

인공신경망을 이용한 소비자 선택 예측에 관한 연구

송수섭* · 이의훈*

A study on forecasting of consumers' choice
using artificial neural network

Soo-Sup Song* · Eue-Hun Lee*

■ Abstract ■

Artificial neural network(ANN) models have been widely used for the classification problems in business such as bankruptcy prediction, credit evaluation, etc. Although the application of ANN to classification of consumers' choice behavior is a promising research area, there have been only a few researches. In general, most of the researches have reported that the classification performance of the ANN models were better than conventional statistical model.

Because the survey data on consumer behavior may include much noise and missing data, ANN model will be more robust than conventional statistical models which need various assumptions. The purpose of this paper is to study the potential of the ANN model for forecasting consumers' choice behavior based on survey data. The data was collected by questionnaires to the shoppers of department stores and discount stores. Then the correct classification rates of the ANN models for the training and test sample with that of multiple discriminant analysis(MDA) and logistic regression(Logit) model.

The performance of the ANN models were better than the performance of the MDA and Logit model with respect to correct classification rate. By using input variables identified as significant in the stepwise MDA, the performance of the ANN models were improved.

Keyword : Neural network, Classification, Consumer choice

1. 서론

인공신경망(Artificial Neural Network : ANN) 모형은 재무관리, 생산관리, 마케팅 등 기업경영의 다양한 분야에서 의사결정의 질을 제고하기 위한 보조수단으로 사용되어 왔다. Wong et al.[28]은 인공신경망 모형을 기업경영분야에 적용한 연구의 조사분석에서 1994년부터 1998년까지 302편을 논문을 찾아냈다. 이 조사에서 생산관리분야에 적용한 논문이 가장 많았으며, 재무관리, 마케팅 및 유통, 정보시스템, 회계 및 회계감사, 인적자원관리 분야의 순으로 논문의 수가 많았다. Wong et al.은 1995년도에 실시한 동일한 조사결과와 비교하여 생산관리분야와 재무관리분야는 아직도 가장 활발하게 인공신경망 모형이 적용되는 분야이며, 특히 마케팅 및 유통분야에서의 적용이 두드러지게 증가하였다고 분석하고 있다.

경영분야에서 인공신경망의 적용은 분류(classification)와 예측(forecasting)의 두 가지 큰 흐름으로 구분할 수 있다. 재무제표상의 데이터를 입력하여 도산기업과 건전기업을 분류하는 문제를 대표적인 분류의 문제로 볼 수 있으며 미래의 주식가격지수(stock market index)를 예측하는 문제를 대표적인 예측의 문제로 생각할 수 있다. 그동안 마케팅분야는 인공신경망 모형의 적용이 상대적으로 많지 않았던 분야의 하나이다. 그러나 Vellido et al.[26]은 마케팅 분야에서 소비자행동 분류 문제가 인공신경망을 적용할 가장 유망한 연구분야라고 주장하고 있다.

분류문제를 해결하기 위하여 가장 많이 사용된 통계적 모형은 다변량 판별분석(multivariate discriminant analysis : MDA) 방법이다[2, 5, 14, 20]. 그런데 MDA는 판별변수들이 다중정규확률분포(multivariate normal probability distribution)를 한다는 조건을 포함하여 몇 가지 제한적 가정을 만족시켜야 그 타당성이 성립한다. 이 다중정규분포의 가정은 판별분석에서 필수적인 조건으로 이를 만족시키지 못하는 경우에는 분석결과가 오도

될 수 있다[13, 20]. 그러나 실제 상황에서 입력변수들은 다중상관성이 높아 이 가정이 성립하지 않는 경우가 많다. 특히 소비자행동 분류 문제에서는 많은 입력변수들이 소비자들의 행위에 관련된 행태변수(behavioral variable)인 경우가 많아 더욱이 이러한 전제조건들을 충족시키는 경우가 많지 않다. MDA의 정규분포의 가정에 대한 문제점을 해결하기 위한 통계적 모형으로 나온 것이 로지트분석(logistic regression : Logit)모형이다. 그러나 Logit 모형 역시 선형관계를 기본으로 하고 있어 비선형관계를 포착할 수 없는 문제점을 내포한다.

이러한 통계적 모형들의 한계를 극복할 목적으로 인공신경망 모형이 분류문제의 해결에 도입되었다. 인공신경망은 다양한 데이터의 내생적 관계를 찾아내기 위한 정보처리시스템으로 입력층(input layer), 은닉층(hidden layer) 및 출력층(output layer)으로 구성된다. 입력층은 외부로부터 입력자료를 받아들여 이를 은닉층으로 전송하며 은닉층은 입력 값을 받아 이를 처리한 뒤 처리결과를 출력층으로 전송하고 출력층은 최종 출력값을 산출한다. 인공신경망 모형은 데이터를 처리하는 은닉층이 블랙박스적 특성을 띠고 있어 변수들간의 상관관계를 뚜렷이 표출하지 못하는 단점이 있음에도 불구하고 이 모형이 학계 및 산업계에서 관심을 끌고 있는 이론적 배경은 인공신경망 모형이 복잡한 비선형적인 관계를 표현할 수 있는 적응능력을 갖고 있기 때문이다. 즉 통계적 모형의 전체가 되는 여러 가지 가정사항을 충족하지 못하는 상황에서도 그 적용의 타당성이 보장될 수 있기 때문이다.

인공신경망 모형과 전통적 통계모형의 예측성과 비교는 많은 연구에서 인공신경망 모형이 더 우수한 것으로 판명되었다. Sharda[25]는 인공신경망 모형을 적용한 42개 연구들을 조사한 결과 30개의 연구에서 인공신경망 모형이 전통적 통계모형보다 더 우수한 것으로 나타났다고 보고하고 있다. Sharda는 인공신경망 모형이 갖는 통계모형에 대한 이점으로 통계모형의 확률분포의 가정에서 자유로우며, 비선형적 관계를 갖는 유형을 분류할 수 있으며, 불완

전한 데이터에 적용이 가능하다는 점을 들고 있다.

소비자의 행태를 분석하는 마케팅 연구에서 설문서에 의하여 수집된 데이터에 대하여 MDA와 Logit 같은 통계적방법이 널리 적용되어 왔다. 그러나 설문서 데이터에 통계적 모형을 적용하는대는 비선형성, 노이즈(noise), 실측데이터(missing data) 등 많은 문제점들을 내포하고 있다. 소비자 행동 연구와 관련한 인공신경망 모형의 강점은 초기에 제품 속성이나 지각, 그리고 행동 사이의 모수(parametric) 관계를 미리 가정할 필요 없이 인간의 뇌를 모방하여 비선형적인 과정을 추정할 수 있는 능력에 있다. 시장의 글로벌화로 경쟁이 점차 격화되는 상황에서 마케터로서는 표적고객의 행동을 예측 분류하는데 있어 약간의 효율성을 개선할 경우 엄청난 마케팅비용을 절감할 수 있는 등 경쟁상 위치를 대폭 제고시킬 수 있다. 따라서 기존의 고객 분류방법보다 더 타당성(robust)이 있고 정확한 분류방법을 이용할 수 있다면 효율성 증대를 통한 경쟁력 제고라는 측면에서 마케터에게 큰 이점을 제공할 것이다.


본 연구의 목적은 마케팅분야의 중요한 연구 주제의 하나인 소비자 선택 예측문제에 인공신경망 모

형의 적용가능성을 검토함으로써 전통적인 통계적 방법의 한계를 극복할 수 있는 가능성에 대하여 검토하는 것이다. 이를 위하여 할인점과 백화점의 식품점 고객을 대상으로 수집한 설문데이터를 하나의 분류문제로 구성하여 전통적인 MDA, Logit 및 인공신경망 모형으로 분석하고 그 결과를 비교한다.

2. 마케팅 연구와 인공신경망 모형

2.1 인공신경망 개요

인공신경망 모형은 다양한 형식으로 모형을 구축할 수 있는 비모수(nonparametric)적 분석방법이다. 인공신경망 모형은 계산과 조정이 이루어지는 다수의 노드(node)를 갖는 2개 이상의 층(layer)으로 이루어지며 각 층의 노드들은 네트워크로 연결된다. 이 네트워크는 노드간의 연결강도인 가중치를 조정하면서 병렬적인 처리에 의하여 학습을 한다. 모형의 각 노드는 다른 노드 또는 외부로부터 입력신호를 받아서 이를 전이함수(transfer function)를 통하여 처리하며 그 변환된 결과를 다른 노드 또는 최종 출력으로 보낸다. 인공신경망은 네트워크 구



[그림 1] 전형적인 3계층 인공 신경망 구조

조로 구성되는데 이는 층의 수(number of layers), 각 층의 노드 수, 각 노드들이 어떻게 연결되는가에 따라 그 구조의 특성이 결정된다.

가장 널리 사용되는 인공신경망은 다층퍼셉트론(multi-layer perceptron : MLP)으로 모든 노드와 층은 입력층으로부터 출력층으로 정렬된다. [그림 1]에서 첫 번째 또는 최하위 층은 입력층으로 외부로부터 관련정보를 받아 네트워크에 입력한다. 최상위 층은 출력층으로 모형의 해를 출력한다. 중간층은 은닉층으로 인공신경망이 복잡한 비선형적 패턴을 식별하는데 중요한 층이다. 분류문제에 있어 MLP 모형은 전형적으로 하나 또는 두 개의 은닉층을 갖는다.

다른 통계적 모형의 경우와 같이 인공신경망 모형을 예측 목적으로 사용하기 위해서는 모형의 계수인 가중치들이 추정되어야 한다. 이 가중치들을 추정하는 과정을 훈련(training)이라 하며 분류문제에 있어서 훈련은 지도학습(supervised learning) 또는 자율학습(unsupervised learning)에 의하여 수행된다. 지도학습은 입력데이터와 해당 출력이 사전에 알려져 있어 입력데이터가 해당 출력을 생성하도록 가중치를 반복적으로 조정하여 생성된 출력값의 오차를 최소화하는 알고리즘에 의해 수행되며 자율학습은 사전에 클래스(class)에 대한 정보가 없이 자기조직화 알고리즘에 의하여 클래스를 구분한다.

지도학습 모형에서 은닉층의 값은 입력층 각 노드의 입력값과 가중치에 의해서 계산되고 은닉층의 각 노드는 모든 입력노드로부터 가중치가 가해진 값을 누적시켜 그 가중합에 적절한 전이함수를 적용하여 출력노드로 보내는 값을 계산한다. 입력 데이터 벡터를 $x = (x_1, x_2, \dots, x_n)$ 이라고 하고, y 를 출력, w_1 과 w_2 를 입력노드에서 은닉노드와 은닉노드에서 출력노드로의 가중치라고 하면 세계의 층으로 구성된 MLP 모형은 다음과 같은 비선형 모형으로 정의될 수 있다.

$$y = f_2(w_2 f_1(w_1 x))$$

여기서 y 는 출력값을 의미하며 f_1 과 f_2 는 은닉층과 출력층의 전이함수를 뜻한다. 가장 널리 사용되는 f_1 과 f_2 함수는 시그모이드(sigmoid)함수와 쌍곡탄젠트(hyperbolic tangent) 함수로 그 수식은 다음과 같다.

$$\text{Sigmoid 함수 : } f_1(x) = f_2(x) = (1 + e^{-x})^{-1}$$

Hyperbolic tangent 함수 :

$$f_1(x) = f_2(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$$

네트워크를 훈련하는 목적은 전체적인 오차의 척도인 평균제곱오차(MSE)를 최소화하는 w_1 과 w_2 를 추정하는 것이다. 따라서 이러한 학습과정은 제약 없는(unconstrained) 비선형 최소화문제이며 가장 잘 알려진 학습방법은 역전파(backpropagation)알고리즘이다[30]. 역전파학습 인공신경망 모형이 가장 널리 적용되고 있는 이유는 첫째, 다양한 기업경영 관련 문제가 분류의 문제로 구성될 수 있는데 이는 전방향(feedforward)네트워크 모형에 적합한 문제이며, 둘째, 전방향네트워크모형의 학습 알고리즘인 역전파학습은 이론적으로 잘 정립되어 이해하기가 용이하다는 점이며, 셋째, 이 모형에 대한 각종 상용 소프트웨어들이 개발되어 쉽게 실세계 문제에 적용할 수 있다는 점 때문이다.

2.2 인공신경망을 이용한 마케팅연구

마케팅분야는 재무관련분야에 비하여 상대적으로 인공신경 모형의 적용이 활발하지 못한 분야에 하나이다. Davis et al.[9]은 인공신경망을 이용하여 은행의 현금자동입출금기(ATM)에 대한 고객들의 긍정적/부정적 태도를 분석하였다. 저자들은 개인적 인터뷰를 통하여 수집한 고객들의 태도척도(ATM서비스에 대한 기대, ATM 사용에 따른 위험 인식정도, 신뢰도 등) 데이터를 3계층 역전파 학습 인공신경망 모형에 입력하여 고객을 우호적 그룹과 부정적 그룹으로 분류하여 은행의 전략수립에 기여할 수 있는 의미 있는 결과를 도출하였다.

대부분의 인공신경망 적용 연구는 분석결과를 전통적인 통계모형과 분류적중률 측면에서 비교하였다. Fish et al.[12]은 산업마케팅에서 대상이 되는 시장을 두 그룹 및 세 그룹으로 분류하는 문제에서 기존 통계적 분류방법인 MDA 및 Logit 모형과 인공신경망의 분류적중률(hit ratio)을 비교 분석하였다. 이 분석은 사실적 데이터와 인구통계적 데이터를 입력 패턴으로 사용한 두 그룹 분류문제에서 그 적중률이 MDA 68%, Logit 72%, ANN 74%로 인공신경망 모형이 우수한 결과를 나타내는 것으로 보고하고 있다.

Dasgupta et al.[8]은 설문에 의하여 수집된 개인고객의 라이프스타일(lifestyle)변수를 사용하여 고객을 금융적 위험에 대응하는 태도에 따라 고위험(high risk) 그룹과 저위험(low risk) 그룹으로 분류하는데 역전과학습 인공신경망 모형을 적용하였으며 그 결과를 MDA, Logit과 비교하였다. 라이프스타일 데이터는 인구통계적 데이터 또는 지역적 데이터에 비하여 노이즈(noise)가 많은 데이터로 개인 고객의 행동분류에 적용하기가 힘든 데이터이다. 따라서 검증 표본에 대한 분류적중률이 MDA 55.5%, Logit 55.2%, ANN 58.9%로 저조한 결과를 나타냈다. 그러나 세 모형 가운데 ANN 모형이 가장 우수한 성과를 나타낸 것으로 보고하고 있다. West et al.[27]에서 성격이 유사한 미국의 양판점인 Kmart, Montgomery Ward 및 Sears Reback에 대하여 점포 선택에 대한 설문데이터 및 점포별 특성데이터를 입력변수로 하여 MDA, Logit, ANN 모형을 적용 그 분류성적을 분석한 결과 평균 분류적중률은 MDA 70.8%, Logit 70.1%, ANN 79.3%로 ANN 모형이 다른 두 모형에 비하여 훨씬 우수한 것으로 나타났다. 두 연구[8, 27] 모두에서 MDA 모형과 Logit 모형의 성과는 비슷한 것으로 나타나고 있다. 이는 입력데이터가 노이즈가 많은 설문데이터를 포함하기 때문인 것으로 판단된다.

Balakrishnan et al.[4]은 처음으로 자율학습 모형인 FSCL(Frequency Sensitive Competitive

Learning)알고리즘을 커피의 브랜드 선택 데이터에 적용하여 소비자를 2~5개의 그룹으로 세분화하는 연구를 하였으며 이를 전통적인 군집(cluster) 분석방법인 K-means 알고리즘에 의한 분류결과와 비교하였다. 여기서는 인공신경망 모형이 전통적인 방법보다 낮은 성과를 보였으며 인공신경망 모형을 K-means 방법의 보완방법으로 사용함으로써 두 방법을 단독으로 사용했을 때 보다 더 좋은 성과를 얻을 수 있다고 보고하고 있다.

인공신경망을 이용한 과거의 마케팅 연구를 보면 소비자행동 분류 문제에 있어 입력변수들을 가지고 알려지지 않은 그룹으로 구분해내는 자율학습 모형이 더욱 적합할 것으로 생각되나 소비자행동 연구에서 자율학습 모형을 적용한 것은 Balakrishnan et al.[4]의 연구 하나뿐이며 나머지는 모두 지도학습 모형인 역전과학습 모형을 사용하여 미리 알려진 그룹에 대한 데이터를 훈련표본과 검증표본으로 나누어 훈련하고 검증표본에 대한 분류적중률을 분석하였다.

이론적으로 인공신경망 모형은 비선형적인 데이터의 패턴을 잘 식별해 내고 데이터의 노이즈, 실측데이터 등을 잘 처리할 수 있는 능력이 전통적인 통계적 방법보다 우수한 특성을 가지고 있다. 소비자행동 분류 문제에서 사용되는 변수는 소비자의 주관적인 태도를 측정하는 변수로 기업도산 예측, 신용평가 등의 분류 문제에 사용되는 객관적 변수보다 보다 훨씬 많은 노이즈 및 실측데이터를 포함할 수밖에 없다. 따라서 마케팅 분야는 Vellido et al.[26]에서 언급한 것처럼 인공신경망을 적용하여 가장 큰 효과를 볼 수 있는 분야이다. 그러나 재무 분야, 생산관리분야 등에 비해서 마케팅분야에서 인공신경망의 적용 연구가 상대적으로 미약한 편이다. 특히 우리 나라에서 마케팅분야에 인공신경망 모형을 적용한 연구는 거의 없는 실정이다.

3. 연구모형 및 방법

본 연구에서는 식료품 구입을 위하여 백화점을

이용하는 고객과 할인점을 이용하는 고객을 대상으로 설문을 통하여 점포선택 행태관련 데이터를 수집하고 역전파학습 인공신경망 모형을 적용하여 이를 분류하고 이를 MDA 및 Logit 모형의 분류적 중률과 비교하여 소비자 선택행동의 예측 문제에 대한 인공신경망 모형의 적용가능성을 검토한다.

3.1 모형의 식별

인공신경망 분야는 그 적용이 급속히 성장하는 분야로 과거의 연구에서 50가지가 넘는 모형들이 제안되었다[7]. 그리고 각 모형은 고유의 특성을 가지고 있어서 특정 분야의 현상에 선별적으로 적용할 수 있는 것으로 분석되고 있다[3]. 분석가가 주어진 문제를 해결하기 위하여 적절한 인공신경망 모형을 찾아내고 선택하는 것에 대하여 아직도 밝혀진 일반적인 규칙은 없다. 따라서 단일 신경망모형을 사용할 경우 주어진 상황과 모형을 구축하는 사람의 자의적 판단 등에 의하여 최선의 모형이 달라질 수 있는 취약점이 있다.

인공신경망의 특정 모형을 결정하기 위해서는 먼저 네트워크의 형태를 결정해야 하는데 분류문제에서 가장 흔히 사용되는 모형이 다층퍼셉트론(MLP)이며 이 모형에서 가장 널리 사용되는 학습방법이 역전파학습 알고리즘이다. 본 연구에서도 하나와 두개의 은닉층을 갖는 두 가지 MLP 구조를 사용하여 분석하였다. 일단 네트워크의 구조와 학습방법이 결정되면 다음과 같은 사항이 결정되어야 한다.

- 네트워크 크기 : 입력층 노드의 수, 은닉층 노드의 수, 출력층 노드의 수
- 전이함수(transfer function) : 선형(linear), sigmoid, hyperbolic tangent 함수 등
- 학습규칙 : 델타(Delta) 규칙, 표준화누적델타(Normalized cumulative delta) 규칙 등

인공신경망 모형의 구축에서 어려운 문제중의 하나가 적절한 네트워크의 크기를 결정하는 것이다. 대부분의 경우 모형설계자는 경험적 규칙이나 과거의 연구에서 성공적으로 적용되었던 구조를 답

습한다[3]. 네트워크의 크기를 결정하는 것은 계층의 수, 입력층의 노드수, 은닉층의 노드수, 출력층의 노드수를 결정하는 것이다.

3.1.1 계층의 수(Number of layers)

MLP 네트워크에는 하나의 입력층과 하나의 출력층이 있어야 함으로 계층의 수를 결정하는 것은 은닉층의 수를 결정하는 것이다. 은닉층을 도입하는 주된 목적은 입력층의 입력 데이터를 출력층의 바람직한 출력데이터로 변화시키는 필터(filter)의 역할을 수행하는 것이며 이는 데이터에 내재한 비선형적인 관계를 도출하는 수단이다. 과거의 인공신경망의 적용연구에서 하나의 은닉층을 갖는 구조가 가장 성공적으로 사용되었으나 본 연구에서는 비선형적인 요소가 많을 것으로 예상되는 소비자의 행태적 데이터를 사용함으로 은닉층이 하나인 경우와 두 개인 경우를 병행 적용하여 그 성과를 검토한다.

3.1.2 입력층 노드의 수

입력층의 노드 수는 입력변수의 수와 같다. 그러나 최소한의 노드로 구성된 모형이 더 복잡한 모형보다 그 결과를 보편화(generalize)하는데 유리한 것으로 보고되고 있다[21, 23]. 설명력을 유지하면서 입력데이터를 단순화하는 방법은 두 그룹을 분류하는 통계적 유의성 검증, 단계적 모형추정(stepwise), 요인분석에 의한 유의성이 있는 요인의 도출 등을 들 수 있다.

본 연구에서 소비자 행태를 측정하기 위하여 사용된 설문서의 29개 항목가운데 두 집단 평균차이에 대한 t-검정을 실시한 결과 백화점과 할인점 고객을 구분하는데 유의성이 있는 것은 19개 항목 그리고 3개의 인구통계적 항목 가운데 유의성이 있는 것은 2개 항목(연령 및 소득)으로 통계적 유의성 검증에서 21개 항목이 선정되었다. 단계적 추정에서는 단계적 MDA를 적용한 결과 11개의 행태측정 항목과 2개의 인구통계적 항목 등 13개 항목이 유의성이 있는 것으로 선정되었다. 그리고 행태측정 29개 항목에 대한 요인분석에서 3개의 요인을

도출하였다. 따라서 이러한 3가지 경우를 입력변수로 하여 분석하였다(부록 : 설문항목 참조).

3.1.3 은닉층 및 출력층의 노드수

은닉층의 노드수도 일정한 규칙은 없으나 한 선행연구는 과다한 수의 은닉층 노드를 갖는 ANN 모형은 훈련표본 외의 데이터에 대한 분류능력을 저하시킨다고 보고하고 있으며[22], 또 다른 연구는 은닉층의 노드 수는 입력층의 노드 수보다 작아야 보고하고 있다[29]. BrainMaker[6]는 입력노드수와 출력노드 수를 합한 값의 50%~75% 정도의 은닉노드를 도입하는 것을 일반원칙으로 제안하고 있다. 이에 따르면 본 연구에서 은닉층의 노드수는 10~15개가 된다. 한편 NeuralWorks[21]는 은닉층의 노드수를 훈련에 가용한 표본의 수에 비례하여 다음과 같이 제안하고 있다.

$$h = \frac{\text{훈련 표본수}}{5 \times (m + n)} : m = \text{출력노드수}, \\ n = \text{입력노드수}$$

이러한 제안에 의하면 $319 / (5 * (21 + 1)) \approx 3$ 개가 된다. 따라서 본 연구에서는 첫 번째 은닉층의 노드수가 5, 10, 15개인 세가지 모형을 검토한다. 한편 두 번째 은닉층의 노드수는 5, 10개인 두 가지 경우를 검토한다.

출력층의 노드 수는 본 연구가 2개 그룹의 분류 문제이므로 하나이면 충분하다(0 : 백화점고객, 1 : 할인점 고객).

3.1.4 전이함수 및 학습규칙

전이함수는 특정 은닉층에서 하위 은닉층 또는 입력층으로부터 신호를 전달받아서 다음계층으로 전달하는 출력신호를 생성하는 함수이다. 즉 은닉층의 j 번째 노드의 출력 $O_j = T_j(\text{net}_j)$ 로 표현된다. 여기서 T_j 는 노드 j 에 적용되는 전이함수이며 net_j 는 노드 j 에 연결된 모든 하위노드로부터의 입력을 노드간의 연결강도(가중치)를 적용하여 산출된 가중합이다.

가용한 여러 가지 전이함수 가운데 하나를 선택

하는 것은 입력데이터의 성격과 네트워크에 무엇을 학습시키려는가에 달려 있다. 경험에 의하면 기업도산 예측이나 투자대상 주식 선정 등 예외적인 구조를 식별하는 문제에 있어서는 쌍곡탄젠트(hyperbolic tangent)함수가 우수한 성과를 나타내며, 특정 객체를 다른 객체들로부터 분류해내는 문제에서는 시그모이드(sigmoid)함수가 우수한 성과를 나타내는 것으로 보고되었다[16]. 따라서 본 연구에서는 역전파학습 네트워크에 대하여 쌍곡탄젠트 함수와 시그모이드함수를 적용하여 분석한다.

한편 학습규칙(learning rule)은 서로 다른 계층 노드간의 연결강도(weight)를 조정하는 규칙이다. 일반적으로 무작위성이 포함된 데이터에 대해서는 델타규칙이 좋은 성과를 나타내는 것으로 판명되었다[16]. 델타규칙을 적용할 경우에는 학습에서 데이터를 무작위로 입력하는 것이 중요하다. 따라서 대부분의 인공신경망 소프트웨어 패키지는 데이터를 난수(random number)에 의해서 무작위로 입력하는 기능을 제공한다. 델타규칙에서 데이터의 무작위성에 따른 문제점을 보완하기 위하여 도입된 학습규칙이 표준화누적델타규칙이다. 표준화누적델타규칙은 무작위성의 문제를 경감하기 위하여 연결강도의 변화를 일정 케이스 수(epoch)만큼 누적시켰다가 수정하는 것이다. 이렇게 함으로써 수정치를 평균화하여 학습에 입력되는 데이터의 순서에 따른 영향을 경감할 수 있다. 본 연구에서는 델타규칙과 표준화누적델타규칙의 두 가지 학습규칙을 함께 분석한다.

따라서 본 연구에서 백화점 고객과 할인점 고객을 분류하는데 적용하여 검토할 역전파학습 모형에 대하여 두 가지의 학습규칙(델타규칙, 표준화누적델타규칙), 두가지 전이함수(시그모이드, 쌍곡탄젠트), 그리고 은닉층이 하나인 3가지 네트워크모형(21-5-1, 21-10-1, 21-15-1), 은닉층이 두 개인 2가지 네트워크모형(21-x-5-1, 21-x-10-1)의 조합에 따른 총 24(2×2×3×2)가지 모형을 검토하여 분석한다.

본 논문에서 인공신경망 모형을 분석하는데 사

용된 소프트웨어는 NeuralWorks Professional II /Plus 패키지이다.

3.2 데이터의 수집 및 처리

3.2.1 표본의 구성 및 데이터 수집

본 연구의 목적을 효과적으로 달성하기 위하여 표본은 서울과 경기도 (일산, 분당 신도시)에 거주하는 소비자로서 백화점 혹은 할인점의 식품점을 주로 이용하는 여성을 대상으로 하였다. 그리고 비교의 목적을 달성하기 위하여 서울과 경기도 지역의 백화점과 할인점 식품점 앞에서 면접 당일 식품점에서 구매를 한 소비자를 대상으로 체계적 표본추출법(systematic sampling)을 사용하여 면접 대상을 선정하였다. 특정 요일의 특성이 반영되는 것을 피하기 위해 1주일 전 기간동안 면접을 진행하였다. 각각 할인점과 백화점을 주로 이용하며 당일 실제로 할인점과 백화점의 식품점에서 구매를 한 응답자를 대상으로 면접을 진행하여 실제 주 구매자를 확인 분류하였다. 이러한 구분은 소비자의 선택행동을 구분하는데 이용되었다. 설문지는 485부가 수집되었으며 불성실하게 응답한 30부를 제외하고 455부를 최종적으로 분석에 이용하였다.

3.2.2 측정도구

본 연구는 백화점과 할인점 등 점포별 고객들의 특성에 차이가 있다는 기존의 연구들[11, 17-19]을 이론적 바탕으로 하여, 이러한 고객들의 특성의 차이가 다시 백화점과 할인점을 선택하여 직접 구매하게 하는 요인으로 작용한다는 가정 하에 진행되었다.

점포 선택의 최종 평가 요인은 가격 요인과 품질 등의 요인을 종합적으로 고려한 인식가치[15]이다. 따라서 가치의식이나 이러한 가치의식의 결정 변수인 가격의식 혹은 점포의 고급성에 대한 소비자의 인식이 점포 선택에 영향을 주므로 이러한 요인에 관련된 고객의 특성이 고객의 점포선택 행동을 예측하는 주요 요인으로 작용할 것이다. 또한 본래 고객이 소유한 절약성의 정도도 백화점과 할인점을 선택하게 하는 주요 요인[17]이 될 것으로 판단

하였다.

따라서 이러한 요인들에 대한 고객특성을 측정하는 척도를 신뢰도와 타당성이 검증된 기존의 연구를 활용하여 본 연구에 사용하였다. 즉 가치의식(value-consciousness : 7항목), 가격의식(price-consciousness : 5항목)에 관한 척도는 Lichtenstein et al.[18], 긍지의식(prestige : 9항목) 척도는 Erickson and Johansson[11], 절약성(frugality : 8항목) 척도는 Lastovicka et al.[17]의 연구 결과를 이용 총 29개의 설문서 항목으로 만들어졌다. 인구통계학적 변수는 나이, 학력, 소득 등 3개 항목의 소매점 점포 선택에 영향을 주는 것으로 알려진 변수로서 구성하였다(부록 : 설문서 항목 참조).

3.2.3 입력데이터의 사전처리

인공신경망에서 사용되는 학습규칙은 대부분 입력자료로부터 가중치에 대한 변화정도를 계산하는 방법으로 수행된다. 따라서 입력자료의 변화범위가 크면 클수록 해당 입력자료에 따른 가중치의 조정이 크게된다. 어떤 경우에는 가중치의 조정이 너무 커서 해당노드의 출력이 포화상태에 이르는 경우가 있어 학습이 정체되거나 불가능하게 된다. 한편 입력자료의 변화범위가 너무 작을 경우에는 입력자료에 내포된 정보의 내용이 상실되거나 신경망에서 효과적으로 학습에 사용되지 못하는 결과를 초래한다[21].

이러한 문제를 경감시키기 위하여 통상 입력자료에 대한 사전처리를 실시함으로써 모든 입력자료의 변화범위를 조정한다. 이는 대부분의 경우 입력자료에 내포된 정보를 상실하지 않으면서 신경망의 학습효과를 증진시킨다. 입력자료의 사전처리에 주로 사용되는 방법은 Max-Min변환($X'_i = (X_i - X_{\min}) / (X_{\max} - X_{\min})$)방법, 통계적표준화($X'_i = (X_i - \bar{X}) / S_x$)변환방법 등이 있다.

3.2.4 훈련표본(training sample)과 검증표본(test sample)의 구분

인공신경망 모형을 구축하기 위해서는 훈련표본과 검증표본이 필요하다. 훈련표본은 모형의 추정

에 사용되는 표본이며 검증표본은 분류적중률의 검증에 사용된다. 따라서 훈련표본과 검증표본의 선정은 모형의 성과에 영향을 미칠 수 있다. 전체표본을 훈련표본과 검증표본으로 나누는 비율에 대한 일반적인 지침은 없으나 문제의 성격, 데이터의 형태 및 가용한 표본의 수를 고려하여 결정한다 [29]. 선행연구에서 대부분의 저자들은 훈련표본과 검증표본의 비율을 90 : 10, 80 : 20 또는 70 : 30 등으로 구분하여 사용하였다.

본 연구에서는 총 455개의 표본 가운데 319 (70%)를 훈련표본으로, 136(30%)개를 검증표본으로 구성하였다. 그리고 표본 구분에 따른 편기(bias)의 문제를 경감하기 위하여 중복을 최소화하면서 서로 다른 5개의 훈련표본/검증표본 셀을 도출하여 사용하였다. 여기서 훈련표본에는 백화점 고객에 대한 표본이 160개, 할인점 고객에 대한 표본이 159개 포함되었으며 검증표본에는 각각 68개씩의 표본을 포함하고 있다.

4. 결과분석

4.1 다중판별분석 결과와 인공신경망모형분석 결과의 비교

본 연구는 우선 분석대상이 되는 24가지 인공신경망모형 가운데 500여회의 실험적 실행(run)에 의하여 두 가지 학습규칙, 두 가지 전이함수, 두 개의 너층(1개와 2개)의 조합($2^3=8$)에 따른 8개 그룹별로 검증표본에 대한 평균분류적중률을 기준으로

가장 성과가 우수한 모형을 한가지씩 선별하여 분석대상 모형을 8가지 모형으로 축소하였다. 여기서 평균 분류적중률은 백화점 고객의 분류적중률과 할인점고객의 분류적중률을 평균한 것이다.

입력데이터의 변환에 관하여 Shanker et al.[24]은 통계적표준화 변환방법에 따른 변환이 분류성과를 개선하는 것으로 보고하고 있으며 실제 본 연구의 실험적 시행에서도 이 방법이 분류성과를 개선하는 것으로 나타나서 이후의 분석에서는 통계적표준화 방법에 의하여 변환된 입력데이터를 사용하였다.

인공신경망 모형을 훈련함에 있어 야기되는 문제의 하나가 과도훈련(over training)의 문제이다. NeuralWorks[21]는 이 문제의 해결을 위하여 네트워크의 크기를 작게 하거나 패키지에서 제공하는 BestSave 기능을 이용할 것을 제안하고 있다. Best-Save 기능은 모형의 훈련/검증 과정에서 검증결과가 가장 우수한 모형을 추정간에 저장하도록 하여 사용자가 훈련대상 모형에 대하여 최적의 모형계수를 찾아 낼 수 있도록 하고 있다. 따라서 여기서도 이 기능을 사용하여 검증표본에 대한 분류적중률을 구하였다. 선택된 8가지 모형은 <표 4-1>과 같다.

<표 4-1> 분석대상 인공신경망 모형

학습규칙 전이함수	델타규칙	표준화누적델타 규칙
시그모이드함수	21-5-1(DS-1)	21-5-1(NS-1)
	21-5-5-1(DS-2)	21-5-5-1(NS-2)
쌍곡탄젠트함수	21-10-1(DT-1)	21-5-1(NT-1)
	21-10-5-1(DT-2)	21-5-5-1(NT-2)

<표 4-2> MDA, Logit 및 인공신경망모형의 성과 비교

(분류적중률 : %)

구분	MDA	Logit	DS-1	DT-1	NS-1	NT-1	DS-2	DT-2	NS-2	NT-2	
훈련 표본	백화점	85.01	79.62	85.06	90.69	82.50	86.98	87.88	87.75	81.25	93.50
	할인점	76.38	79.22	80.32	83.46	75.04	92.08	76.98	88.49	74.59	90.38
	평균	77.08	79.42	82.69	87.07	78.77	89.93	82.43	88.12	77.92	91.94
검증 표본	백화점	73.02	74.18	76.62	75.44	74.41	77.94	80.15	74.41	73.53	76.76
	할인점	76.14	75.41	75.30	75.44	74.27	73.68	73.25	77.94	73.61	73.68
	평균	74.57	74.79	75.96	75.44	74.34	75.81	76.25	76.18	73.57	75.22

인공신경망 패키지에서는 입력데이터 셀의 입력 순서를 난수에 의하여 무작위로 반복학습을 시행함으로써 선택되는 난수에 따라 그 성과가 달라질 수 있다. 따라서 각 모형에서 5개 훈련표본/검증표본 셀에 대하여 한 셀에 2회씩 총 10회의 훈련/검증 결과를 산출하고 그 평균 분류적중률로 성과를 비교하였다.

<표 4-2>에서 보는 바와 같이 MDA 모형과 Logit 모형은 선행연구 결과에서와 같이 검증표본에 대하여 비슷한 성과를 나타내고 있으며, 인공신경망모형은 훈련표본의 분류적중률은 모든 모형이 MDA 모형의 적중률보다 높게 나타나고 있다. 검증표본에서도 표준화누적델타 학습규칙과 시그모이드 전이함수를 채용한 2개모형(NS-1, NS-2)을 제외한 6개 모형은 MDA 및 Logit 모형보다 우수한 성과를 나타내고 있다. 학습규칙에서는 델타학습규칙(DS, DT)이 표준화누적델타규칙(NS, NT)보다 더 우수한 성과를 나타냈다. 한편 전이함수의 비교에서는 델타 학습규칙을 사용한 모형에서는 시그모이드 함수가 표준화누적델타 학습규칙을 사용한 모형에서는 쌍곡탄젠트 함수가 약간 우수한 성과를 나타내고 있다.

현재 기업들은 경쟁의 심화로 불특정 다수를 대상으로 하는 대중마케팅에서 정확한 대상을 찾아 마케팅을 하는 표적마케팅 또는 직접마케팅(direct marketing)으로 전환하고 있다. 따라서 마케터로서는 고객행동을 예측하여 분류를 좀 더 정확히 할 수 있는 모형을 이용할 수 있으면 마케팅활동의 효율성을 크게 제고할 수 있다. 즉 백화점과 할인점 고객의 모집단은 대단히 크므로 고객행동 분류 적중률을 1%만 제고한다 해도 마케팅 비용절약 측면에서는 상당히 큰 성과를 기대할 수 있다. 일반적으로 마케팅 조사자의 역할이 소비선택행동 예측에 있다는 것

을 가정한다면 인공신경망 모형을 적용함으로써 MDA 또는 Logit 모형을 적용할 경우보다 훨씬 우수한 성과를 얻을 수 있을 것으로 판단된다.

4.2 모형의 단순화

4.2.1 다중판별분석과 인공신경망의 연계

인공신경망 모형에서는 대상변수 가운데 유의성이 있는 변수를 찾아내는 검증된 방법이 없다. 이견창외[1]는 기업도산을 예측함에 있어 다중판별분석에서 유의성 있는 것으로 판명된 재무비율을 인공신경망 모형의 입력변수로 사용함으로써 다중판별분석(63%)에 의한 것보다 우수한 예측률(70%)을 나타낸다고 보고하고 있다.

다중판별분석에서 유의성 있는 최소한의 변수를 찾아내는 방법의 하나가 단계적(stepwise) 방법이다. 단계적 방법에서 29개의 행태 측정항목 가운데 11개 항목이 유의성이 있는 것으로 나타났으며, 3개의 인구통계 항목 가운데 2개(연령, 소득)가 유의성이 있는 것으로 나타났다. 이 유의성 있는 변수들을 인공신경망의 입력변수로 사용하여 앞에서 선정된 8개의 인공신경망 모형(<표 4-1>)에 대하여 입력변수만 21개를 13개로 대체하여 분석한바 그 결과는 <표 4-3>과 같다(부록: 설문서 항목 참조).

<표 4-3>의 결과를 <표 4-2>의 결과와 비교할 때 다중판별분석의 단계적 방법에서 식별된 유의성 있는 변수들만 입력변수로 사용하여 모형을 단순화함으로써 0.5~3% 정도의 적중률 개선이 있었음을 알 수 있다. MDT-1 모형이 가장 높은 적중률(77.13%)을 보이고 있다. 이러한 모형의 단순화로 적중률의 개선과 함께 보편화능력을 제고함으로써 실제업무에 적용에서는 21개의 입력변수를 갖는 모형보다 훨씬 유리할 것으로 판단된다.[23]

<표 4-3> 단계적 MDA 유의변수 모형의 평균 분류적중률(%)

	MDA	Logit	MDS-1	MDT-1	MNS-1	MNT-1	MDS-2	MDT-2	MNS-2	MNT-2
훈련	79.63	80.13	81.62	85.61	79.81	86.74	81.28	87.62	78.68	88.06
검증	74.07	74.51	76.30	77.13	75.81	75.88	76.69	76.33	76.10	75.74

4.2.2 사전지식에 의한 네트워크의 단순화

마케팅 연구의 요소분석(factor analysis) 및 주 요인분석(principle component analysis)에서처럼 인공신경망 연구에서 Davis et al.[9]은 입력층으로부터 은닉층으로의 가중치(weights)와 은닉층으로부터 출력층으로의 가중치를 해석하여 각 은닉층을 고객의 행태에 의미있는 그룹으로 해석하였다.

본 연구에서 소비자의 행태 측정에 사용된 가치 의식(A), 가격의식(B), 절약성(C), 긍지의식(D) 및 인구통계 지표(E)는 다른 마케팅연구[11, 17, 18]에서 검증된 항목들이다. 이는 의미있는 그룹으로 이 5개 그룹을 인공신경망의 은닉층으로 구성함으로써 네트워크를 단순화할 수 있을 것이다. 따라서 각 그룹을 은닉층의 노드로 구성하고 각 그룹에 해당되는 입력층의 노드(변수)를 소속 은닉층 노드에만 연결하도록 하여 네트워크를 단순화하고 그 분류적중률을 검토하였다. 즉 입력변수 A_i 는 은닉층 노드 A에만, B_i 는 은닉층 노드 B에만 등으로 연결하는 형식으로 네트워크를 단순화하는 방법이다.

검토된 모형은 은닉층 노드를 5개로 하고 <표 4-1>의 학습규칙-전이함수 조합을 사용한 4개 모형과 앞에서 검토한 21개 입력변수와 13개 입력변수를 사용하는 경우를 망라한 총 8개 모형을 검토하였다. 따라서 네트워크구조는 21-5-1과 13-5-1이며 학습규칙 전이함수 조합은 델타-시그모이드(SD-S, MD-S) 델타-쌍곡탄젠트(SD-T, MD-T), 표준화누적델타-시그모이드(SN-S, MN-S), 표준화누적델타-쌍곡탄젠트(SN-T, MN-T)이다. 이 모형들의 훈련표본과 검증표본에 대한 분류적중률(10회 평균)은 <표 4-4>와 같다.

<표 4-4>의 결과를 <표 4-2> 및 <표 4-3>의 결과와 비교해 보면 21개 입력변수를 갖는 모형에

서는 검증표본에 대한 분류적중률의 저하를 나타내고 있으며 13개 입력변수를 갖는 모형에서는 1% 미만의 분류적중률 개선효과를 나타내고 있다. 이는 가치의식 등 각 행태요소에 대한 측정도구가 해당 행태요소뿐 아니라 다른 행태요소에도 영향을 미치는 노이즈가 내포되어 있기 때문으로 해석할 수 있다.

4.2.3 요인분석(factor analysis)에 의한 모형의 단순화

요인 분석은 입력변수들 간의 상관관계를 분석하여 설명력의 손실을 최소화하면서 입력데이터를 단순화하는 대표적인 방법의 하나이다. 본 연구에서는 요인분석에 의한 입력데이터의 단순화가 인공신경망의 성과에 어떻게 영향을 미치는가를 분석하였다. 이를 위해 29개 행태측정 항목에 대한 데이터로 요인분석을 실시하여 3개의 요인을 도출하였다. 그리고 각 표본에 대한 요인적재값(factor loading)을 구하여 인공신경망의 입력데이터로 사용하였다. 그리고 2개의 인구통계 항목은 그대로 사용하여 총 5개를 입력변수로 하고 하나의 은닉층에 3개의 노드를 갖는 모형(5-3-1)을 구성하고 학습규칙 전이함수 조합인 델타-시그모이드(FD-S), 델타-쌍곡탄젠트(FD-T), 표준화누적델타-시그모이드(FN-S), 표준화누적델타-쌍곡탄젠트(FN-T) 모형에 대하여 분석하였다. 그 평균 분류적중률은 <표 4-5>와 같다.

<표 4-5> 요인분석 도출변수에 의한 모형(5-3-1)의 분류적중률(%)

구 분	MDA	Logit	FD-S	FD-T	FN-S	FN-T
훈련표본	74.19	74.39	74.67	75.57	74.23	75.99
검증표본	71.29	72.17	72.64	76.03	72.57	76.46

<표 4-4> 단순화 모형 분류적중률(%)

구 분	21-5-1				13-5-1			
	SD-S	SD-T	SN-S	SN-T	MD-S	MD-T	MN-S	MN-T
훈련표본	79.20	78.89	75.54	80.59	80.88	80.15	76.69	81.72
검증표본	74.27	75.15	71.99	75.00	75.44	77.47	76.42	76.99

<표 4-5>에서 보는바와 같이 요인분석에 의하여 도출된 변수에 의한 모형은 통계적 모형과 모든 인공신경망 모형에서 분류적중률의 저하를 가져왔다. 이는 공통인자로 데이터를 단순화하는 과정에서 오는 설명력의 손실로 판단된다. 따라서 인공신경망 모형의 경우 노이즈가 있는 행태측정 데이터에서도 요인분석에 의한 모형의 단순화는 바람직하지 않은 것으로 판단된다.

4.3 인공신경망 모형의 평가

본 연구에서는 소비자의 선택행동을 분류할 목적으로 설문서를 통하여 수집한 데이터를 다양한 역전파학습 인공신경망 모형으로 분석하였다. 그리고 예측 분류적중률을 전통적 통계적 모형인 MDA 및 Logit 모형의 결과와 비교하였다. 선행연구[8, 9, 12, 27]들의 결과와 같이 인공신경망 모형이 통계적 모형보다 우수한 분류적중률을 나타냈다. 인공신경망의 SDT-1(77.13%) 모형과 MD-T(77.46%) 모형은 MDA 및 Logit 모형보다 3% 정도 높은 평균분류적중률을 나타냈다.

한편 본 연구에서 검토된 인공신경망 모형은 설문데이터와 인구통계적 데이터를 함께 사용한 모형으로 라이프스타일 설문데이터만을 사용한 Dasgupta et al.[8]의 인공신경망 분류적중률 58.9%보다는 높은 분류적중률을, 설문데이터와 점포특성 등 객관적 데이터를 함께 용한 West et al.[27]의 79.3%보다는 낮은 적중률을 나타냈다. 이는 객관성이 높은 관련데이터를 함께 사용할 경우 분류적중률을 개선할 수 있는 것으로 해석될 수 있다.

검토된 인공신경망 모형들 가운데 21개 변수를 갖는 NT-1 및 NT-2 모형이 일부 표본에서 과도적합(overfitting) 현상이 발생하였으나 좀더 단순화된 13개 변수를 갖는 모형에서는 이러한 현상이 해소되었다. 따라서 표준화누적델타 학습규칙과 쌍곡탄젠트 전이함수를 조합하여 사용할 경우에는 모형을 단순화하는 것이 효과적인 것으로 나타났다.

단계적 MDA에 의해 식별된 유효변수(13개)를

사용한 모형에서 MDA와 Logit 모형은 초기모형(21개변수)과 거의 같은 분류적중률을 보이고 있으나 인공신경망 모형은 모든 모형에서 적중률이 개선되고 있다. 한편 요인분석에 의한 모형(5개변수)에서는 MDA와 Logit은 물론 인공신경망 모형에서도 적중률의 저하를 보이고 있다. 따라서 비선형모형인 인공신경망 모형에서도 어느 정도의 단순화는 성과를 개선하는 반면 과도한 단순화는 설명력의 손실을 가져오는 것으로 판단된다. 또한 은닉층이 2개인 모형들이 은닉층이 1개인 모형들에 비하여 분류적중률을 개선하지 못하는 결과를 나타내어 일반적으로 알려진 과거 연구결과와 같이 행태적 데이터를 사용하는 모형에서도 은닉층이 1개이면 충분한 것으로 분석되었다.

한편 측정도구와 측정요소와의 관계를 이용한 네트워크의 단순화는 입력변수들이 영향을 미치는 경로를 제한하는 것으로 21개변수 모형에서는 단순화 전보다 적중률의 저하를 보였으며 13개변수 모형에서는 단순화 전과 비슷한 적중률을 보였다. 이는 측정도구와 측정요인간의 관계에 노이즈가 많은 상황에서 네트워크 연결의 제한은 성과를 개선에 도움이 되지 못하는 것으로 해석할 수 있다.

5. 요약 및 결론

그동안 인공신경망 모형은 경영분야의 다양한 문제에 대하여 널리 적용되어 왔다. 인공신경망 모형은 통계모형에서 필요한 정규분포, 선형관계 등의 가정을 필요로 하지 않으며 데이터에 노이즈와 실측데이터가 존재하더라도 해당 데이터를 폐기할 필요 없이 처리할 수 있어, 일반적인 데이터를 처리함에 있어 통계모형 보다 더 보편성이 있는 모형으로 평가되고 있다. 과거 실증적 연구결과 인공신경망 모형은 기업도산의 예측, 신용평가 등과 같은 재무분야의 분류문제와 예측문제의 분석에서 통계모형보다 더 우수한 성과를 나타내는 것으로 보고되고 있다.

본 연구는 소비자 행동 연구와 관련하여 인공신

경망 모형이 초기에 소비자가 가지는 태도와 행동 사이의 모수(parametric) 관계를 미리 가정할 필요 없이 비선형적인 관계를 추정하여 소비자 행동을 예측하는데 우수한 성과를 보임을 제시하였다. 마케팅연구에서 소비자 행동을 예측하는 문제는 중요한 관심사의 하나이다. 소비자의 설문데이터를 기반으로 이러한 소비자행동 분류 문제에 대하여 MDA, Logit 등 전통적 통계모형이 그동안 널리 적용되어 왔으며 인공신경망 모형은 다양한 가정의 제한을 받는 통계모형의 한계를 극복하는 대안으로 적용되고 연구되었는바 마케팅 분야는 소비자의 행태적 데이터를 분석해야 하는 특성상 인공신경망 모형을 적용할 경우 가장 큰 효과가 기대되는 분야임에도 불구하고 인공신경망을 적용한 연구가 많지 않은 편이며 이제 연구가 활성화되어 가는 분야이다.

본 연구에서는 소비자의 행태적 데이터를 분석하여 일련의 소비자를 백화점 이용 고객과 할인점 이용 고객으로 분류하는데 지도학습 인공신경망 모형인 역전파학습 모형을 적용하여 그 분류적중률을 산출하고 이를 MDA 및 Logit 모형의 분류적중률과 비교하였다. 검증표본에 대한 분류적중률에서 인공신경망 모형은 MDA 및 Logit 모형보다 우수한 성과를 나타내고 있다. 전통적 통계모형이 요구하는 가정사항을 충족시키지 못하는 경우가 많은 마케팅 연구에서 인공신경망 모형은 전통적 통계모형 보다 더 우수한 성과와 이론적 타당성을 제공하는 모형이 될 수 있다. 본 연구의 결과는 인공신경망 모형이 소비자의 선택을 예측하는데 유용한 수단이 될 수 있다는 것을 보여주고 있어 앞으로 마케팅 분야에 인공신경망 모형의 적용을 활성화시키는데 기여할 것이다.

마케팅에서 소비자를 알려지지 않은 일련의 그룹으로 묶는 그룹화(clustering)문제가 더 중요한 과제인바 이에 대해서는 인공신경망의 자율학습(unsupervised learning) 모형이 가장 적합한 모형이다. 이러한 그룹화문제에 자율학습 모형을 적용한 연구는 거의 없는 실정으로 향후 마케팅분야

에 대한 자율학습 모형의 적용에 대한 활발한 연구가 필요하다고 판단된다.

〈부록〉 : 설문서 항목 -

I. 이용 점포("V" 표시)

① 백화점 ② 할인점

* 인공신경망 모형의 출력노드의 값으로 백화점은 "0", 할인점은 "1"로 출력값이 0.5 이하면 백화점으로 0.5이상이면 할인점 고객으로 분류한다.

II. 다음 각 문항에 대하여 매우그렇다(1), 보통이다(4), 전혀그렇지않다(7)를 기준으로 1~7 사이의 값에 "V" 표시를 하도록 설계되었음.

A : 가치의식 항목

A1 : 나는 낮은 가격에 매우 관심이 있고 상품의 품질에도 관심이 있다.

A2 : 나는 쇼핑할 때 서로 다른 상표의 가격을 비교해서 최상의 가치있는 상품을 얻고 싶어한다.

A3 : 상품을 구매할 때 나는 내가 지불한 돈에 대하여 질적으로 최상의 상품을 얻으려고 노력한다.

A4 : 상품을 구매할 때 나는 항상 내가 지불한 돈에 대하여 질적으로 최상의 상품을 얻는 것을 확신하고 싶어한다.

A5 : 나는 일반적으로 낮은 가격의 품질이 좋은 상품을 구매하기 위하여 돌아다니며싼 가격보다는 품질이 좋은 상품을 찾는다.

A6 : 나는 점포에 갈 때 상표에 대한 가격을 미리 알고서 가격을 비교한다.

A7 : 나는 내가 지불한 돈에 대하여 최상의 가치를 얻기 위해서 항상 가격을 확인한다.

B : 가격의식 항목

B1 : 나는 값이 싼 상품을 구매하기 위해 노력한다.

B2 : 나는 값이 싼 상품을 판매하는 점포보다는, 일반적인 가격으로 판매하는 점포를 더 좋아한다.

B3 : 싼 가격을 찾아 구매한 결과, 보통의 경우 내가 들인 시간이나 노력만큼의 가치는 없다.

B4 : 나는 값이 싼 상품을 구매하기 위해 한 점포에서만 구매한다.

B5 : 싼값의 상품을 발견하는데 들인 시간은 보통의 경우 노력만큼의 가치는 없다.

C : 절약성 항목

C1 : 상품에 대한 세심한 주의를 기울인다면 결국 돈을 절약하게 된다.

C2 : 구매한 상품 중에는 불필요한 물건도 많다.

C3 : 기분전환을 위해 상품구매를 한다.

C4 : 재사용할 수 있는 물건이 있어도 새로운 상품을 구매한다.

C5 : 상품 구매시 지불하는 돈에 대하여 세심한 주의를 한다.

C6 : 상품 구매시 철저한 계획에 의해 구매한다.

C7 : 원하는 상품을 구매하기 위해 돈을 꾸준히 모은다.

C8 : 사고싶은 상품을 오늘 사지 않고 지나가면, 내일이면 불필요해지는 상품도 있다.

D : 긍지의식 항목

D1 : 값이 비싼 상품을 구매했을 때 다른 사람들로부터 주목받게 된다.

D2 : 값이 비싼 상품을 구매하는 것은 내게 기분을 좋게 한다.

D3 : 값이 비싼 상품을 구매하면 내가 세련되었다고 느낀다.

D4 : 나는 비싼 상품을 구매하는 것을 즐긴다.

D5 : 사람들은 내가 값이 비싼 상품을 구매했을 때 상품에 대하여 무언가 말한다.

D6 : 나의 친구들은 내가 값이 비싼 상품을 구매하길 바란다.

D7 : 나는 가장 값이 비싼 상품을 구매하여 다른 사람의 시선을 끈다.

D8 : 나는 다른 사람들이 내가 구매한 상품으로 나를 판단한다고 생각한다.

D9 : 값이 싼 상품이 있어도 나는 값이 비싼 상품에 관심을 갖는다.

III. 인구 통계적 항목(해당 사항에 "V" 표시)

E1 : 귀하의 연령은?

- ① 만 24세 이하 ② 만 25~34세
③ 만 35~44세 ④ 만 45~54세
⑤ 만 55세 이상

E2 : 귀하의 학력은?

- ① 고졸이하 ② 전문대졸/재학
③ 대졸/재학 ④ 재학원졸/재학

E3 : 귀하 가정의 연간 가계소득은?

- ① 약 1,000만원 미만
② 약 100~2,000만원 정도
③ 약 2,000~3,000만원 정도
④ 약 3,000~4,000만원 정도
⑤ 약 4,000~5,000만원 정도
⑥ 약 5,000만원 이상

* 1차 모형에 포함된 21개변수 : A1, B1, B2, B3, B4, B5, C1, C2, C4, C7, D1, D2, D3, D4, D5, D6, D7, D8, D9, E1, E3

* 2차 모형에 포함된 13개변수 : A3, A6, B1, B2, B3, C1, C3, C5, D3, D4, D9, E1, E3

참 고 문 헌

- [1] 이진창, 김명중, 김혁, "기업도산예측을 위한 귀납적 학습지원 인공지능망 접근법 : MDA, 귀납적학습방법, 인공지능망 모형과의 비교", 「경영학연구」, 제23권, 제3호 1994.
- [2] Altrnan, E.I., R.G. Haldman and P. Narayanan, "Zeta analysis : A New Model to

- Identify Bankruptcy Risk of Corporation," *Journal of Banking and Finance*, Vol.1(June 1977), pp.29-54.
- [3] Bailey D.L., & D. Thompson, "Developing Neural Network Application," *AI Expert*, (September 1990), pp.34-50.
- [4] Balakrishman, P.V., M.C. Cooper, V.S. Jacob and P.A. Lewis, "Comparative performance of the FSCL neural net and K-means algorithm for market segmentation," *European Journal of Operational Research*, 93 (1996), pp.346-357.
- [5] Blum, M., "Failing Company Discriminant Analysis," *Journal of Accounting Research*, (Spring 1974), pp.1-25.
- [6] BrainMaker, *User Guide and Reference Manual*, California Scientific Software, 1989.
- [7] Chu, C. & D. Widjaja, "Neural Network System for Forecasting Method Selection," *Decision Support System*, Vol.12(1994), pp. 13-24
- [8] Dasgupta, C.G., G.S. Dispensa and S. Ghose, "comparing the predictive performance of a neural network model with some traditional market response models," *International Journal of Forecasting*, 10(1994), pp. 235-244.
- [9] Davies, F., L. Moutinho and B. Curry, "ATM user attitudes : a neural network analysis," *Marketing Intelligence & Planning*, Vol. 14/2(1996), pp.26-32.
- [10] Diamantaras, K.I. and S.Y. Kung, *Principal component neural networks : Theory and applications*, Wiley and Sons, New York, 1996.
- [11] Erickson, G.M. and J.K. Johansson, "The Role of Price in Multi-Attribute Product Evaluations," *Journal of Consumer Research*, 12(1985), pp.195-199.
- [12] Fish, K.E., J.H. Barnes and M.W. Aiken, "Artificial Neural Networks : A new methodology for industrial market segmentation," *Industrial Marketing Management*, 24(1995), pp.431-438.
- [13] Huang, W.Y. and R.P. Lippman, "Comparison between Neural Net and Conventional Classifiers," *IEEE 1st International Conference on Neural Networks IV*, (1987), pp. 485-493.
- [14] Karels, G.V. and A. Prakash, "Multivariate Normality and Forecasting of Business Bankruptcy," *Journal of Business Finance and Accounting*, (Winter 1987), pp.573-593.
- [15] Kerlin. R.A., A. Jain, and D.J. Howard, "Store Shopping Experience and Consumer Price-Quality-Value Perceptions," *Journal of Retailing*, 68(1992), pp.376-398.
- [16] Klimasauskas, C.C., "Applying neural networks, Part 2 : A walk through the application process," *PC AI*(March/April 1991), pp.27-34.
- [17] Lastovicka, J.L., L.A. Bettencourt, R.S. Hughner, and R.J. Kuntze, "Lifestyle of the Tight and Frugal : Theory and Measurement," *Journal of Consumer Research*, 26 (1999), pp.89-99.
- [18] Lichtenstein, D.R., R.G. Netemeyer, and S. Burton, "Distinguishing Coupon Proneness from Value Consciousness : An Acquisition Transaction Utility Theory Perspective," *Journal of Marketing*, 54(1990), pp. 54-67.
- [19] Monroe, K.B. and J.D. Chapman, "Framing Effects on Buyers' Subjective Product Evaluations," In *Advances in Consumer Research*, 14(1987), M. Wallendorf and P. An-

- derson, eds. Provo, UT : Association for Consumer Research, pp.193-197.
- [20] Moyer, R.C., "Forecasting Financial Failure : A Reexamination," *Financial Management*, (Spring 1977), pp.11-17.
- [21] NeuralWare, *NeuralWorks Reference Guide* (1998), pp.RF-108
- [22] Patuwo, E., M.Y. Hu and M.S. Hung, "Two-group classification using neural networks," *Decision Science*, Vol.24, No.4(1993), pp. 825-845
- [23] Reed, R. "Pruning algorithms ... A survey," *IEEE Transactions on Neural Networks*, Vol.4(1993), pp.740-747.
- [24] Shanker, M., M.Y. Hu and M.S. Hung, "Effect of data standardization on neural network training," *Omega*, Vol.24, No.2(1996), pp.385-397.
- [25] Sharda, R., "Neural Networks for the MS/OR Analyst : An Application Bibliography," *Interfaces*, (March/April 1994), pp.116-130.
- [26] Vellido, A., P.J.G. Lisboa and J. Vaughan, "Neural networks in business : s survey of applications(1992-1998)," *Expert System with Applications*, 17(1999), pp.51-70.
- [27] West, P.M., P.L. Brockett and L.L Golden, "A comparative Analysis of Neural Networks and Statistical Methods for Predicting Consumer Choice," *Marketing Science*, Vol.16, No.4(1997), pp.370-391.
- [28] Wong, B.K., V.S. Lai and J. Sam, "A bibliography of neural network business applications research : 1994-1998," *Computers & Operation Research*, 27(2000), pp.1045-1076.
- [29] Zhang, G., B.E. Patuwo and M.Y. Hu, "Forecasting with artificial neural networks : The state of the art," *International Journal of Forecasting*, Vol.14(1998), pp.35-62.
- [30] Zhang, G., M.Y. Hu, B.E. Patuwo and D.C. Indro, "Artificial neural networks in bankruptcy prediction and cross-validation analysis," *European Journal of Operations Research*, 116(1999), pp.16-32