

ニューラルネットワーク，遺伝的アルゴリズム， ファジイ推論を用いたSP戦略策定システム

板垣 朝子，高嶋 守，西尾 チヅル，中西 章八郎

1. はじめに

従来，スキャンパネルデータを用いたセールスプロモーション（以下SP）効果分析には，関数型を仮定してパラメータを推定し，個人別の選択行動を推定するという形の手法が中心であった。しかし，SP効果分析にあたっては，消費者個人の特性，市場内の主要ブランドのSP状況やブランド力などの多数の要因を同時に考慮する必要があり，適切な関数型の発見が非常に困難である。そこで，本研究では，ニューラルネットワーク（以下NN），遺伝的アルゴリズム（以下GA），学習型ファジイ推論を組み合わせた手法で，パネルデータから消費者のブランド選択行動モデルを自動的に構築するシステムを提案する。本システムは，大量のパネルデータから自動的に知識を獲得し，消費者の購買行動に関する複雑な因果関係を適切にモデル化するシステムである。本システムでは，最初に複数のNNにより消費者の特性を考慮したブランド毎の選択確率に関する知識を獲得し，次いでファジイ推論を用いてこれらを統合して，最終的なブランド選択確率を推定する。また，ファジイ推論器の構成にはGAと一般化デルタルールを用いており，総合判断に必要な知識を自動的に獲得し，モデル化する。学習（知識獲得）後の本システムは，消費者の複雑な行動に関するモデル化が終了している。そこで，この学習後のシステムを用いて，シェア予測などいろいろ解析を行うことが

できる。

本システムを今回の目的であるインスタントコーヒーのパネルデータを用いたブランド選択行動モデルの構築に応用し，構築されたモデルを用いてブランドシェアを予測することで，本システムの有効性を示す。

2. システムの構成

図1にシステムの全体像を示す。システムは，サブモデル1とサブモデル2に大きく分かれている。サブモデル1は，消費者の各ブランドに対する反応（購買特性）を考慮して，あるSPが実施されているときの各ブランドの購買確率を求めるためのモデルであり，そのモデル化にNNを用いている。また，1ブランドにひとつのNNが対応するために，同時に考慮しているブランドの数だけNNが必要になる。サブモデル2は，ブランド毎に存在するネットワークの出力を統合して，最終的に世帯毎のブランド別購買確率を求めるモデルであり，最適なファジイ推論器を自動的に構成するために，GAと学習型ファジイ推論を用いている。

2.1 サブモデル1：ニューラルネットワーク

NN[3]は，入出力が対になったデータを与えることにより，その間にある複雑な関係を自動的に学習することができる人工的回路網である。サブモデル1では，NNを用いて，各ブランドに関する消費者の購買特性を考慮したSP効果についての知識を獲得する。NNによって表現される知識は，2ブランドの場合を例にとって日常使用される言葉に直すと，「ブランド1をよく買う人は，SP状況がBというパターンの時，ブランド1を $a\%$ ，ブランド2を $b\%$ の確率で選択する」といったものになる。つまり，サブモデル1は，各ブランドについての消費者の特徴およびSP状況と，各ブランドの選択確率の間の関係についての知識を獲

いたがき あさこ，たかしま まる 日本ナレッジ
インダストリ 〒141 品川区西五反田 7-22-17 TOC
ビル

にしお ちづる 筑波大学大学院経営システム科学
〒112 東京都文京区大塚 3-29-1

なかにし しょうはちろう 東海大学工学部
〒259-12 神奈川県平塚市北金目 1117

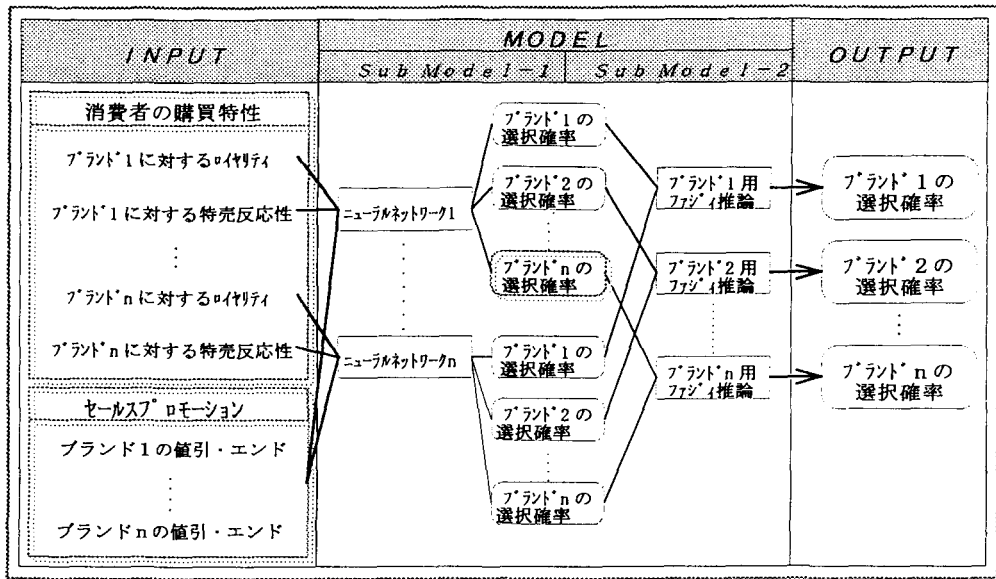


図1 システムの全体像

得し、これを用いてモデル化を行っている。本システムで用いる NN は Rumelhart [4] らの提案した階層型ニューラルネットワークである。

2.2 サブモデル2:遺伝的アルゴリズムを用いたファジイ推論器の構成

ファジイ推論は、ファジイ数を持つ if-then ルールで表わされる規則の組で推論を行うものである。サブモデル1では、ブランドの数だけ NN があり、各 NN にはブランドの数だけ出力がある。したがって、総合的判断をするためには、これら NN の出力を統合する必要がある。サブモデル2では、この統合プロセスをファジイ推論を用いて行い、総合的な推論を行うための知識をファジイルールを用いて記述する。その知識を日常使用される言葉で表現すると、「A という人 (= ブランド1 はよく買うがブランド2 はあまり買わない人) が、SP 状況が B のとき、ブランド1 を選択する確率とブランド2 を選択する確率を、サブモデル1 で得られた知識群をもとにして推論するための知識」である。本研究で用いたファジイ推論は、後件部が実数値をとる簡略型ファジイ推論である。推論器の入力はサブモデル1の出力であり、推論結果は統合された

ブランド選択確率である。

ファジイ推論を自動的に構成するためには、前件部 (ルールの if 節にあたる部分) と、各前件部に対応する後件部 (then 節にあたる部分) を同定する必要がある。ここでは、GA と一般化デルタルールを組み合わせることにより、データから自動的にファジイ推論規則を構成する方法を用いる [5, 6]。ファジイ推論の前半 (if 節の部分) を同定するのに GA を用いており、同定された前件部に対応する後件部の決定に一般化デルタルールを用いている [7]。

3. システムの入出力

本システムの目的はパネルデータに内包されている消費者のブランド選択に関する知識を獲得して、適切なモデルを構築することである。システムは前節で述べたように、各ブランドに関して知識を獲得するサブモデルと、それを統合するサブモデルの2つのプロセスから構成されている。本システムでは知識の獲得 (学習) は各サブシステム毎に行われる。すなわち、システムの学習 (知識獲得) は2段階で行われる。最初の学習はサブモデル1における NN の学習であり、次の段階はファジイ推論器の構成である。システムに学習

させるためには、学習用の入出力データ(パターン)をシステムに提示する必要がある。そこで、パネルデータから学習用データを構成する方法、すなわちシステムの基本的学習概念を、各サブモデル毎の入出力データ(パターン)に関して、次に述べる。

(1) サブモデル1 (NNの学習)

(a) 入力パターン：消費者があるSP状況に遭遇した時の反応は、その人の購買特性によって異なると考えられる。大きく値引されているブランドを良く買う人とあまり買わない人では、当然、そのブランド選択行動は異なり、また、特売によく反応する人とそうでない人とでもやはり異なる。そこで、入力パターンを購買特性とSP状況を示す2つの部分から構成する。消費者の購買特性については、ロイヤルティと特売反応性を表わす2つの指標を導入し、この指標を用いて購買行動を表す。SP状況では値引とエンドを取り上げ、各ブランドの値引とエンドを図2のように2値で表す。今回使用したパネルデータには、他にチラシの




図2: NNの入力パターン

有無の状況も記録されていたが、実施件数そのものが少なく、これを含めてもその効果が十分に反映されるとは考えられないので除外した。購買特性は、ブランド毎に異なるため、各ブランドについてこのような入力パターンを作成し、それぞれのNNの入力パターンとする。従って、入力パターンとして与えるデータは、図2のように、購買特性を示す部分が当該ブランドに対するロイヤルティと特売反応性を示す2ビットと、SP状況を示す部分が各ブランドの値引とエンドの有無を示す $2 \times n$ ビットとなる。ここで、 n はモデル内で考慮するブランドの数である。

(b) 出力パターン：上で求めたパターンに対するそれぞれのブランドの選択確率を、対応するNNの教師信号として与える。

(2) サブモデル2 (ファジィ推論器の構成)

サブモデル2ではサブモデル1の出力が入力として与えられる。ファジィ推論規則の構成にあたっては、

2.2節で用いた手法で、前件部同定用データはサブモデル1の出力によって与えられる。このデータの最適ファジィ分割(同定)をGAで行う。後件部同定はパネルデータの実際の選択確率からデルタルールによって決定する。

4. 学習パターン抽出の手順

以下の手順でデータをパターン化し、NNの学習用データを作成する。

(1) 世帯別・ブランド別ロイヤルティ指標の決定

1993年1月~12月のパネルデータから、世帯別に購入機会数と各ブランドの購入回数を算出し、後者を前者で割って、ブランド別年間購入比率を算出する。当該ブランドの年間購入比率が50%以上の場合には1、50%未満の場合には0として、ロイヤルティ指標とする。

(2) 世帯別・ブランド別特売反応性指標の決定

(1)と同じく、世帯毎に各ブランドの購入機会に着目し、最も高かった時の購入価格(最大購入価格)をブランド毎に抽出する。当該ブランドの最大購入価格が、基準値よりも安ければ1、高ければ0として、特売反応性指標とする。ここで、基準値には、対象データ全体についてのブランド別購入価格の中央値を用いる。

(3) SP状況のコード化

パネルデータ内のSP状況(ブランド別価格掛率、エンド有無)を、値引額、エンド有無としてコード化する。ここで、値引額は、価格掛率を、その中央値を基準にして、大と小の2つに変換したものである。一方、エンド有無は元のパネルデータ内でも二値データなので、そのまま利用する。

(4) ブランド選択確率の算出

各ブランドの同じ購買特性を持つグループに対して、上記(3)でコード化されたSP状況別にブランド別の選択確率を算出し、各NNの教師信号とする。ここで、ブランド別選択確率は、世帯特異性・SP状況別の購入機会中に占める当該ブランドの購入回数割合である。

5. シェア予測

1993年1月~12月のパネルデータを用いてNNおよびファジィ推論器を構成し、そのモデルを使用して

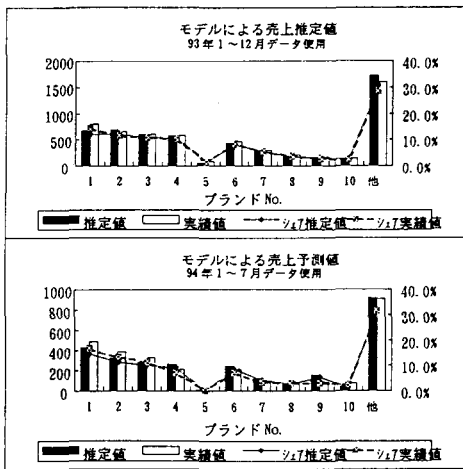


図3: モデルの推定値と予測値

1994年1月～7月のシェアを予測した。なお、今回、このモデルで学習するのはブランド1-4, 7, 8の6ブランドとし、それ以外のブランド*i* (*i* = 5, 6, 9, 10, 11)は「その他」として取り扱った。理由は、上記6ブランド以外のブランドではほとんどSPが実施されていないため、SPの効果として売上を説明することは不可能であると考えられるからである。これらモデルに含まれないブランドのシェア推定値、シェア予測値については、次の式で算出している。

$$S_i = \frac{(100 - \sum_j S_{ej}) S_{ri}}{\sum_i S_{ri}}$$

ここで、 S_i はブランド*i*のシェア推定値、 S_{ej} はブランド*j* (*j* = 1, 2, 3, 4, 7, 8)のモデルによる当該年度シェアの推定値、 S_{ri} はブランド*i*の93年実績シェアである。

予測結果を図3に示す。タイトルの不一致係数は

	93年(推計)	94年(予測)
不一致係数	0.041	0.058

となり、どちらもきわめて良好な結果が得られている。また、本システムが消費者の異質性をどの程度とらえているかを見るために、ブランド4について、購買特性のSPに対する反応を表したのが図4である。

購買特性によって同じSPでもブランド選択確率が違うことがわかる。また、その違いは我々の直感にきわめて近いものである。すなわち、本システムが、消費者の特性によるブランド選択行動の違いについての知識を的確に獲得し、極めて適切なモデルを構築し




図4: 購買特性によるSP効果の違い

ていることがうかがえる。

6. まとめ

NN, GA, 学習型ファジィ推論を組み合わせ、SP効果を分析するモデルを構築した。その結果、データに対して適合度が高く、また予測に際しても汎化性の高いモデルができた。また、構築したモデルは、消費者の特性も織り込んだブランド選択行動に関するモデルとなっていることを示した。

参考文献

- [1] 恩蔵;『セールスプロモーション研究の発展課程と今後の課題』, 早稲田商学, 第338, 339合併号, pp. 219-248 (1990).
- [2] 西尾;『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, pp. 187-195 (1992).
- [3] 甘利俊一;『ニューラルネットワーク情報処理』, 産業図書 (1988).
- [4] Rumelhart, D. E. and McClelland, J. L.; "Parallel Distributed Processing: Explorations in the Microstructure of Cognition," The MIT Press, (1986). (甘利俊一監訳:『PDPモデル:認知科学とニューロン回路網の探索』産業図書(1989).)
- [5] 野村, 荒木, 林, 若見;『アルタールによる学習型ファジィ推論—遺伝的アルゴリズムによる前件部の構造同定』, FANシンポジウム講演論文集, pp. 25-30 (1991).
- [6] 市橋, 渡辺;『学習型ファジィ推論を用いたファジィモデルによる学習型制御』, 日本ファジィ学会誌, vol2, No.3, pp. 429-437 (1990).
- [7] Itagaki, A., Takashima, M., Ashino, Y., Nishio, C. and Nakanishi, S.; "Fuzzy Inference Systems by Genetic Algorithm and Factor Analysis - Causal Modeling for Multi-variate Complex Systems," in the Proceedings of IEEE Symposium on Emerging Technologies & Factory Automation, pp. 194-205 (1994).