

ニューラルネットワークによる青果物の需要構造分析

仙北谷 康*

Demand Analysis on Vegetables and Fruits with the Method of Neural Network Information Processing theory

Yasushi SEMBOKUYA*

The aim of this paper is to apply the neural network information processing theory to an analysis of demand structure and clarify its ability and problems.

Neural network has two merits: one is that, during data-processing, it absorbs the "noise" which is contained in the data brought by an observation; the other is that it makes non-linear classification available. But before applying neural network to an analysis of social and economic data, we must inspect the behavior of neural network with the theory of social science.

The main results obtained were as follows:

- 1) There are some cases that the theory does not fit in with extrapolation; it must be treated carefully.
- 2) The output of neural network varies with the shape of sigmoid function. We must decide the shape of sigmoid function considering the learning speed, the needed degree of non-lineation, and consistency in the theory.
- 3) In a simulation on demand structure, we obtained non linear locus.

緒 言

ニューラルネットワーク情報処理は、従来は、工学の分野で、ファジィニューロなどとして、機械制御の面における実用化がはかられている。しかし近年これを他のさまざまな分野に応用する試みがさかんにおこなわれるようになってきた^{1,4,6,7)}。ニューラルネットワーク情報処理の考え方方は、生物の神経細胞網における情報処理の動作を模して考案されたものであり、これを人間の選好

や印象などによって影響を受ける分野に応用しようとする考えは、当然の発想といえるであろう。しかしながら、これを社会科学の分野に応用し、その可能性と問題点などを明らかにした論文はまだ数例にすぎない^{5,6)}。

われわれが観測することができる経済変数は、常に「曖昧さ」を含んでいる。ニューラルネットワークは、学習過程を通じてこの曖昧さを取り込むことができるため、より現実的な分析が可能になると考えられている。また、従来の価格予測および需要構造分析においては、

*鳥取大学農学部農林総合科学科情報科学講座

*Department of Agricultural Information Science, Faculty of Agriculture, Tottori University

変数間の関係に線形性を想定する場合が多い。これに対してニューラルネットワークは、必ずしも線形性を想定しておらず、非線形の分析が可能である。

他方、ニューラルネットワークは、従属変数、独立変数間の構造的な関係が必ずしも明らかにされていなくとも、両者の関係を学習過程を通じて取り込み、これを用いてシミュレーションをおこなうことが可能であるとされている。従属変数、独立変数間の関係を明らかにすることは、経済構造分析において重要な課題であるが、この問題をひとまずさけて分析することが技術的には可能である。

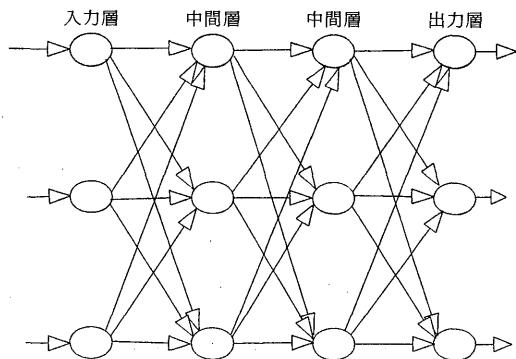
本稿では、ニューラルネットワーク情報処理の適用の可能性と問題点を、青果物の需要構造分析を素材として検討する。特に注目したい点は、ニューラルネットワークがわれわれが観測できるデータの曖昧さによる「ノイズ」をうまく吸収して、経済論理に即した理想的な構造分析、構造表現が可能かどうかということである。この点が保証されなければ、構造分析や、さらにはそれをふまえた価格予測も論理的な根拠付けがなされないことになる。

階層型ニューラルネットワークと誤差逆伝播法

ニューラルネットワークは、生物の脳や神経系が持つ優れた情報処理原理をモデル化したものとして着目されている。ニューラルネットワークは、その形態に注目して、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大別される。

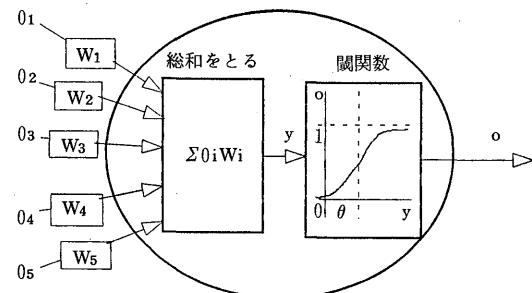
階層型ニューラルネットワークとは、ネットワークを構成する単位（ユニット）が複数の階層をなすように並び、一端の層を入力層、他端を出力層とする。そして、データが処理される方向が、入力層から出力層に向かって一方向に送られるようにそれぞれのユニットが結合しているものである。これに対して相互結合型ニューラルネットワークは、任意のユニットの間に双方向の結合があるものをさし、ユニットの出力値が自らに返ってくるフィードバックの結合も持っている。本稿では、第1図に示した階層型ニューラルネットワークを用いる。

各ユニット間は特定の結合強度を持ち、それらは重みとして与えられる。ニューラルネットワークは、特定の入力値に対して望ましい値（教師信号）に近い値を出力するように学習するが、これは重みを修正することを通しておこなわれる。出力層の出力値と教師信号の二乗誤差をもとめ、これが一定程度にまで低下した段階をもって学習が収束したとみなす。



第1図 階層型ニューラルネットワーク

この二乗誤差が最小化（正確には極小化）させる方向に重みが修正され学習が進んでいくことになるが、階層型ニューラルネットワークにおける学習アルゴリズムは、誤差逆伝播法として知られている⁸⁾。



第2図 ユニットの模式

入力層以外の各層のユニットは、第2図に示したような動作を示す。全段の層の各ユニットからの出力(o_i)に重み(w_i)付けされたものがユニットに入力され、その合計値が一定値(閾値、 θ)以下であれば、そのユニットは0（またはそれに近い値）を、それ以上であれば1（またはそれに近い値）を出力する。閾値の設定は、生物の細胞が一定以上の電気的刺激によって興奮（発火）することを模したものであるが、階層型ニューラルネットワークにおける学習アルゴリズムでは、この値も重みと同様に決定される。

ここでユニットの出力(o)を決定する関数を $f(y)$ とすると、

$$o = f(y) \quad (1)$$

$$y = \sum w_i o_i \quad (2)$$

となる。本稿では、この動作関数として、次に示される非線形区分関数であるシグモイド関数を用いる。

$$o = 1 / \{1 + \exp(-y + \theta)\} \quad (3)$$

重みは、ウェイトに対して次の式によって示される誤差項に比例した値を加減することによって修正される。

出力値 (M 層) とその前の層 ($M-1$ 層) の間の重み ($W^{M-1,M}$) の場合は、教師信号を t とすると、

$$\delta = (t - o) f'(y) \quad (4)$$

中間層の場合、 k 層と $k-1$ 層の間の重み ($w^{k-1,k}$) の場合は、

$$\delta^{k-1} = f'(y^{k-1}) \sum w^{k-1,k} \delta^k \quad (5)$$

(5)式からわかるように、 δ^k が計算によって求められれば、その次の層の誤差項である δ^{k-1} を求めることができます。いうまでもなく誤差項の計算の始まりは(4)である。このように、修正する誤差が出力層から入力層に向かって、データ処理とは逆向きに確定し、伝播していくので、この学習アルゴリズムを誤差逆伝播法 (Error Back Propagation) と呼んでいいのである。

さて、本稿において用いる階層型ニューラルネットワークは、MR型ニューラルネットワーク²⁾と呼ばれるものである。ニューラルネットワークによる一般的な分析では、神経細胞の発火を模して出力層の複数のユニットに 0 または 1 の値を出力させるが、このMR型ニューラルネットワークは出力層 (M) のユニットをひとつとし、そのユニットの動作関数だけには、通常用いられるシグモイド関数ではなく、

$$O_M = y = \sum w_{i0} i \quad (6)$$

という関数を用いる。つまり、($M-1$) 層のユニットからの入力の総計をそのまま出力させる。これによってネットワークが 0 から 1 までの連続的な値を取りやすくなり、通常の重回帰分析 (Multi-Regression Analysis) に近似した動作を示すのである。

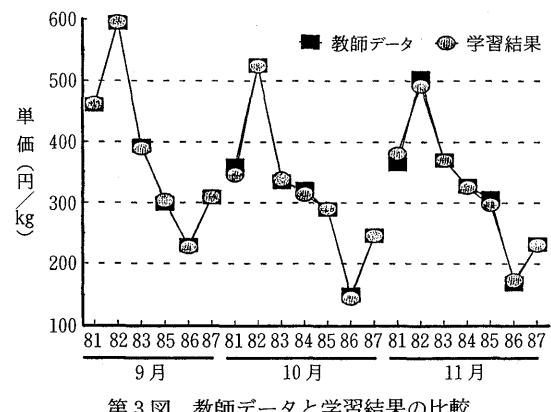
分析結果

1. 分析対象

分析対象は、鳥取県の特産物であるナガイモである。鳥取県におけるナガイモ生産は、鳥取県中部に位置する北条砂丘の砂丘畑を中心におこなわれており、市場からは「砂丘ながいも」として知られている。戦前から京阪神向けに出荷が開始され、1972年には作付け面積が戦後

最高の約250haを記録した。その後生産量、作付け面積ともに急減しているが、鳥取県農業の重要な柱のひとつとして、今後、生産の拡大が望まれている作物である。現在、出荷量のおよそ3分の1は、大阪、京都を中心とする関西地域向けであり、かつ良品が多く出荷されている。大阪市場は、鳥取県産ナガイモの主要出荷市場とみることができ³⁾、以下の分析では、大阪市場（本場、以下同様）におけるデータを分析に用いる。

大阪市場における月別産地別シェアをみると、北海道、青森県、長野県という主要産地が年間を通して高いシェアを占めているが、鳥取県産ナガイモの収穫出荷時期にあたる9~11月には、鳥取県が10%前後を占めている。主要産地では野菜貯蔵施設を導入し周年出荷態勢をしいているが、鳥取県はこの時点ではまだそのような対応はとっていない。ここでは分析期間を9~11月に絞ることにする。



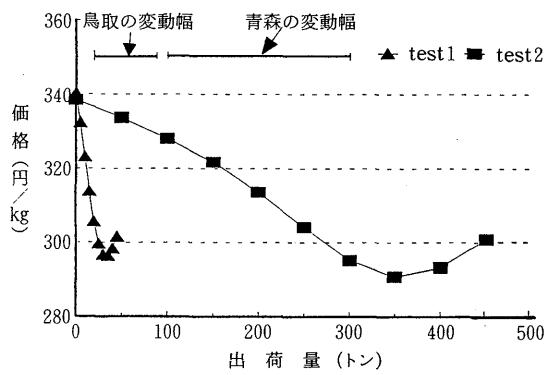
第3図 教師データと学習結果の比較

第3図は、ニューラルネットワークの学習能力を示したものである。ここでは、北海道、青森県、長野県、鳥取県の月別出荷量および月ダミー (9~11) を入力し、そのときの鳥取県産ナガイモの価格を教師信号として与える。誤差が一定以下になった時点で学習が収束したとみなし、再び入力値を与え、出力値を求める。図はそのときの出力値と教師信号を比較したものである。各データともに出力値は教師信号にかなり近似していることがわかる。

2. 外挿の困難性

ここでは、ニューラルネットワークに一定期間内のデータを与えて、その需要構造を学習させ、その後に特定の値を任意に変化させたデータを与えて出力値をシミュレートし、通常の需要関数に類似した関係を導出させる。

学習に用いるデータは1984年から90年までの7年間のうち、上下1年ずつを除いた5年間とする。大阪市場におけるナガイモ産地としての鳥取の位置は「非銘柄産地」であり、そのため鳥取県産ナガイモの価格は銘柄産地の出荷量などから影響を受けると考えられる。そこで4産地の出荷量と月ダミーを入力値として、そのときの鳥取県産ナガイモの価格を教師信号として与え学習させる。シミュレートの方法については、データの与え方によって二通り試みた。このうちtest1は、鳥取県産ナガイモの出荷量を変化させるものであり、test2は、銘柄産地でかつ最も出荷シェアの高い青森県産ナガイモの出荷量を変化させるものである。通常の需要構造分析においては、前者が価格伸縮性を、後者が交差伸縮性を求めるところにあたる。



第4図 出荷量の変化と価格変化

その結果を第4図に示した。この図からまず第一に、test1とtest2における価格の変化をみると、前者のほうが出荷量の変化に対する価格の変化が大きいとみてよい。これは価格伸縮性のほうが交差伸縮性よりも大きくなるであろうという一般的な通念と一致するものである。

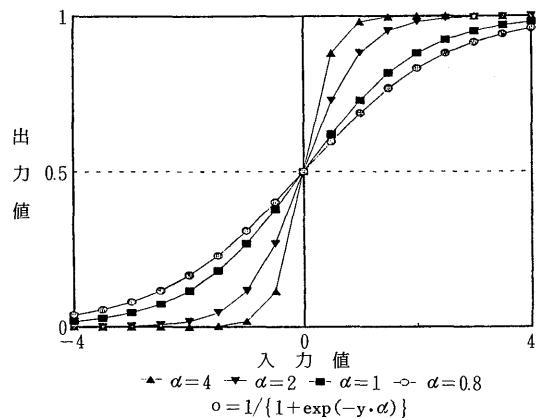
しかし第二に、価格と出荷量の軌跡は大部分において右下がりであるが、出荷量が一定以上になると右上がりとなり、需要関数の条件にそぐわない動作を示していることがわかる。この点について、test2については実際の青森県の出荷量の変動幅を超えた部分で軌跡が右上がりとなっており、外挿の問題の困難性としてとらえることができるが、test1については、鳥取県産の出荷量の変動幅のなかで右上がりとなっている。非銘柄産地であると考えられる鳥取県は、鳥取県産ナガイモの出荷量だけで価格が決定するとは考えにくく、それがこのような軌跡にあらわれたものと解釈されるが、この点に関してはより詳細な検討が必要である。

3. シグモイド関数の問題

MR型ニューラルネットワークにおいて非線形の軌跡が描かれるのは、各ユニットの動作関数として非線形関数が用いられるためであり、通常は、シグモイド関数が用いられる。シグモイド関数を用いるのは、微分可能性の問題から、誤差逆伝播法を適用するために都合が良いという側面がある。しかし高性能のコンピュータを用いても、学習を収束させるためには相当の時間を要する場合がある。そこで誤差逆伝播法による学習過程の収束を早めるためにいくつかの操作が有効であることが経験的に知られている。そのひとつとして、シグモイド関数に入力される値を定数倍するという方法がある。つまり、 y を入力値とすると、出力値 o を、

$$o = 1/[1 + \exp\{\alpha(-y + \theta)\}] \quad (7)$$

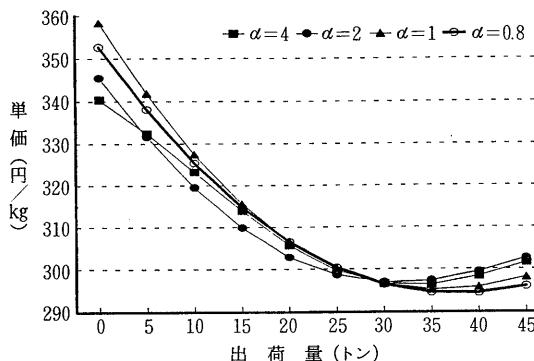
とするのである。一般に α は0.8~4までの値を取ること

第5図 α 値の変化によるシグモイド関数の形状変化

が多いが、絶対的な基準はない。さまざまな α の値に対応するシグモイド関数の形状を第5図に示した。ここでみると、 α が大きければシグモイド関数は非線形性を強め、ニューラルネットワーク全体が非線形の分類能力を高めるが、逆に小さくなれば線形関数に近くなる。ところが値が大きければ過学習の問題が発生し、分類能力の一般性が低下するという新たな問題が発生する。

さて、ここでの問題は、MR型ニューラルネットワークは出力値として(7)式を用いているために、出力値が α の値によって微妙に異なってくるということである。その例を第6図に示した。用いられているデータは、先のtest1と同様である。ここに示したように、 α の値によって軌跡は微妙に異なり、小さい α のほうが線形性が強いことがわかる。つまり、今までの例では右上がりの部分

がでにくくなるということであり、需要構造分析における経済理論と一致しやすい。しかしこれは逆に非線形の軌跡を描けるというニューラルネットワークのメリット

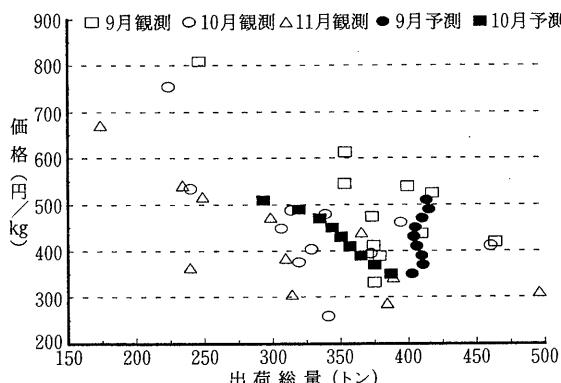
第6図 α 値の変化による出力値の変化

を低下させることになる。

この点については、学習の収束性、軌跡の非線形性、理論との整合性などいくつかの要因をあわせ考え、 α 値を決定しなければならない。このように考えると、さきにニューラルネットワークを用いる分析では、構造分析をひとまずさけてシミュレーションをおこなうことが技術的には可能であると述べたが、シミュレーションをおこなう以上、分析対象の構造分析と切り離して考えることは問題があるといえる。

4. 需要関数との比較

最後にニューラルネットワークによる需要構造分析と通常の需要関数による分析の結果を比較する。つまり、需要構造を学習させたニューラルネットワークに対して、価格と需要量のシミュレーションをおこない、その軌跡と通常の需要関数を比較する。学習に用いたデータは、



第7図 月別のナガイモ需要構造

大阪市場全体の取引量と価格および月ダミーである（所得については、金山・仙北谷³⁾によって優位ではないことが明らかにされていること、また人口についても特定できず、学習データとはしなかった）。需要関数においてデータを対数変換するために、ニューラルネットワークへの入力データに対しても同様の処置を施した。

まずニューラルネットの場合を第7図に示した。実際の観測値はほぼ右下がりの範囲に分布している。これに対してニューラルネットワークによるシミュレーションの結果は、10月のデータによるシミュレーションではほぼ同様の傾向を示すが、9月のデータでは価格の変動に対して非常に硬直的な分布を示している。

第1表 大阪市場におけるナガイモの需要構造

	Neural Network		重回帰分析	
	9月	10月	(A)	(B)
価格	0.047 (1.855)	-0.635 (-8.697)	-0.459 (-3.286)	-0.553 (-5.069)
月ダミー			-0.233 (-4.143)	
R ²	0.330	0.915	0.258	0.629

注 1) Neural Networkによる値は、出力値での回帰分析である。

2) 重回帰分析(A)：Neural Networkの学習値を用いた重回帰分析による。

(B)：金山、仙北谷（未定稿）による。

3) 括弧内の数値はt-値である。

シミュレーションの値から需要関数を求めたものと、学習値から需要関数を求めた結果を第1表に示す。重回帰分析(A)は9~11月のデータをプールした計測結果であり、(B)は、金山・仙北谷³⁾によるものである。シミュレーションの結果は、10月の値は回帰分析と近似した結果であるといえる。他方、9月のデータについては、この時期の需要が価格変動に対して硬直的であるからとも考えられるが、しかし実際の9月のデータの分析はやはりやや右下がりである。ニューラルネットワークではこの変動を過小に評価していることを示しているが、この点については詳細な検討が必要であろう。

10月のシミュレーションの結果は非線形でかつ右下がりの軌跡を示している。今後、この非線形の軌跡が実際の需要構造をよりよく表すものであるのかどうかということを検討する必要がある。

結論

本報告では、階層型ニューラルネットワークのなかのMR型ニューラルネットワークを用いて、青果物（ナガイモ）の需要構造を分析した。

ここで明らかになった事項をまとめると、まず、外挿に問題があり、需要関数が右上がりになり、経済理論にそぐわないことがある。また、連続的な値を出力させるニューラルネットワークの使用法においては、シグモイド関数の形状によって出力値が異なる。このため関数選択の問題をさけて通ることができない。内挿問題では、非線形の軌跡を描くことができ、場合によっては価格の高低によって異なる需要の弾力性を求めることが可能である。

分析においては、MR型ニューラルネットワークを用いて、連続的な値を出力させたが、シグモイド関数の形状など、細かな問題が残った。この点については、例えばMR型ニューラルネットワークではなく、価格帯の分類問題として扱うことによって解消するという方法が考えられる。しかし、分類問題はMR型ニューラルネットワークよりも収束に非常に時間がかかるという問題がある。

本稿は、ニューラルネットワークの社会科学分野への応用の端緒的な試みにすぎず、今後取り組まなければならない問題も数多い。しかしどもすれば対象となる社会経済構造をブラックボックス的に扱い、ノイズを上手に吸収する装置としてニューラルネットワークをとらえるという論考もみられるが、そのような判断にもとづきシミュレーションをおこなうことは問題があるということを明らかにした。

参考文献

- 1) 林晋：生活保障意識と行動のシミュレーション—ニューラル・ネットワーク・モデルによるアプローチ—マケティング・リサーチャー, 59, 44–51 (1991)
- 2) 市川紘：階層型ニューラルネットワーク. 共立出版社会社, 東京 (1993) p.27
- 3) 金山紀久・仙北谷康：非銘柄産地の出荷構造. 今井鑑藏退官記念論文集, 未定稿
- 4) 北川央樹：ニューラルネットワークを用いたデザイン支援システム. 森典彦編. 海文堂出版, 東京 (1993) pp.114–130
- 5) 李鋼浩, 時永祥三：ニューラルネットワークによる企業財務情報分析と株価予測. 濱砂敬郎・時永祥三編. 九州大学出版会, 福岡 (1992) pp. 3–30
- 6) 西尾チヅル・宮沢永光・中西祥八郎：ニューラルネットワークを用いたセールスプロモーション戦略決定支援システム. 東海大学紀要工学部, 31 (2), 187–195 (1991)
- 7) 西尾チヅル・宮沢永光・中西祥八郎：ニューラルネットワークとファジィ推論を用いたセールスプロモーション効果分析システム. 日本経営工学会誌, 42 (6), 431–439 (1992)
- 8) Rumelhart, D. E. et al : Learning representations by back-propagating errors. *Nature*, 323 (9), 533–536 (1986)
- 9) 時永祥三・李鋼浩：ニューラルネットワークを基礎とする企業倒産予測システムの設計. 経営情報学会誌, 1 (2), 35–50 (1993)