

퍼지신경망을 이용한 기업부도예측*

김경재

한국과학기술원 테크노경영연구소
(kkj@kgsm.kaist.ac.kr)

한인구

한국과학기술원 테크노경영대학원 부교수
(igkan@kgsm.kaist.ac.kr)

본 연구에서는 퍼지신경망을 이용한 기업부실예측모형을 제안한다. 신경망은 탁월한 학습능력을 가진 것으로 알려져 있으나, 잡음이 심한 재무자료에 대해서는 종종 일관되지 못하고 기대에 미치지 못하는 예측성적을 보인다. 이는 연속형의 형태를 지닌 독립변수와 파다한 양의 원자료로부터 예측에 필요한 일정한 패턴을 찾기가 어렵기 때문이다. 이러한 문제점은 예측모형에서의 독립변수와 종속변수 간의 인과관계를 신경망이 용이하게 찾아낼 수 있도록 독립변수의 형태를 변환함으로써 해결할 수 있다. 이러한 해결방법의 하나는 기존 신경망에 퍼지집합의 개념을 적용하여 신경망 학습에 사용될 자료를 퍼지화하고 이를 신경망에 학습시키는 것이다. 입력자료를 퍼지화함으로써 정보의 손실 없이도 신경망이 자료 내의 복잡한 관계를 용이하게 학습하는 것이 가능하다. 본 연구에서 제안된 퍼지신경망을 기업부도예측에 적용한 결과, 퍼지신경망이 기존의 신경망보다 우월한 예측성적을 나타내었다.

1. 서 론

정확한 기업부도예측모형은 시장원리에 따른 금융자원의 효율적 배분을 도모하고 금융기관 자산의 건전화를 촉진할 수 있는 기반이다. 과거 국내 금융기관들의 대출관행은 모기업 및 관계기업의 규모나 담보설정여부 등을 위주로 보수적인 신용평가를 수행해 왔다. 그러나 IMF체제 이후 대기업의 부도와 경영환경의 급변으로 인해 대부분의 국내 금융기관들은 상당한 규모의 부실채권을 부담하게 되었으며 일부 금융기관은 합병, 퇴출 등의 방법으로 금융시장에서 사라져 가고 있는 실정이다. 최근의 이러한 영업환경의 변화는

각 금융기관들로 하여금 정교한 기업부도예측의 중요성을 인식케 하는 원인이 되었다.

정교한 부도예측을 위해 많은 연구자들이 여러 가지 예측모형을 제시하여 왔다. 선행연구에서는 주로 재무비율 등을 이용한 통계적 방법론에 의한 부도예측모형들이 제안되어 왔는데, 구체적으로는 판별분석, 회귀분석, logit 분석, probit 분석 등이 사용되어 왔다(Altman, 1968; Altman, 1983; Ohlson, 1980). 최근에는 비선형적인 패턴을 보이는 재무변수 간의 관계 파악을 용이하게 해 주는 것으로 알려진 신경망(artificial neural network)에 의한 부도예측모형이 활발히 제시되고 있다.

* 이 논문은 한국과학재단 연구지원(과제번호: 98-0102-08-01-3)에 의하여 연구되었음

신경망은 비선형적인 관계를 가진 자료분석에 탁월한 학습능력을 가지고 있는 것으로 알려져 있으나, 매우 심한 잡음이 있는 재무자료의 분석 시에는 그 학습에 한계를 보이는 경우가 있다 (Kim and Han, 2000). 이러한 한계의 원인 중 하나는 연속형 자료와 과다한 양의 자료를 단일 신경망에 학습시키는데 따른 것이다(Liu and Setiono, 1996). 불필요한 변수와 자료의 제거 및 변환은 예측성고를 유지하면서도 신경망의 학습 시간을 줄이고 예측 결과의 일반화를 제고하는 효과가 있다(Dash and Liu, 1997).

본 연구에서는 기존 신경망에 퍼지집합의 개념을 적용하여 신경망 학습에 사용될 자료를 퍼지화하고 이를 신경망에 학습시켜 기업부도예측에 활용한다. 각각의 입력자료를 퍼지화함으로써 정보의 손실 없이도 입력자료가 신경망에 용이하게 학습될 수 있는 형태로 변환할 수 있다 (Klimasauskas, 1992). 또한 이러한 방식으로 변환된 입력자료는 신경망이 자료 내의 복잡한 관계(high-order interaction)를 용이하게 학습할 수 있도록 해 준다(Klimasauskas, 1995).

본 연구는 다음과 같이 구성되어 있다. 제 2 장에서는 신경망을 이용한 기업부도예측에 관련된 선행연구를 검토하고 기존 연구의 한계점을 제시한다. 제 3 장에서는 본 연구에서 사용될 퍼지신경망에 관하여 설명한다. 제 4 장에서는 제시된 모형의 성과를 검증하기 위한 실험용 자료와 실험설계에 관하여 기술한다. 제 5 장에서는 실험의 결과를 정리하고 통계적 유의성을 검증한다. 제 6 장에서는 결론과 본 연구의 한계점을 논의한다.

2. 신경망을 이용한 기업부도예측연구

많은 학자들이 기업의 부도예측에 인공지능기법을 사용한 연구를 계속적으로 진행하여 왔다. Odom and Sharda(1990)의 연구는 신경망을 부도예측에 적용한 초기의 연구라고 할 수 있다. 그들은 판별분석과 역전파신경망(backpropagation neural networks)의 성과를 비교하였는데 역전파신경망의 성과가 더 정확한 것으로 나타났다. 이후의 연구들은 대체로 Odom and Sharda(1990)의 연구와 같이 통계적 방법론과 신경망의 성과를 비교하는 형태로 이루어 졌다. 이러한 경향의 대표적인 연구로는 Tam and Kiang(1992)의 연구가 있는데, 이 연구에서는 은행의 부실 여부를 역전파신경망으로 예측하고 그 결과를 판별분석, 로지스틱 회귀분석, k-최근접이웃방법(k-nearest neighbor), 귀납적 추론(ID3)의 결과와 비교하였다. 연구 결과, 신경망에 의한 모형이 신경망의 여러 한계점에도 불구하고 예측성고, 적응력 등에서 다른 방법론에 비해 우수한 결과를 나타내었다.

Wilson and Sharda(1994)는 몬테카를로 샘플링기법(MonteCarlo resampling technique)을 이용하여 부도기업과 건전기업의 구성비를 변화시켜 가며 신경망 실험을 수행한 후 그 결과를 판별분석과 비교하였는데 역시 신경망의 성과가 더 우수한 것으로 나타났다. Jo et al.(1997)의 연구에서는 역전파신경망의 성과가 사례기반추론(case-based reasoning)과 판별분석의 성과보다 우월함을 확인하였으며, Jo and Han(1996)의 연구에서는 많은 연구들이 역전파신경망의 부도예측에의 응용가능성에 대해 연구를 하여 왔으나 설명력이 부족하여 예측결과의 원인을 설명하기 어렵다는 한계점과 함께 기존의 연구가 주로 소

량의 자료를 대상으로 하였기 때문에 일반화의 가능성도 떨어진다는 한계점을 제기하였다.

이러한 이유로 최근의 연구에서는 기존의 역전파신경망 외에 다양한 형태의 신경망을 기업부도예측에 응용하고 있다. Serrano-Cinca(1996)와 Kiviluoto(1998)는 무감독학습(unsupervised learning) 방법인 자기조직화 신경망의 부도예측 적용가능성에 대해 연구하였다. 특히 Kiviluoto(1998)의 연구에서는 자기조직화 신경망 외에 RBF(radial basis function) - SOM(self organizing map)과 LVQ(learning vector quantization) 등 세 가지 무감독학습방법과 선형 판별분석, 이차판별분석(quadratic discriminant analysis), k-최근접이웃방법 등을 비교하였다.

연구 결과, 베이스스함수의 위치를 SOM에 의해 결정한 RBF-SOM이 다른 모형에 비해 근소하게 우수한 것으로 나타났으나 그 차이는 유의하지 않았다. 최근의 연구로는 PNN(probabilistic neural networks)을 부도예측에 적용한 Yang et al.(1999)의 연구를 제시할 수 있는데 그들의 연구 결과에서는 패턴의 정규화를 거치지 않은 PNN 모형과 판별분석의 예측성도가 역전파신경망의 성과보다 우월한 것으로 나타났다. <표 1>은 제시된 선행연구의 내용을 정리한 것이다.

기업부도예측에 이용되는 재무비율과 같은 재무자료는 각 독립변수와 종속변수 사이의 관계가 복잡하고, 많은 기업에 대한 재무자료를 사용함으로써 인해서 신경망의 학습에 있어서 효과적이지

<표 1> 신경망을 이용한 기업부도예측 주요 선행 연구

	사용된 신경망 모형	실험 자료수	비교 대상 모형	독립변수의 수
Odom and Sharda(1990)	역전파신경망	129개	선형판별분석	5개
Tam and Kiang(1992)	역전파신경망	202개	판별분석, 로지스틱 회귀분석, k-최근접이웃방법, 귀납적 추론	19개
Wilson and Sharda(1994)	역전파신경망	129개	선형판별분석	5개
Jo and Han(1996)	역전파신경망	542개	선형판별분석, 사례기반추론	20개
Serrano-Cinca(1996)	자기조직화 신경망	66개	비교대상 없음	9개
Jo et al.(1997)	역전파신경망	542개	선형판별분석, 사례기반추론	선택방법에 따라 9개~23개 사이
Kiviluoto(1998)	자기조직화 신경망, RBF-SOM, LVQ	1137개	선형판별분석, 이차판별분석, k-최근접이웃방법	4개
Yang et al.(1999)	PNN, 역전파신경망	122개	선형판별분석	5개

못한 경우가 있다. 그러나, 전술한 연구의 대부분은 기업부도예측에 이용된 도구의 개선에 관한 것으로 입력자료의 복잡성이나 과다한 입력자료의 양에 의한 학습의 비효과성에 관한 연구는 많이 이루어 지지 않았다. 신경망 학습에 용이한 형태로 입력자료를 변환하면 신경망의 예측성과를 제고할 수 있을 것이다. 따라서 보다 효과적인 기업부도예측을 위해서는 재무자료의 특성을 신경망 학습에 용이하게 반영할 수 있는 방법에 관한 연구가 필요하다.

3. 퍼지신경망

신경망을 이용하여 예측을 하기 위해서는 신경망이 효율적으로 처리할 수 있는 형태로 자료를 전처리하여야 한다. 일반적으로 신경망을 위한 전처리 방법 중 가장 대표적인 것은 선형 스케일링(linear scaling)이다. 신경망에서의 선형 스케일링이란 원자료 값의 범위를 0에서 1, 또는 -1에서 1 사이로 맞추어 주는 것으로 정규화 등의 방법을 통하여 구할 수 있다. 이러한 전처리는 독립변수 간의 규모차이에 의한 효과를 감소시킬 수 있을 뿐만 아니라 신경망이 보다 용이하게 자료 내의 관계를 파악할 수 있게 한다. 그러나 선형 스케일링을 거친 자료의 형태도 연속형이고 원자료 값의 범위를 일정하게 조정할 것일 뿐이므로 자료 내의 복잡한 관계를 완화하기에는 한계가 있다.

따라서 연속형 자료를 이산형 또는 비연속형 자료로 변환함으로써 자료의 복잡성을 감소시키고 학습성과를 제고할 수 있다. 선행연구에서는 여러 가지 변환방법을 제시하고 있는데 크게 외적변환방법(exogenous method)과 내적변환방법

(endogenous method)으로 나눌 수 있다 (Dougherty et al., 1995; Scott et al., 1997).

외적변환방법은 학습알고리즘의 학습성과를 제고할 수 있도록 학습알고리즘과 유기적으로 입력자료를 변환하는 방법이다. 선행연구로는 다른 독립변수와의 Cramer V 값의 통계적 유의성을 최대화하도록 입력자료를 변환하는 방법(Scott et al., 1997), 귀납적학습방법과 k-최근접이웃방법에서 엔트로피를 최소화하도록 변환하는 방법(Fayyad and Irani, 1993; Martens et al., 1998; Ting, 1997), 귀납적학습방법의 하나인 C4.5와 신경망에서 유전자알고리즘을 이용하여 입력자료를 변환하는 방법(Vafaie and De Jong, 1998; Kim and Han, 2000) 등이 외적변환방법으로 제시된 것이다. 이 방법은 종속변수와 독립변수 간의 연관관계를 변환과정에 반영할 수 있다는 장점이 있지만 학습알고리즘과 변환알고리즘이 유기적으로 결합되어야 하므로 결합된 알고리즘을 개발하는데 많은 시간과 비용을 필요로 한다는 단점이 있다.

반면에 내적변환방법은 신경망 등과 같은 학습알고리즘에 사용될 입력자료를 그 학습알고리즘과 무관하게 변환하는 방법이다. 이는 입력자료 자체의 특성에 따라 입력자료를 변환하며 학습알고리즘의 예측성과 등은 고려하지 않는다. 따라서 이 방법은 학습알고리즘과 자료의 변환과정이 분리된 것이라 할 수 있다. 선행연구에서는 SOM(Lawrence et al., 1996), 백분위방법(Buhlmann, 1998; Scott et al., 1997), 군집화방법(Kontkanen et al., 1997; Scott et al., 1997) 등이 내적변환방법으로 제시되었다. 그 밖에 Basak et al.(1998)이 제시한 특성평가지표에 의한 뉴로퍼지 방법과 Piramuthu et al.(1998)이 제시한 의사결정나무방법도 내적변환방법으로 분류될 수 있

다. 내적변환방법은 변환과정이 단순하고 구현이 용이하다는 장점이 있다. 본 연구에서는 내적변환방법의 일종인 퍼지집합과 신경망을 결합한 방법론을 제안한다.

퍼지집합과 신경망을 결합하는 방법은 여러 가지 형태로 제안되어 왔다. 본 연구에서 사용하는 퍼지신경망은 신경망 학습에 사용될 입력자료를 퍼지소속함수에 따라 퍼지화하고 이를 신경망에서 학습하는 형태이다. 퍼지화는 퍼지소속함수에 의해 연속형 자료를 퍼지화된 기호로 변환시켜주는 것으로 입력자료의 복잡성을 줄여 주는 이상적인 방법이다(Chou et al., 1997). 퍼지소속함수를 구축하는 방법에도 여러 가지 방법이 제시되었으나 본 연구에서는 Klimasauskas(1992)에 의해 제안된 군집화 알고리즘을 이용하는 방법을 사용한다.

Klimasauskas의 방법은 2개의 단계로 구성되어 있다. 첫번째 단계는 k-means 군집화 알고리즘을 이용하여 연속형 자료를 k개의 군집으로 집단화한 후, 군집을 소속함수로 변환한다. k-means 알고리즘은 k개의 이산화된 집합(crisp set)을 반환하게 된다. 두번째 단계는 퍼지화 단계로서 반환받은 이산화된 집합을 퍼지화하여 퍼지집합을 반환받는 단계이다. 본 연구에서는 각 군집을 위한 퍼지범주의 경계를 0.5로, 퍼지범주의 최대값인 1을 각 군집의 평균으로 가정한다. 본 연구에서의 퍼지화 과정은 다음에 의해 이루어진다.

$$C = 0.5 \times (S + E)$$

$$K = 2 \times (1 - M) / (E - S)$$

$$F_i = \text{Max}(0, 1 - K \times |X_i - C|)$$

C = 경계 사이의 중앙값(the center between the boundary)

S = 극좌 경계

E = 극우 경계

K = 스케일요소(the scale factor)

M = 경계에서의 퍼지소속함수의 수치

F_i = 퍼지소속 값

X_i = 입력자료의 수치

이런 추정치는 이웃하고 있는 두 소속함수가 0.5 소속범주에서 교차하도록 허용한다. 본 연구에서 사용된 퍼지화에 의한 변환방법은 내적변환방법의 하나이다. 따라서 3장에서 언급한 바와 같이 이 변환방법은 변환과정이 단순하고 구현이 용이하다는 장점을 갖고 있다. 이상과 같은 퍼지화를 통해서 생성된 자료는 신경망의 입력자료로 사용된다. 본 연구에서 사용된 신경망은 신경망의 경영학 응용연구에서 가장 많이 사용되고 있는 역전파신경망이다. Vellido et al.(1999)에 의하면 저명 국제 학술지에 실린 신경망의 경영학 응용연구 110편 중 67.8%가 역전파신경망을 이용하고 있다. 역전파신경망은 광범위한 응용가능성으로 인하여 많은 경영학 문제에 사용되고 있다. 그러나 이 신경망은 알고리즘 자체로는 최적의 입력변수와 최적의 신경망 구조를 결정하지 못한다는 단점이 있다(Tsaih et al., 1998).

입력변수 선정에 있어서는 많은 연구들이 선형회귀분석, 판별분석과 같은 선형방법에 근거한 선택방법에 의존하여 왔다. 그러나 이런 방법은 비선형모형에서의 최적 입력변수선정을 보장해주지 못한다(Vellido et al., 1999). 최근에는 비선형모형에서도 최적 또는 유사최적의 입력변수군을 선정해 주는 유전자알고리즘(genetic algorithm)이 많은 연구자들에 의해 사용되고 있다. 유전자알고리즘이 입력변수선정에 사용되고 있는 학습알고리즘으로는 신경망(Ornes and Sklanski, 1997; Yang and Honavar, 1998), 귀납

적 학습방법(Bala et al., 1995; Vafaie and De Jong, 1998), 선형회귀분석(Wallet, 1996) 등이다.

신경망 내의 최적 구조를 찾는 것도 신경망을 이용한 예측에 있어서 매우 중요한 요소 중의 하나이다. 신경망의 구조를 결정한다는 것은 크게 입력층의 처리요소, 은닉층의 처리요소, 은닉층의 수를 결정하는 세 가지의 문제로 생각할 수 있다. 이 중 입력층의 처리요소는 입력변수군의 선정과정을 통해 결정되는 과정이다.

은닉층의 수는 선행연구들에 의해 하나의 은닉층으로도 충분히 효과적인 신경망을 구축할 수 있음이 주장되어 왔다(Cybenko, 1989; Masters, 1993; de Villiers and Barnard, 1992). 따라서 본 연구에서는 하나의 은닉층을 갖는 신경망을 이용하기로 한다. 그러나 은닉층 내의 처리요소의 수를 최적화하는 것은 효과적인 신경망 구축을 위해 반드시 필요한 과정이다. 선행연구에서도 은닉층의 처리요소를 결정하기 위한 많은 시도가 이루어져 왔는데, 구체적으로는 전진선택방법, 후진제거방법이 대표적이다. 그러나 이러한 방법들은 일반적으로 복잡하고, 실행이 어려우며, 최적의 구조를 보장하지 못한다는 단점이 있다(Coakley and Brown, 2000).

최근에는 이러한 단점을 보완하고자 전역탐색 방법(global search method)인 유전자알고리즘이 제안되고 있다(Maniezzo, 1994; Williamson, 1995; Hansen, 1998; Nissinen et al., 1999; Hansen et al., 1999). 유전자알고리즘은 적합함수를 어떻게 설정하느냐에 따라 선형이나 비선형 모형에서의 최적 또는 유사최적의 구조를 결정해주는 장점이 있다. 본 연구에서는 효과적인 퍼지신경망의 구현을 위해 입력변수와 구조를 유전자알고리즘이 전역적으로 탐색하여 결정하는 방법을 사용한다.

4. 실험설계

제안된 연구모형의 유용성을 검증하기 위해 총자산 규모 70억 이상의 국내 대기업의 재무자료를 이용하여 기업부도예측을 수행한다. 표본의 총 기업수는 560개 기업이며, 이를 신경망 학습을 위해 사용된 학습용 자료 342개 기업, 학습오차를 최소화하기 위해 사용된 시험용 자료 110개 기업, 학습결과의 일반화 정도를 검증하기 위해 사용된 검증용 자료 108개 기업으로 분류하였다. 각 자료군은 임의추출방법에 의해 구성되었으며 예측결과가 부도나 건전의 한 쪽으로 치우치는 현상을 방지하기 위해 각 자료군의 부도기업 수와 건전기업 수를 동수로 구성하였다. 본 연구에 사용된 초기 재무변수는 94개이다.

제안된 퍼지신경망의 유용성을 검증하기 위하여 크게 2개의 모형을 구성하였다. 첫번째 모형은 전형적인 역전파신경망을 이용하는 모형으로 본 연구에서는 이 모형을 CNN(conventional neural network)이라 명명한다. 이 모형에서는 각 입력변수의 규모효과를 제거하기 위한 선형스케일링 외에는 특별한 조작을 하지 않는다. 두번째 모형은 본 연구에서 제안하는 퍼지신경망을 이용하여 구축한 모형으로 FNN(fuzzy neural network)이라 한다. 이 모형에서는 입력자료에 대해 k-means 알고리즘을 이용한 퍼지화를 수행한다.

본 연구에서는 유전자알고리즘을 이용하여 신경망에서의 입력변수군과 신경망 구조를 결정하기에 상기의 두 모형이 각각 다른 입력변수군과 구조를 가질 수 있다. 이것은 유전자알고리즘이 각각의 모형에서의 시험용 자료에 대해 최고의 적응률을 보이는 입력변수군과 구조를 선택하도록 적합도를 설정하였기에 발생하는 현상이다.

<표 2> 모형별 선택 변수

모형	선택 변수	산식
CNN	유보액/납입자본 매출액경상이익률 금융비용대매출액비율 금융비용대부채비율 순현금흐름/차입금 기계투자효율 매입채무불일치액	$(\text{자본잉여금} + \text{이익잉여금} - \text{배당금}) / \text{자본금} \times 100$ $(\text{경상이익} / \text{매출액}) \times 100$ $\text{이자비용} / \text{매출액} \times 100$ $\text{이자비용} / (\text{전기부채총계} + \text{당기부채총계}) \times 200$ $\text{순영업활동조달현금} / \text{총차입금} \times 100$ $\text{부가가치} / (\text{전기기계장치} + \text{당기기계장치}) \times 200$ $[(\text{당기매입채무} + \text{당기미지급금} - \text{전전기매입채무} + \text{전전기미지급금}) - ((\text{당기월매출액} - \text{전전기월매출액}) (\text{전전기매출채권} + \text{전전기미지급금}) / \text{전전기재고자산})]$
FNN / CFN	배당성향 유보액/총자산 유보액/납입자본 금융비용대매출액비율 금융비용대부채비율 자기자본비율 순현금흐름/차입금	$\text{배당금} / \text{당기순이익} \times 100$ $(\text{자본잉여금} + \text{이익잉여금} - \text{배당금}) / \text{자산총계} \times 100$ $(\text{자본잉여금} + \text{이익잉여금} - \text{배당금}) / \text{자본금} \times 100$ $\text{이자비용} / \text{매출액} \times 100$ $\text{이자비용} / (\text{전기부채총계} + \text{당기부채총계}) \times 200$ $\text{자본총계} / \text{자산총계} \times 100$ $\text{순영업활동조달현금} / \text{총차입금} \times 100$

그러나 신경망의 경우, 선정된 입력변수군과 구조에 따라서 그 예측성과는 상이할 수 있다. 따라서 본 연구에서는 입력변수군과 신경망 구조의 상이함에 따른 예측성과의 차이를 제거하기 위해 CNN 모형에서 최적으로 선정된 입력변수군과 구조를 FNN 모형에 적용하여 본 연구에서 제안된 퍼지신경망의 효과를 보고자 한다. CNN 모형의 입력변수군과 구조를 FNN 모형에 적용하는 모형을 본 연구에서는 CFN(combined fuzzy neural network)이라 한다. 이상 총 3개의 모형을 이용하여 예측성과를 비교한다. 유전자알고리즘에 의해 각 모형에서 선택된 변수는 <표 2>와 같다.

5. 실험결과

전술한 바와 같이 본 연구에서는 3가지 기업부도예측모형의 성과를 비교하였다. <표 3>은 각 모형의 예측성과를 학습용 자료, 시험용 자료, 검증용 자료로 나누어 정리한 것이다. <표 3>의 수치는 기업의 부도, 건전 여부를 학습용 자료와 시험용 자료를 이용하여 학습시킨 후 검증용 자료로 예측하게 한 후 각 자료군 내에서 예측값과 실제값이 일치한 기업의 수가 차지하는 비율을 백분율로 계산한 것이다.

<표 4>는 검증용 자료에 대한 실험 결과의 통계적 유의성을 검증하기 위하여 두 집단에서의

비율의 차이에 대한 검정(two-sample test for proportions)을 통해 얻은 p 값이다. 이 검정은 두 모집단에서의 특정한 비율을 서로 비교해야 할 경우에 사용될 수 있다(Harnett and Soni, 1991).

<표 3> 모형별 예측성과(단위: 적중률)

모형	학습용 성과	시험용 성과	검증용 성과
CNN	76.2 %	84.5 %	75.1 %
CFN	77.3 %	84.4 %	81.2 %
FNN	79.6 %	88.0 %	83.0 %

<표 4> 검증용 자료의 실험 결과에 대한 두 집단 비율의 차이에 대한 검정 결과(p 값)

	CFN	FNN
CNN	0.1396	0.0776
CFN		0.3652

실험 결과, 본 연구에서 제시된 FNN이 학습용, 시험용, 검증용의 각 자료군에서 CNN과 CFN에 비해 우월한 예측성적을 보이는 것으로 나타났다. FNN은 10% 유의수준에서 CNN보다 유의적으로 우월한 것으로 나타났다. 그러나 CFN과 CNN의 차이는 통계적으로 유의한 차이를 보이지 못하였다. 또한, FNN도 CFN에 비해 우수한 예측성적을 보였으나 그 차이는 통계적으로 유의하지 않았다. 이 결과는 본 연구에서 제시된 퍼지신경망을 이용한 기업부도예측모형이 기존의 전통적인 신경망을 이용한 기업부도예측모형보다 유용함을 보여 주는 것이다. 이는 재무변수와 같이 잡음이 심하고 종속변수와 독립변수 간의 관계가 복잡한 경우에는 퍼지화를 통해 입

력변수의 차원을 단순화할 수 있고, 그 결과로 우월한 예측성적을 얻을 수 있음을 보여 주는 것이다.

6. 결 론

본 연구에서는 정교한 기업부도예측을 위해 최근에 활발하게 연구되고 있는 신경망 모형에 퍼지집합의 개념을 결합한 퍼지신경망에 의한 기업부도예측모형을 제안하였다. 본 연구에서 사용된 퍼지신경망은 전통적인 방식의 신경망 모형에서의 입력변수의 복잡성을 단순화하는 방법으로 입력변수의 퍼지화를 수행하였다. 제안된 모형을 실제 기업 재무자료를 이용하여 실험한 결과, 퍼지신경망을 이용한 기업부도예측모형이 유용하며 전통적인 신경망에 의한 기업부도예측모형보다 통계적으로 유의한 예측성적의 차이를 보이는 것으로 나타났다. 이 결과는 재무변수와 같이 잡음이 심하고 종속변수와 독립변수 간의 관계가 복잡한 경우에 퍼지화를 통해 입력변수의 차원을 단순화할 수 있으며, 그 결과로 우월한 예측성적을 얻을 수 있음을 보여 주는 것이다.

본 연구는 다음과 같은 한계점을 가지고 있으며 이는 향후 연구과제로 제안될 수 있다. 첫째, 본 연구에서는 입력변수의 전처리과정에 일반적으로 많이 이용되는 선형 스케일링 방법과 퍼지화 방법을 비교하였다. 그러나 최근에는 전술한 바와 같이 엔트로피(entropy) 최소화 방법(Fayyad and Irany, 1993), 유전자알고리즘에 의한 방법(Kim and Han, 2000) 등 다양한 전처리 방법들이 제안되고 있다. 따라서 향후 연구에서는 다른 전처리 방법과의 비교연구가 수행되어야 할 것이다. 둘째, 본 연구에서는 제안된 퍼지신경

망을 기업부도예측에 적용하였는데, 제안된 방법론이 보다 일반화된 방법론인지를 검증하기 위해서는 기업부도예측 뿐만 아니라 다른 분야의 예측에도 적용하여 검증하여야 한다. 퍼지신경망은 특히 독립변수와 종속변수 간의 관계가 복잡한 재무예측의 문제에서 유용할 것으로 생각된다.

또한, 본 연구의 실험에서 사용된 기업 재무자료는 전술한 바와 같이 총자산 규모 70억 이상의 대기업 자료들로 구성되어 있다. 중소기업 재무자료의 특성은 대기업의 특성과 상이할 수 있으므로 본 연구의 결과가 중소기업의 자료에서는 일반화되지 못할 가능성이 있다. 그러나 일반적으로 대부분의 소속기업이 외부감사의 대상이 되는 대기업 자료에 비해 상당수의 소속기업이 외부감사의 대상이 되지 않는 중소기업 자료는 그 자료 내의 복잡성의 정도가 더 심한 것으로 인식되고 있다. 따라서 본 연구에서 제안된 방법론이 중소기업의 부도예측모형 구축에 더 유용할 가능성이 있으며 이도 향후 연구에서 검증되어야 할 것이다.

참고문헌

- [1] Altman, E., "Financial ratios, discriminant analysis and the prediction of corporate bankruptcy", *The Journal of Finance*, Vol. 23, No. 4(1968), 589-609.
- [2] Altman, E., *Corporate Financial Distress - A Complete Guide to Predicting, Avoiding and Dealing with Bankruptcy*, John Wiley & Sons, New York, 1983.
- [3] Bala, J., J. Huang, H. Vafaie, K. De Jong and H. Wechsler, "Hybrid learning using genetic algorithms and decision trees for pattern classification", In *Proceedings of the International Joint Conference on Artificial Intelligence*, 1995, 19-25.
- [4] Basak, J., R. K. De and S. K. Pal, "Unsupervised feature selection using a neuro-fuzzy approach", *Pattern Recognition Letters*, Vol. 19, No. 11(1998), 997-1006.
- [5] Buhlmann, P., "Extreme events from the return-volume process: a discretization approach for complexity reduction", *Applied Financial Economics*, Vol. 8, No. 3(1998), 267-278.
- [6] Chou, S. T., H. Hsu, C. Yang and F. Lai, "A stock selection DSS combining AI and technical analysis", *Annals of Operations Research*, Vol. 75(1997), 335-353.
- [7] Coakley, J. R. and C. E. Brown, "Artificial neural networks in accounting and finance: Modeling issues", *International Journal of Intelligent Systems in Accounting, Finance and Management*, Vol. 9, No. 2(2000), 119-144.
- [8] Cybenko, G., "Approximation by superpositions of a sigmoid function", *Mathematics of Control, Signals, and Systems*, Vol. 2(1989), 303-314.
- [9] Dash, M. and H. Liu, "Feature selection methods for classifications", *Intelligent Data Analysis: An International Journal*, Vol. 1, No. 3(1997), 131-156.
- [10] de Villiers, J. and E. Garnard, "Backpropagation neural nets with one and two hidden layers", *IEEE Transactions on Neural Networks*, Vol. 4, No. 1(1993), 136-141.
- [11] Dougherty, J., R. Kohavi and M. Sahami, "Supervised and unsupervised discretization of continuous features", In *Prieditis, A. and S. Russell(eds.): Proceedings of the Twelfth International Conference on Machine Learning*, Morgan Kaufmann Publishers,

- 1995, 194-202.
- [12] Fayyad, U. M. and K. B. Irani, "Multi-interval discretization of continuous-valued attributes for classification learning", In Proceedings of the 13th International Joint Conference on Artificial Intelligence, Chambéry, 1993, 1022-1027.
- [13] Hansen, J. V., "Comparative performance of backpropagation networks designed by genetic algorithms and heuristics", International Journal of Intelligent Systems in Accounting, Finance and Management, Vol. 7, No. 2(1998), 69-79.
- [14] Hansen, J. V., J. B. McDonald and R. D. Nelson, "Time series prediction with genetic-algorithm designed neural networks: An empirical comparison with modern statistical models", Computational Intelligence, Vol. 15, No. 3(1999), 171-184.
- [15] Harnett, D. L. and A. K. Soni, Statistical Methods for Business Economics, Addison-Wesley Publishing, Reading, Massachusetts, 1991.
- [16] Jo, H. and I. Han, "Integration of case-based forecasting, neural network, and discriminant analysis for bankruptcy prediction", Expert Systems with Applications, Vol. 11, No. 4(1996), 415-422.
- [17] Jo, H., I. Han and H. Lee, "Bankruptcy prediction using vase-based reasoning, neural networks, and discriminant analysis", Expert Systems with Applications, Vol. 13, No. 2(1997), 97-108.
- [18] Kiviluoto, K., "Predicting bankruptcies with the self-organizing map", Neurocomputing, Vol. 21(1998), 191-201.
- [19] Kim, K. and I. Han, "Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index", Expert Systems with Applications, Vol. 19, No. 2(2000), 125-132.
- [20] Klimasauskas, C. C., "Hybrid fuzzy encodings for improved backpropagation performance", Advanced Technology for Developers, September 1992.
- [21] Klimasauskas, C. C., "Using fuzzy pre-processing with neural networks for chemical process diagnostic problems", In Goonatilake, S. and S. Khebbal(eds.): Intelligent Hybrid Systems, John Wiley & Sons, Chichester, 1995, 143-151.
- [22] Kontkanen, P., P. Myllymaki, T. Silander and H. Tirri, "A Bayesian approach to discretization", In Proceedings of the European Symposium on Intelligent Techniques, Bari, Italy, 1997, 265-268.
- [23] Lawrence, S., A. C. Tsoi and C. L. Giles, "Noisy time series prediction using symbolic representation and recurrent neural network grammatical inference", Technical Report UMIACS-TR-96-27 and CS-TR-3625, Institute for Advanced computer Studies, University of Maryland, 1996.
- [24] Liu, H. and R. Setiono, "Dimensionality reduction via discretization", Knowledge-Based Systems, Vol. 9, No. 1(1996), 67-72.
- [25] Maniezzo, V., "Genetic evolution of the topology and weight distribution of neural networks", IEEE Transactions on Neural Networks, Vol. 5, No. 1(1994), 39-53.
- [26] Martens, J., G. Wets, J. Vanthienen and C. Mues, "An initial comparison of a fuzzy neural classifier and a decision tree based classifier", Expert Systems with Applications, Vol. 15, No. 3/4(1998), 375-381.
- [27] Masters, T., Practical Neural Network Recipes in C++, Academic Press, Boston, 1993.
- [28] Nissinen, A. S., H. N. Koivo and H. Koivisto,

- "Optimization of neural network topologies using genetic algorithm", *Intelligent Automation and Soft Computing*, Vol. 5, No. 3(1999), 211-224.
- [29] Odom, M. D. and R. Sharda, "A neural network model for bankruptcy prediction", In *Proceedings of the IEEE International Conference on Neural Networks*, San Diego, CA, 1990, 163-168.
- [30] Ohlson, J., "Financial ratios and probabilistic prediction of bankruptcy", *Journal of Accounting Research*, Vol. 18, No. 1(1980), 109-131.
- [31] Ornes, C. and J. Sklanski, "A neural network that explains as well as predicts financial market behavior", In *Proceedings of the IEEE/IAFE, 1997*, 43-49.
- [32] Piramuthu, S., H. Ragavan and M. J. Shaw, "Using feature construction to improve the performance of neural networks" *Management Science*, Vol. 44, No. 3(1998), 416-430.
- [33] Scott, P. D., K. M. Williams and K. M. Ho, "Forming categories in exploratory data analysis and data mining", *Advances in Intelligent Data Analysis*, Springer-Verlag, Berlin, 1997, 235-246.
- [34] Serrano-Cinca, C., "Self organizing neural networks for financial diagnosis", *Decision Support Systems*, Vol. 17(1996), 227-238.
- [35] Tam, K. Y. and M. Y. Kiang, "Managerial applications of neural networks: The case of bank failure predictions", *Management Science*, Vol. 38(1992), 926-947.
- [36] Ting, K. A., "Discretization in lazy learning algorithms", *Artificial Intelligence Review*, Vol. 11, No. 1-5(1997), 157-179.
- [37] Tsaih, R., Y. Hsu and C. C. Lai, "Forecasting S&P 500 stock index futures with a hybrid AI system", *Decision Support Systems*, Vol. 23, No. 2(1998), 161-174.
- [38] Vafaie, H. and K. De Jong, "Feature space transformation using genetic algorithms", *IEEE Intelligent Systems and Their Applications*, Vol. 13, No. 2(1998), 57-65.
- [39] Vellido, A., P. J. G. Lisboa and J. Vaughan, "Neural networks in business: a survey of applications", *Expert Systems with Applications*, Vol. 17, No. 1(1999), 51-70.
- [40] Wallet, B. C., D. J. Marchette, J. L. Solka and E. J. Wegman, "A genetic algorithm for best subset selection in linear regression", In *Proceedings of the 28th Symposium on the Interface, 1996*.
- [41] Williamson, A. G., "Refining a neural network credit application vetting system with a genetic algorithm", *Journal of Microcomputer Applications*, Vol. 18(1995), 261-277.
- [42] Wilson, R. L. and R. Sharda, "Bankruptcy prediction using neural networks", *Decision Support Systems*, Vol. 11(1994), 545-557.
- [43] Yang, J. and V. Honavar, "Feature subset selection using a genetic algorithm", *IEEE Intelligent Systems and Their Applications*, Vol. 13, No. 2(1998), 44-49.
- [44] Yang, Z. R., M. B. Platt and H. D. Platt, "Probabilistic neural networks in bankruptcy prediction", *Journal of Business Research*, Vol. 44(1999), 67-74.

Abstract

Bankruptcy Prediction using Fuzzy Neural Networks

Kyoung Jae Kim*
In Goo Han*

This study proposes bankruptcy prediction model using fuzzy neural networks. Neural networks offer preeminent learning ability but they are often confronted with the inconsistent and unpredictable performance for noisy financial data. The existence of continuous data and large amounts of records may pose a challenging task to explicit concepts extraction from the raw data due to the huge data space determined by continuous input variables. The attempt to solve this problem is to transform each input variable in a way which may make it easier for neural network to develop a predictive relationship. One of the methods selected for this is to map each continuous input variable to a series of overlapping fuzzy sets. Appropriately transforming each of the inputs into overlapping fuzzy membership sets provides an isomorphic mapping of the data to properly constructed membership values, and as such, no information is lost. In addition, it is easier for neural network to identify and model high-order interactions when the data is transformed in this way. Experimental results show that fuzzy neural network outperforms conventional neural network for the prediction of corporate bankruptcy.

Key words: fuzzification; neural networks; bankruptcy prediction

* KAIST Graduate School of Management