %	54.2	8.33	25.0
誤差率 %	64.29	128.87	116.86

#### E. 「最急降下法」における細目設定1（「慣性係数」の設定）

先に指摘した最急降下法の最大の弱点である、「局所的最適解への収束問題」を解消するために考案されたアイデアとして「慣性法」や「忘却を考慮に入れたアルゴリズム」が知られている。これらのうち、慣性法は前回のウェイト修正幅の一定割合を必ず動かすために慣性項を加えて誤差を調整するものである。

慣性係数MC ( $0 < MC < 1$ ) の設定値を1に近づければ、学習成果について猜疑的になり、0に近づければ盲信的になる。両方がバランスする適正な数値を探索した。



（結果）

学習期間を4期間に分割して、それぞれの期間での学習回数を、200回、300回、500回、3000回と徐々に増やしていき、合計4000回学習させることにした。局所的最適解の問題を検討するため、「慣性係数」の数値についてつぎのようなパターンA～Eを考えた。すなわち、

A：すべて低めに設定、0.3、0.3、0.3、0.3

B：すべて中間に設定、0.5、0.5、0.5、0.5

C：すべて高めに設定、0.8、0.8、0.8、0.8

D：次第に上昇させる、0.2、0.4、0.6、0.8

E：次第に低下させる、0.9、0.7、0.5、0.3

のように各段階での慣性係数の設定値を組み合わせせて試行錯誤実験を行った。結果は、図表V-6のようになり、いずれの場合も結果は同じになり、あまり良好ば予測結果が得られなかった。

これは、今回のデータを用いた予測において、慣性法を用いたバック・プロパゲーションが収束的な過程ではなく、学習を反復するにつれて誤差が増大したためとみられる。グループA～Eの結果はいずれも、反復学習の過程で最も当てはまりの良好であった学習開始直後のウェイト値を採用したものである。

図表V-6 「学習係数」の設定とパフォーマンスの比較

	A	B	C	D	E
的中率 %	25.0	25.0	25.0	25.0	25.0
誤差率 %	116.8	116.8	116.8	116.8	116.8

#### F. 「最急降下法」における細目設定2（「学習係数」の探索）

学習成果の定着の度合いを、学習係数LC（ $0 < LC < 1$ ）で表す。この係数は、ニューラルネットワークの信号に対する適応の度合いや柔軟性を表し、値が1に近づけば学習効率が低いものの、学習経験のない新しい入力信号のパターンに対する応用が利かないことになる。また、値が0に近づけば、柔軟性

はあるものの、学習効率が悪く膨大な学習時間を要することになる。両者を考慮し適切な学習係数の値を試行錯誤により探索した。

(結果)

慣性係数を全段階とも0.5に設定し、学習係数のみをグループA～Cに設定し、予測精度を比較した。ただし、

A：次第に低下させる、0.9、0.7、0.5、0.3

B：次第に上昇させる、0.3、0.5、0.7、0.9

C：すべて低めに設定、0.2、0.2、0.2、0.2

その結果は、図表V-7にまとめている。慣性係数の場合と同様に全て同一となり、良好な結果が得られなかった。

図表V-7 「学習係数」の設定とパフォーマンスの比較

	A	B	C
的中率 %	25.0	25.0	25.0
誤差率 %	116.8	116.8	116.8

#### G. 予測に採用したモデル


以上、試行錯誤により、ニューラルネットワークのデザインを検討したが、最終的に得られた予測結果は、図表V-8に示したとおりである。

入手できるデータを用いて3かヶ月先を学習し、さらに1か月先を予測しているのが、実質的には4か月先を予測していることになる。予測期間は長期化しているが、先に図表IV-5で示したものに比べより細やかな動きをフォローできるようになった。

図表V-8 - (1) ニューラルネットワークを多変量時系列モデルに用いたモデルによる予測


変化率を用いた景気学習

近畿鋳工業生産指数 (変化率を水準に変換)



図表V-8-(2) ニューラルネットワークを多変量時系列モデルにを用いたモデル  
 変化率による未学習領域の予測パフォーマンクス

近畿鉱工業生産指数(変化率を水準に変換)



## V. 結びに代えて

景気の現状を鉱工業生産指数をニューメレルとして評価し、この将来の変動に対して事前にシグナルを発する5つの景気先行性の統計系列の挙動から予測を行うという試みはとりあえず成功した。

ただ、今後、このアイデアを実用化するためには、より予測精度を向上させるべく、採用系列の見直し、ニューラルネットワークの改良(ベイジアンニューロ、コホーネント型ニューラルネットワークほか)、他の状態空間モデル、カオス制御などとの融合を試す必要がある。

予測精度を改善する試みとして、特に注目すべきことは、第IV章の2節でデータ系列をグループ化して、専門教育を行い、これらのネットワークを再統合して予測を行ったところ、期待するほどにはパフォーマンスが向上しなかったという事実である。すなわち、各グループ学習では予測誤差を小さくできたのににもかかわらず、これらを統合した結果は、1つのネットワークで全体学習を結果を超えられなかったのである。

この原因はいくつか考えられ、ネットワークが全体的に働いていなかったこと、ノイズを学習してしまったことなどの技術的な問題もありえる。別の可能性としては、限定合理性と集団合理性という複雑系に起因する問題である。すなわち、ゲーム論における「囚人のジレンマ」のように、個人としての最適行動(専門学習における予測誤差最小化)を集計した結果が必ずしも社会全体としての最適行動(全体学習における予測誤差最小化)にはならないことも考えられる。

今回はニューラルネットワークを試運転する過程で生じた問題を提起し、今後の課題としたい。