

신경망기법을 이용한 기업부실예측에 관한 연구

정기웅* · 홍관수**

<요 약>

본 연구의 목적은 특정 금융기관의 주거래기업들에 대한 부실예측을 위해 주거래기업들을 잠식, 도산, 그리고 건전기업과 같이 세집단으로 구분하여 예측하고자 하며, 기업부실 예측력에 영향을 미치는 세가지 요인으로서 표본구성, 투입변수, 분석기법의 관점에서 다음을 살펴보는 것이다.

첫째, 기업부실예측에서 전통적인 *delta learning rule*과 *sigmoid*함수를 사용한 역전파학습(신경망 I)과 이들의 변형형태인 *normalized cumulative delta learning rule*과 *hyperbolic tangent*함수를 사용한 역전파 학습(신경망II)과의 예측력의 차이를 살펴보고 또한 이러한 두가지 신경망기법의 예측력을 MDA(다변량판별분석) 결과와 비교하여 신경망기법에 대한 예측력의 유용성을 살펴보고자 한다. 둘째, 세집단분류문제에서는 잠식, 도산, 건전기업의 구성비율이 위의 세가지 예측기법의 결과에 어떠한 영향을 미치는지를 살펴보고자 한다. 셋째, 투입변수선정은 기존연구 또는 이론을 바탕으로 연구자의 판단에 의해 선택하는 방법과 다수의 변수를 가지고 통계적기법에 의해 좋은 판별변수의 집합을 찾는 것이다.

본 연구에서는 이러한 방법들에 의해 선정된 투입변수들이 세가지 예측기법의 결과에 어떠한 영향을 미치는지를 살펴보고자 한다.

이러한 관점에서 본 연구의 실증분석결과를 요약하면 다음과 같다.

1) 신경망기법이 두집단에서와 같이 세집단 분류문제에서도 MDA보다는 더 높은 예측력을 보였다. 2) 잠식과 도산기업의 수는 비슷하게 그리고 건전기업의 수는 잠식과 도산기업을 합한 수와 비슷하게 표본을 구성하는 것이 예측력을 향상하는 데 도움이 된다고 할 수 있다. 3) 속성별로 고르게 투입변수로 선정한 경우가 그렇지 않은 경우보다 더 높은 예측력을 보였다. 4) 전통적인 *delta learning rule*과 *sigmoid*함수를 사용한 역전파학습 보다는 *normalized cumulative delta learning rule*과 *hyperbolic tangent*함수를 사용한 역전파 학습이 더 높은 예측력을 보였다. 이러한 현상은 두집단문제에서 보다 세집단문제에서 더 큰 차이를 나타내고 있다.

* 계명대학교 경영학과 조교수

**계명대학교 경영학과 부교수.

I. 서 론

기업부실은 투자자뿐만 아니라 경영관리자, 채권자, 종업원, 고객, 주주 등과 같은 이해관계자들에게 경제적손실을 초래하고 더 나아가 사회적, 경제적으로 막대한 비용을 초래한다. 그러므로 기업부실화를 사전에 예측할 수 있다면 이해관계자들은 조기에 예방적 조치를 취하여 부실에 따른 비용 및 경제적 비효율성을 최소화할 수 있다.

특히, 우리나라에서는 금융시장개방과 금리자유화 등 여러가지 금융환경변화로 인하여 향후에는 은행 스스로 대출대상기업을 결정하여야 할 뿐만 아니라 대출금리도 직접 결정하여야 될 상황에 처해있으므로 은행 등 금융기관들에게는 부실거래 및 부실대출을 최소화하면서 경쟁력을 갖추기 위해서는 부실기업의 사전적 예측이 매우 중요하다고 하겠다.

이와 같은 관점에서 기업부실을 예측하기 위해 많은 연구들이 수행되어 왔다. 일반적으로 기존의 기업부실 예측에 관한 연구들은 기업부실의 정의에 따라 도산예측과 부실예측으로 구분할 수 있다. 즉, 기업부실을 협의로 정의하여 도산예측 그리고 광의로 정의하여 부실예측이란 제목으로 많은 연구들이 수행되어졌다. 여기에서 광의의 기업부실은 통상적인 경영수단으로 해결할 수 없는 지급불능의 저하를 말하며, 협의의 기업부실은 법률적 파산을 의미한다[1]. 그러나 도산예측이든 부실예측이든 두개의 집단, 즉 건전기업과 비건전기업으로 구분하여 예측을 하였다.

그러나 대부분의 기업부실은 순간적으로 일어나는 것이 아니라 점진적으로 전개되는 일련의 과정을 거치면서 최종적으로 파산에 이르게 된다. 따라서 파산의 중간단계라 할 수 있는 자본잠식에 대한 정보를 예측할 수 있다면 파산과 같은 극단적인 상황에 이르기 전에 미리 적절한 행동을 취하여 경제적 손실을 최소화할 수 있을 것이다. 그러므로 기업부실예측을 건전과 비건전의 두 집단으로 구분하여 예측을 하는것 보다는 비건전기업을 부실화 정도에 따라 세분화하여 예측하는 것이 의사결정자들에게 보다 유익한 정보를 제공하여 줄 수 있다. 이러한 관점에서 본 연구에서는 기업부실화 과정의 중간단계를 자본잠식으로, 마지막단계를 도산으로 간주하여 비건전기업을 크게 자본잠식기업과 도산기업으로 나누어 예측하고자 한다.

기존의 두집단분류문제인 기업도산 또는 부실예측연구는 재무비율과 같은 회계정보를 가지고 다변량판별분석(multivariate discriminant analysis: MDA), 로지트분석(logistic regression analysis), 프로빗분석(probit analysis)과 같은 통계적기법, 특히 다변량판별분석을 많이 사용하였다. 그러나 이러한 통계적기법들은 특정기법이 갖는 엄격한 가정에 의해 사용상의 제약을 받는다는 한계점을 가지고 있다. 반면에 이러한 한계점을 극복하기 위하

여 최근에는 특정 통계적 가정을 전제로 하지 않는 인공지능기법 중의 하나인 인공신경망(neural networks)을 이용한 예측연구들이 다수 나왔다. 이러한 인공신경망기법은 다변량 판별분석, 로지트분석, 프로빗분석과 같은 기존의 통계적모형이나, 귀납적학습방법, 사례 기반예측(case-based forecasting)과 같은 여타의 인공지능기법보다 상대적으로 높은 예측력을 보여주고 있다[3-6,12,14-18].

인공신경망이 기업부실예측, 신용평가, 주가예측 등과 같은 예측분야에서 많이 이용되고 기대이상의 결과를 보이는 중요한 이유는 기존의 학습방법에서 찾아 볼 수 없는 오류극복성(fault tolerance)과 학습성(learnability)을 가지고 있기 때문이라 할 수 있다[9,10].

신경망은 몇개의 뉴런에 오류가 발생하여도 신경망의 전체적인 기능에는 크게 영향을 받지 않는 오류극복성을 가지고 있다. 이는 학습된 정보가 한곳에 집중되어 있지 않고 시스템 전체에 분배되어지기 때문이다. 따라서 기업부실예측과 같은 예측분야에서의 특징이라 할 수 있는 갑작스런 환경의 변화에도 신경망이 잘 적용될 수 있다고 할 수 있다. 또한 신경망은 전통적인 전문가시스템과는 달리 주어진 학습자료로부터 알려지지 않은 규칙을 찾아낼 수 있는 학습성의 능력을 가지고 있다.

따라서 본 연구의 목적은 특정 금융기관의 주거래기업들에 대한 부실예측을 위해 주거래기업들을 자본잠식, 도산, 그리고 건전기업과 같이 세집단으로 구분하여 예측하고자 하며, 기업부실 예측력에 영향을 미치는 세가지 요인으로서 표본구성, 투입변수, 분석기법의 관점에서 다음과 같이 살펴보는 것이다.

첫째, 기업부실예측문제에 가장 널리 사용된 신경망기법은 전방향네트워크(feedforward network) 구조를 가진 역전파학습(back propagation)이다. 또한 역전파학습에서 가장 널리 사용된 학습방법과 전이함수는 delta learning rule과 sigmoid함수이다. 그러나 다른 연구는 delta learning rule과 sigmoid함수 대신에 이들의 변형된 형태인 normalized cumulative delta learning rule과 hyperbolic tangent함수를 사용하여 Fisher의 붓꽃자료(Fisher's Iris data) 분류문제에서 좋은 결과를 보여주었다[11]. 따라서 본 연구에서는 기업부실예측에서도 기존의 전통적인 delta learning rule과 sigmoid함수를 사용한 역전파학습(신경망 I)보다 normalized cumulative delta learning rule과 hyperbolic tangent함수를 사용한 역전파 학습(신경망II)이 더 좋은 예측력을 보여줄 수 있는지를 살펴보고 또한 이러한 두가지 신경망기법의 예측력을 MDA 결과와 비교하여 신경망기법에 대한 예측력의 유용성을 살펴보고자 한다.

둘째, 두집단 분류문제에서는 분석에 사용된 건전과 비건전기업의 수가 일치할 때 예측력이 높게 나타났으나[12,18], 세집단분류문제에서는 잠식, 도산, 건전기업의 구성비율이

위의 세가지 예측기법의 결과에 어떠한 영향을 미치는지를 살펴보고자 한다.


세째, 투입변수선정은 기존연구 또는 이론을 바탕으로 연구자의 판단에 의해 선택하는 방법과 다수의 변수를 가지고 통계적기법에 의해 좋은 판별변수의 집합을 찾는 것이다. 본 연구에서는 이러한 방법들에 의해 선정된 투입변수들이 세가지 예측기법에 어떠한 영향을 미치는지를 살펴보고자 한다.

II. 신경망기법

본 연구에서 사용되는 신경망의 구조는 [그림 1]에서와 같이 입력층, 은닉층 그리고 출력층으로 구성되어 있다. 네트워크는 입력층, 은닉층, 출력층 방향으로 연결되어 있으며 각 층 내의 연결과 출력층에서 입력층으로의 직접적인 연결은 존재하지 않는 전방향 네트워크 구조를 가진 역전파학습이다.

뉴런 j의 출력은 j 뉴런의 순입력(net input)을 특정 전이함수(transfer function)로 전이시켜 얻어지며 다음과 같이 표시된다.

$$O_i = f(\sum_j (W_{ji} \cdot O_j)) = f(I_i) \tag{1}$$



[그림 1] 신경망구조

여기서 W_{ij} 는 뉴런 i 와 뉴런 j 를 연결하는 가중치, O_i 는 뉴런 i 의 출력, 그리고 I_j 는 뉴런 j 의 순입력을 나타낸다.

이러한 전이함수 중에서 가장 널리 사용되는 함수는 sigmoid함수로 다음과 같이 정의된다.

$$f(z) = \frac{1}{(1.0 + e^{-z})} \quad (2)$$

반면에, 위의 sigmoid함수의 대안으로 사용될 수 있는 hyperbolic tangent함수는 다음과 같이 정의된다.

$$f(z) = \frac{(e^z - e^{-z})}{(e^z + e^{-z})} \quad (2)$$

sigmoid함수는 출력값의 범위가 0과 1사이이며, 반면에 hyperbolic tangent함수는 -1과 1사이의 값을 출력한다.

이런 과정이 출력층에 이를 때까지 계속되고 최후에 출력층에서 값을 출력한다. 이를 전방향학습이라고 한다. 이 출력값과 기대값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해나간다. 이러한 과정을 역방향학습이라고 한다.

은닉층에 대한 오차는 출력층의 오차와 그사이의 연결강도 W_{kj} 를 이용하여 다음과 같이 구해진다.

$$e_j = f'(I_j) \cdot \sum(e_k \cdot W_{kj}) \quad (4)$$

만약 전이함수로 sigmoid함수를 사용하면 이것의 미분은 다음과 같다.

$$f'(z) = f(z) \cdot (1.0 - f(z)) \quad (5)$$

따라서 식 (1)로 부터 식 (4)는 다음과 같이 표시되어 진다.

$$e_i = O_i(1.0 - O_i) \cdot \sum(e_k \cdot W_{ki}) \quad (6)$$

반면에 전이함수로 hyperbolic tangent함수를 사용하면 이것의 미분과 식 (4)는 다음의 식 (7)과 (8)로 표시된다.

$$f'(z) = (1.0 + f(z)) \cdot (1.0 - f(z)) \quad (7)$$

$$e_j = (1.0 + O_j) \cdot (1.0 - O_j) \cdot \sum(e_k \cdot W_{kj}) \quad (8)$$

그리고 출력층에서의 e_k 는 은닉층에서와는 달리 다음과 같이 계산되어 진다.

$$e_k = f'(I_k) \cdot (d_k - O_k) \quad (9)$$

역전파학습에서 위와 같은 오차를 적게하기 위해 일반적으로 많이 사용되는 연결강도의 변화 ΔW_{ji} 에 대한 수식은 다음과 같다.

$$\Delta W_{ji} = \eta \cdot e_j \cdot O_i + \alpha \cdot \Delta W_{ji} \quad (10)$$

여기에서 η 는 학습율, α 는 상수, 그리고 $\alpha \cdot \Delta W_{ji}$ 는 오차진동을 작게 하여 수렴속도를 빨리하기 위하여 첨가된 모멘텀항(momentum term)이다.

이러한 연결강도의 수정방법은 크게 두가지가 있는데 하나는 매번 학습패턴을 제시할 때마다 연결강도를 변경하는 방법(delta learning rule)이고 다른 하나는 특정수(epoch)의 학습패턴이 네트워크에 입력된 후 학습패턴 각각에 대한 오차로부터 구한 연결강도의 수정치를 평균하여 일괄적으로 수정하는 일괄연결강도수정법(normalized cumulative delta learning rule)이다[8,10].

본 연구에서는 매 학습패턴마다 오차를 계산하여 sigmoid함수를 사용하는 역전파학습(신경망 I), 그리고 일괄연결강도수정법과 hyperbolic tangent함수를 사용한 역전파학습(신경망 II)을 사용하여 예측력이 어떠한 차이를 보이는지를 살펴보고자 한다.

Ⅲ. 실증적 연구의 설계

3.1 표본의 선정

P 금융기관의 주거래 대상업체로서 실증분석에 사용된 자본잠식기업의 조작적 정의는 다음과 같다.

- (1) 법정자본금보다 자기자본이 적은 업체
 - (2) 자기자본이 마이너스(-)인 업체
- 그리고 도산기업의 조작적 정의는 다음과 같다.

- (1) 부도발생업체
- (2) 폐업한 업체
- (3) 회사정리절차를 신청, 개시, 진행중인 업체

실증분석에 사용된 부실기업은 상기한 부실기업의 조작적 정의에 따라 다음과 같은 기준으로 선정하였다.

- (1) 부실기업은 1991년부터 1994년 사이의 자본잠식 또는 도산기업
 - (2) 재무제표상의 총자산액이 20억원을 초과하는 비교적 규모가 큰 제조법인기업
- 부실기업과 대응이 되는 건전기업은 다음과 같은 기준으로 선정하였다.

- (1) 1994년말 현재 정상조업업체
- (2) 유사한 업종, 자산규모 그리고 법적형태
- (3) 동일한 회계연도

위와 같은 조건에 맞는 자료를 입수할 수 있는 표본부실기업은 40개로 한정되었고, 표본 건전기업은 표본부실기업의 수집한계로 표본부실기업의 수와 같이 40개로 한정되었다. 이와 같이 하여 최종적으로 선정된 40쌍의 기업들의 분포를 요약하면 <표 1>, <표 2>, 그리고 <표 3>과 같다.

3.2. 표본의 분할

제한된 표본을 가지고 예측력의 신뢰성을 살펴보기 위한 여러가지 방법이 제시되고 있지만[7], 본 연구에서는 그 중의 하나인 전체표본을 분석용과 검정용으로 무작위로 분할하여 예측력을 살펴보는 실험을 반복하는 방법을 사용하였다. 예측결과에 대한 신뢰도는 전체 표본을 무작위로 분석용과 검정용으로 구분하는 절차를 단 한번 시행하여 예측력을 살펴보는 것보다는 전체표본을 무작위로 분석용과 검정용으로 구분하는 절차를 여러번 시행

〈표 1〉 표본기업의 업종별 분포

업종(한국표준산업분류번호)	부실기업	건전기업	합 계
음·식료품(15)	2	2	4
섬유(17)	3	3	6
의복 및 모피(18)	1	1	2
가죽·가방·마구류 및 신발(19)	6	6	12
목재 및 나무(20)	2	1	3
펄프 종이 및 종이 제품(21)	1	2	3
화합물 화학제품(24)	1	1	2
고무 및 플라스틱(25)	2	2	4
비금속광물(26)	1	1	2
제1차 금속제조업(27)	3	3	6
조립금속(28)	5	5	10
기계 및 장비(29)	6	6	12
전자기계 및 전기변환장치(31)	1	1	2
자동차 및 트레일러(34)	3	3	6
기타 운송장비(35)	1	1	2
가구 및 기타 제조업(36)	0	1	1
재생재료 가공처리업(37)	2	1	3
합 계	40	40	80

〈표 2〉 표본기업의 C.P.A 감사여부

구 분	부 실 기 업	건 전 기 업	합 계
CPA감사필	30	23	53(66.2%)
CPA비감사	10	17	27(33.8%)
합 계	40	40	80(100%)

〈표 3〉 표본기업의 부실기업간주시점

부실연도	잠 식	부 도	합 계
1991년	3	2	5
1992년	10	70	17
1993년	7	7	14
1994년	1	3	4
합 계	21	19	4

〈표 4〉 표본에 포함된 잠식, 도산, 건전기업의 수

구성비율	표 본 구 분		잠식기업	부도기업	건정기업	합 계
1:1:2	표본 1	분석용	13	9	22	44
		검정용	8	10	18	36
		합 계	21	19	40	80
	표본 2	분석용	10	10	20	40
		검정용	11	9	20	40
		합 계	21	19	40	80
	표본 3	분석용	8	8	16	32
		검정용	13	11	24	48
		합 계	21	19	40	80
	표본 4	분석용	12	12	24	48
		검정용	9	7	16	32
		합 계	21	19	40	80
1:1:1	표본 1	분석용	13	90	11	33
		검정용	8	10	10	28
		합 계	21	19	21	61
	표본 2	분석용	10	10	10	30
		검정용	11	9	11	31
		합 계	21	19	21	61
	표본 3	분석용	7	7	7	21
		검정용	14	12	14	40
		합 계	21	19	21	61
	표본 4	분석용	12	12	12	36
		검정용	9	7	9	25
		합 계	21	19	21	61

하여 예측력의 평균을 살펴봄으로써 결과의 신뢰성을 높일 수 있다[13]. 따라서 다음과 같이 8가지 경우로 표본을 분할하여 예측력을 살펴보고자 한다.

1) 예측의 타당성을 현재의 시점이 아닌 미래시점에서 검정하기 위해 분석용과 검정용 표본을 같은 기간내에서 추출하지 않고, 검정용표본을 분석용표본의 추출년도 이후의 기

간에서 추출하였다. 즉 전체표본을 분석용표본(1991-1992년)과 검정용표본(1993-1994년)으로 분할하였다(표본 1).

2) 부실 1년전에 해당되는 1991년에서 1994년 사이의 전체표본 80개를 무작위로 분석용표본과 검정용표본의 수가 같은 경우(표본 2), 분석용표본의 수가 검정용표본의 수보다 작은 경우(표본 3), 그리고 분석용표본의 수가 검정용표본의 수보다 큰 경우(표본 4)로 분할하였다.

3) 예측력은 분석용과 검정용에 사용된 잠식, 부도 그리고 건전기업을의 표본구성비율에 영향을 받는다. Wilson과 Sharda[18]는 두집단분류문제에서 분석용과 검정용에 포함된 건전기업과 비건전기업의 수를 다르게 하여 9가지의 표본구성비율에 따른 예측력을 살펴보았다. 그 결과 기존의 많은 연구에서와 같이 건전기업과 비건전기업의 구성비율을 같게 하였을 때 가장 높은 예측력을 보여주었다. 따라서 세집단분류문제에서는 잠식, 부도 그리고 건전기업의 표본구성비율이 예측력에 어떤 영향을 미치는가를 살펴보기 위해 잠식, 부도 그리고 건전기업의 수가 서로 같도록 구성비율이 1:1:1인 경우와, 잠식과 부도기업의 수는 같게 그리고 건전기업의 수는 잠식과 부도기업의 수를 합한것과 같도록 한 구성비율이 1:1:2인 경우로 크게 나누어 위의 두가지 방법에 따라 표본을 분할하였다.

이와 같이 분할한 경우 각 표본의 분석용과 검정용표본의 수, 그리고 각 분석용과 검정용에 사용된 잠식, 도산, 건전기업의 수는 <표 4>에 제시되어 있다. <표 4>에서 표본 1의 경우는 연도에 따라 분석용과 검정용으로 분할하였기 때문에 분석용에 포함된 잠식, 도산, 건전기업의 수는 구성비율인 1:1:1 및 1:1:2에 일치하지 않는다.

3.3. 변수의 선정

부실기업과 건전기업을 판별할 수 있는 독립변수를 선정하기 위해 먼저 기존의 국내외 연구문헌들의 검토를 바탕으로 객관적으로 자료수집이 가능한 37개의 재무비율을 선정하고, 편의상 이들 재무비율을 수익성, 유동성, 안정성, 활동성, 성장성비율로 구분하였다. 그 결과는 <표 5>와 같다.

이러한 37개의 재무비율들은 단순히 판별력을 가지고 있다고는 생각되나 그 비율들이 실제로 지니고 있는 가치나 필요성에 대해서는 불확실하다. 어떤 비율들은 집단간의 차이를 잘 구별못하는 비율로 판명될 수도 있고 혹은 개별적으로는 우수하나 다른 변수들과의 상관관계에 의해 판별정보를 공유하고 있는 변수들도 있다. 따라서 판별에 공헌도가 낮거나 중복되는 비율들은 어떤 논리적인 타당성이 인정되지 않는한 분석과정에서 제외하는

〈표 5〉 재무비율

구분	번호	비율	산식
수익성	X1	매출액순이익율	순이익/매출액
	X2	총자산순이익율	순이익/총자산
	X3	자기자본순이익율	순이익/자기자본
	X4	매출액경상이익율	경상이익/매출액
	X5	총자산경상이익율	경상이익/총자산
	X6	매출액영업이익율	영업이익/매출액
	X7	총자산영업이익율	영업이익/총자산
	X8	매출액총이익율	매출총이익/매출액
	X9	매출액대지급이자비율	매출액/지급이자
	X10	순금융비용대매출액 비율	순금융비용/매출액
	X11	매출액대영업외비용비율	매출액/영업외비용
	X12	자기자본경상이익율	경상이익/자기자본
유동성	X13	유동자산대총자산비율	유동자산/총자산
	X14	순운전자본대총자본비율	순운전자본/총자본
	X15	유동비율	유동자산/유동부채
	X16	당좌비율	당좌자산/유동부채
	X17	유동자산대재고자산비율	유동자산/재고자산
안정성	X18	1/부채비율	자기자본/총부채
	X19	자기자본대유동부채비율	자기자본/유동부채
	X20	자기자본비율	자기자본/총자본
	X21	총자산대차입금비율	총자산/차입금
	X22	1/고정장기적합율	고정부채+자기자본/고정자산+투자자산+기타자산
	X23	매출액대차입금비율	매출액/차입금
활동성	X24	총자산회전율	매출액/총자산
	X25	재고자산회전율	매출액/재고자산
	X26	고정자산회전율	매출액/고정자산
	X27	매출채권회전율	매출액/매출채권
	X28	매입채무회전율	매출액/매입채무
	X29	1/운전자본회전율	운전자본/매출액
	X30	경영자본회전율	매출액/경영자본
성장성	X31	매출채권증가율	(당기매출채권/전기매출채권)-1
	X32	재고자산증가율	(당기재고자산/전기재고자산)-1
	X33	고정자산증가율	(당기고정자산/전기고정자산)-1
	X34	총자산증가율	(당기총자산/전기총자산)-1
	X35	매입채무증가율	(당기매입채무/전기매입채무)-1
	X36	매출액증가율	(당기매출액/전기매출액)-1
	X37	경상이익증가율	(당기경상이익/전기경상이익)-1

것이 바람직하다. 이와 같은 합리적인 예측비율들을 선정하는 방법은 연구자의 판단에 의존하는 방법과 객관적 방법이라고 할 수 있는 통계적 절차를 이용하는 방법이 있다. 여러 가지 통계적 절차 중에서 여기서는 단계적 판별분석법(stepwise discriminant analysis)을 고려하고자 한다.

표본기업을 대상으로 부실기업과 건전기업을 판별하기 위하여 사용된 예측변수는 첫째, 37개의 모든 비율들을 대상으로 단계적 판별분석법을 사용하여 선정된 예측변수들(변수집합 I), 둘째, 재무비율의 속성별(수익성, 유동성, 안정성, 활동성, 성장성)로 가능한 한 하나 이상의 비율이 선정되도록 속성별로 단계적 판별분석법을 사용하여 선정된 예측변수들(변수집합 II), 셋째, 기존 문헌들을 검토한 결과 가장 유효하다고 판단되는 변수를 각 속성에서 2개씩 추출하여 10개의 예측변수들(변수집합 III)을 선정하였다.

3.4. 분석방법

앞에서 설명한 세가지 유형의 기업집단을 잘 판별할 수 있는가를 살펴보기 위해 세가지 분석기법(MDA, 신경망 I, 신경망 II)과 세가지 투입변수(변수집합 I, 변수집합 II, 변수집합 III)의 결합에 의한 9가지의 예측기법을 8가지 유형의 표본에 대하여 실험을 실시하였다. 이러한 9가지의 예측기법에 사용된 예측변수와 기법의 특징을 요약하면 <표 6>과 같다.

인공신경망 실험을 위해서는 상용패키지인 NeuralWorks Professional II/Plus를 사용하였다. 신경망 I과 신경망 II에 사용된 학습률과 모멘텀은 패키지의 기본값을 사용하였고, 학습시 사용된 학습멈춤규칙은 학습횟수가 20,000번에 이르면 학습을 마치도록 하였다. 학습횟수가 10,000이하에서는 은닉층과 출력층의 학습률이 각각 0.30과 0.15이고 모멘텀은 0.4이다. 학습횟수가 10,000이상에서는 은닉층과 출력층의 학습률이 각각 0.15와 0.075이고 모멘텀은 0.2이다.

은닉층의 뉴런의 수는 투입층의 뉴런의 수와 같게 하였고, 출력층의 뉴런의 수는 분류하고자 하는 집단의 수와 같게 하였다. 예를 들어, 잠식, 도산, 건전기업과 같은 세집단인 경우에는 3개의 뉴런을, 부실과 건전기업의 두 집단인 경우에는 2개의 뉴런을 설정하였다.

최종 분류기준은 개체 X 가 집단 G_i 에 속할 출력층 뉴런의 값을 $P(G_i | X)$ 라 하면 $P(G_i | X)$ 가 $P(G_1 | X), \dots, P(G_k | X)$ 중에서 최대값일 때 X 를 집단 G_i 에 분류하는 방법을 사용하였다. 신경망 II의 특정수(epoch)의 값은 패키지의 기본값인 16을 사용하였다.

투입변수를 선정하기 위해 사용한 단계적 판별분석은 SAS의 STEPDISC 처리절차를 이용하였다. 각 단계에서 변수를 선정하기 위한 기준으로서 부분-F통계량과 Wilks의 Λ 를

〈표 6〉 분석에 사용된 예측기법의 유형

예측기법	사용된 예측변수	사용된 기법
판별 1	변수집합 I	다변량판별분석
신경망 I-1	변수집합 I	신경망 I
신경망 II-1	변수집합 I	신경망 II
판별 2	변수집합 II	다변량판별분석
신경망 I-2	변수집합 II	신경망 I
신경망 II-2	변수집합 II	신경망 II
판별 3	변수집합 III	다변량판별분석
신경망 I-3	변수집합 III	신경망 I
신경망 II-3	변수집합 III	신경망 II

변수집합 I : 37개의 전체비율을 사용하여 단계적판별분석에 의해 선정된 변수

변수집합 II : 속성별로 단계적판별분석에 의해 선정된 변수

변수집합 III : 기존문헌들을 토대로 선정된 10개의 변수

신경망 I : delta learning rule과 sigmoid함수를 사용한 역전파학습

신경망 II : normalized cumulative delta learning rule과 hyperbolic tangent함수를 사용한 역전파학습

기준으로 변수를 선택하였고, 변수의 추가 및 제거에 관한 부분 F-검정의 유의수준은 기본값인 0.15를 사용하였다.

다변량판별분석(MDA)은 SAS의 DISCRIM 처리절차를 이용하였다. 부분집단들의 모집단분포가 동일한 공분산행렬을 갖고 있는가의 여부를 검정한 후, 공분산행렬이 같은 경우와 다른 경우로 나누어 분류방법을 채택하는 것이 바람직하다[2]. 따라서 SAS의 DISCRIM 처리절차에서 POOL=TEST라는 선택을 사용하였다.

IV. 실증분석의 결과

본 연구의 실증분석은 전술한 바와 같이 다음의 3가지 가설을 대상으로 한다. 첫째, 세 집단 분류시 어떠한 표본구성 비율이 예측력을 높이는가? 둘째, 부실예측기법으로서의 분석기법간에 예측력의 차이가 얼마만큼 존재하는가? 셋째, 투입변수의 선정이 예측력에 어떠한 영향을 주는가?

이를 위해 먼저 SAS의 STEPDISC 처리절차를 사용하여 잠식, 도산, 건전기업의 구성비

<표 7> 단계적판별분석에서 선택된 변수(세집단)

판별방법	구성비율	표 본	수익성	유동성	안정성	활동성	성장성	
변수집합I	1:1:2	표본 1	X7,X10		X20			
		표본 2		X4	X14	X21,X22	X28	
		표본 3	X4,X5			X29	X31	
		표본 4	X7,X10,X12		X20			
	1:1:1	표본 1	X10			X20		
		표본 2	X8,X10,X12			X19,X22	X24,X28,X30	X31
		표본 3				X22		
		표본 4	X2,X7,X8	X16	X18,X20	X26,X29	X32,X37	
변수집합II	1:1:2	표본 1	X6,X10	X16	X18,X20	X29		
		표본 2	X5,X10	X14,X15	X21,X22	X27,X29		
		표본 3	X4,X5,X6,X10,X12	X15	X22,X22	X29	X35,X36,X37	
		표본 4	X7,X10,X12	X16	X18,X20	X25,X29	X32,X34,X35,X36	
	1:1:1	표본 1	X5,X10		X20			
		표본 2	X8,X10,X11	X14,X15	X22,X23	X24,X28,X29	X31	
		표본 3	X5,X12	X14,X16	X22	X32		
		표본 4	X2,X5,X8,X10,X12	X14,X16	X18,X20	X28,X29		

올과 표본의 종류에 따라 선정된 변수들은 <표 7>과 같다. 그리고 기존 연구들과 이론을 바탕으로 예측에 사용된 10개의 변수는 다음과 같다.

X6, X10, X14, X16, X18, X20, X25, X30, X34, X36

<표 7>에서 보는 바와 같이 선택된 변수들은 16가지 모두 표본의 구성에 따라 상당히 다르다는 것을 알 수 있다. 37개의 모든 비율들을 대상으로 단계적 판별분석법을 사용하여 선정된 예측변수들인 변수집합 I을 살펴보면 전체 8가지 표본중 속성별 비율이 포함된 것은 수익성(7번), 안정성(7번), 활동성(4번), 성장성(3번) 유동성(2번)의 순으로 많이 선택되었다. 속성별로 선택된 비율의 수는 전혀 포함되지 않은 경우에서부터 많게는 3개 포함된 경우(구성비율이 1:1:2이고 표본 4의 수익성, 1:1:1이고 표본 2의 수익성과 활동성 그리고 표본 4의 수익성)가 있다. 예측변수로서 비율 X10(4번), X20(4번), X22(3번)의 순으로 많이

선정되었다.

재무비율의 속성별로 단계적 판별분석법을 사용하여 선정된 예측변수들인 변수집합 II를 살펴보면 전체 8가지 표본중 속성별 비율이 포함된 것은 수익성(8번), 안정성(8번), 유동성(7번), 활동성(6번), 성장성(4번)의 순으로 많이 선택되었다. 속성별로 선택된 비율의 수는 전혀 포함되지 않은 경우에서부터 많게는 5개 포함된 경우(구성비율이 1:1:1이고 표본 4의 수익성)가 있다. 예측변수로서 비율 X10(7번), X20(4번), X16(4번)의 순으로 많이 선택되었다.

전체적으로 수익성과 안정성비율이 상대적으로 많이 선택되었고, 유동성과 성장성에 관련된 비율이 적게 선택되었다. 예측변수로는 비율 X10과 X20이 많이 선택되었다.

<표 7>의 변수집합 I과 변수집합 II 그리고 기존문헌을 토대로 한 10개의 예측변수들인 변수집합 III을 투입변수로 하여 자본잠식, 도산, 건전기업으로 구분한 세개의 집단에 대한 분석결과는 구성비율이 1:1:2인 경우에는 <표 8>과 같고 구성비율이 1:1:1인 경우에는 <표 9>와 같다.

<표 8>과 <표 9>에서 분류행렬의 첫번째 행과 열은 자본잠식기업, 두번째 행과 열은 도산기업, 그리고 세번째 행과 열은 건전기업을 나타낸다. 예를 들어, 1행 1열의 원소는 자본잠식기업을 자본잠식기업으로 올바르게 판명한 경우이고, 1행 2열의 원소는 자본잠식기업을 도산기업으로 잘못 판단한 경우이며, 1행 3열의 원소는 자본잠식기업을 건전기업으로 잘못 판단한 경우이다.

첫째로 잠식, 도산, 건전 등의 세집단 분류시 표본구성비율의 차이에 따라 예측력이 어떻게 차이가 나는가를 살펴보고자 한다. <표 8>과 <표 9>를 비교하면 구성비율이 1:1:2인 경우가 1:1:1인 경우보다 모든 기법에서 예측력이 더 높은 것으로 나타났다. 이는 잠식과 도산기업의 수는 비슷하게 그리고 건전기업의 수는 잠식과 도산기업의 합한 수와 비슷하게 하는 것이 다른 구성비율을 사용한 경우보다 예측력이 높다는 것을 말해준다. 두집단 분류문제에서 건전과 비건전기업의 수가 일치할 때 예측력이 높게 나타났듯이[10,15], 세집단인 경우에는 잠식과 도산기업의 재무비율의 특성이 건전기업보다는 상대적으로 서로 비슷하므로 잠식과 도산기업의 수는 비슷하게 그리고 건전기업과 대별되는 부실기업인 잠식기업과 도산기업의 합한 수는 건전기업의 수와 비슷하게 하는 것이 바람직하다.

둘째, 분석기법의 차이에 따른 예측력의 차이를 살펴보면 다음과 같다. <표 8>에서 같은 투입변수를 3가지 분석기법에 사용한 결과는 신경망 II, 신경망 I, MDA의 순으로 높은 예측력을 보였다. 예를들어, 변수집합 I을 투입변수로 하였을 때 판별분석, 신경망 I, 신경망 II의 평균 예측력은 각각 61.17%, 66.74%, 68.68%로서 예측력은 신경망 II, 신경망 I, MDA

〈표 8〉 구성비율이 1:1:2인 경우의 분류행렬과 예측률

구분	표본 1	표본 2	표본 3	표본 4	평균 예측률
판별 1	5 1 2 6 1 3 2 3 13 (52.78%)	6 4 1 3 5 1 0 8 0 (57.50%)	8 3 2 3 5 3 4 3 17 (60.00%)	4 1 4 1 4 2 0 1 15 (71.88%)	61.17%
신경망 I-1	6 0 2 6 2 2 1 3 14 (61.11%)	5 0 6 3 5 1 1 0 19 (72.50%)	4 0 9 0 10 1 0 7 17 (62.00%)	4 0 5 2 4 1 1 1 14 (68.75%)	66.74%
신경망 II-1	5 1 2 6 2 2 1 1 16 (63.89%)	8 0 3 1 7 1 1 3 16 (77.50%)	7 0 6 2 8 1 2 6 16 (62.00%)	4 0 5 2 4 1 1 1 14 (68.75%)	68.68%
판별 2	6 1 1 8 2 0 3 3 12 (55.56%)	4 6 1 1 4 4 2 0 18 (65.00%)	3 0 10 0 5 6 0 0 24 (66.67%)	4 0 5 0 5 2 0 0 16 (78.13%)	66.34%
신경망 I-2	6 0 2 4 4 2 1 2 15 (69.44%)	4 1 6 1 6 2 1 1 18 (70.00%)	6 0 7 1 8 2 4 1 19 (68.75%)	4 0 5 2 4 1 0 1 15 (78.13%)	70.02%
신경망 II-2	7 0 1 5 3 2 2 0 16 (72.22%)	6 1 4 1 6 2 1 1 18 (72.50%)	8 0 5 0 8 3 6 2 16 (66.67%)	4 0 5 0 6 1 0 1 15 (78.13%)	72.38%
판별 3	5 0 3 9 0 1 4 0 14 (52.77%)	4 1 6 0 6 3 0 0 20 (75.00%)	3 0 10 0 5 6 0 0 24 (66.67%)	4 0 5 1 5 1 1 0 15 (75.00%)	67.36%
신경망 I-3	7 0 1 6 2 2 2 0 16 (69.44%)	6 0 5 4 3 2 0 2 18 (67.50%)	7 1 5 4 7 0 1 2 21 (72.92%)	4 0 5 4 0 3 0 0 16 (62.50%)	68.09%
신경망 II-3	6 0 2 2 6 2 1 1 16 (77.78%)	5 1 5 0 9 0 1 2 17 (77.50%)	6 0 7 0 10 1 1 3 20 (75.00%)	4 0 5 1 5 1 0 0 16 (78.13%)	77.10%

<표 9> 구성비율이 1:1:1인 경우의 분류행렬과 예측률

구 분	표본 1	표본 2	표본 3	표본 4	평균 예측률
판별 1	6 1 1	3 1 7	3 9 2	5 0 4	54.42%
	7 1 2	0 2 7	0 1 1	5 1 1	
	0 2 8	0 0 11	2 5 7	0 0 9	
	(53.57%)	(51.61%)	(52.50%)	(60.00%)	
신경망 I-1	6 0 2	4 1 6	9 0 5	4 0 5	52.87%
	8 0 2	4 1 4	4 5 3	5 1 1	
	1 0 9	1 0 10	3 2 9	0 1 8	
	(53.57%)	(48.39%)	(57.50%)	(52.00%)	
신경망 II-1	7 0 1	4 1 6	9 0 5	6 0 3	58.03%
	6 2 2	2 4 3	3 3 6	3 3 1	
	2 0 8	2 2 7	3 1 10	0 1 8	
	(60.71%)	(48.39%)	(5.00%)	(68.00%)	
판별 2	7 0 1	9 1 1	3 1 1 0	9 0 0	49.55%
	4 2 4	3 2 4	1 1 1 0	6 1 0	
	2 1 7	3 1 7	0 1 4 0	7 0 2	
	(57.14%)	(58.06%)	(35.00%)	(48.00%)	
신경망 I-2	7 0 1	4 1 6	8 0 6	4 0 5	26.28%
	6 2 2	3 3 3	3 7 2	5 1 1	
	2 0 8	3 0 8	2 3 9	0 0 9	
	(60.71%)	(48.39%)	(60.00%)	(56.00%)	
신경망 II-2	5 0 3	9 1 2	7 0 7	4 0 5	58.73%
	3 5 2	6 0 3	3 8 1	3 3 1	
	0 2 8	3 1 7	4 3 7	0 0 9	
	(64.29%)	(51.61%)	(55.00%)	(64.00%)	
판별 3	6 0 2	7 1 3	8 5 1	7 0 2	53.71%
	9 0 1	3 4 2	1 1 1 0	5 1 1	
	3 0 7	4 1 6	1 1 2 1	1 0 8	
	(46.43%)	(54.39%)	(50.00%)	(64.00%)	
신경망 I-3	7 0 1	6 1 4	6 0 8	4 0 5	62.10%
	6 2 2	0 9 0	2 8 2	5 1 1	
	2 0 8	2 1 8	4 1 9	0 0 9	
	(60.71%)	(74.19%)	(57.50%)	(56.00%)	
신경망 II-3	7 0 1	4 1 6	5 0 9	6 0 3	61.13%
	6 3 1	0 9 1	0 1 1 1	6 0 1	
	1 1 8	1 1 8	5 4 5	0 0 9	
	(64.29%)	(67.74%)	(52.50%)	(60.00%)	

의 순으로 우수하다. 변수집합 II와 변수집합 III을 사용한 경우도 신경망 II, 신경망 I, MDA의 순으로 높은 예측력을 보여주고 있다.

<표 9>에서는 변수집합 I과 변수집합 II의 경우에는 신경망 II, 신경망 I, MDA의 순으로 그리고 변수집합 III의 경우에는 신경망 I, 신경망 II, MDA의 순으로 높은 예측력을 보이고 있다.

따라서 <표 8>과 <표 9>를 종합하면, 신경망 II가 신경망 I과 MDA보다 평균적으로 더 높은 예측력을 보여주고 있다.

마지막으로 투입변수의 차이에 따른 예측력의 차이를 살펴보고자 한다.

<표 8>에서 같은 기법을 3가지 투입변수에 적용한 결과, 변수집합 III, 변수집합 II, 변수집합 I의 순으로 높은 예측력을 보여주고 있다. 예를들어, <표 8>에서 MDA기법을 사용한 결과를 보면 변수집합 I, 변수집합 II, 변수집합 III에 대한 평균예측율은 각각 61.17%, 66.34% 67.36%이므로 변수집합 III, 변수집합 II, 변수집합 I의 순으로 예측력이 높게 나타났다. 신경망 I의 결과는 변수집합 II, 변수집합 III, 변수집합 I의 순으로, 그리고 신경망 II의 경우는 변수집합 III, 변수집합 II, 변수집합 I의 순으로 예측력이 높다.

<표 9>에서 MDA결과는 변수집합 I, 변수집합 III, 변수집합 II의 순으로, 신경망 I과 신경망 II의 결과는 변수집합 III, 변수집합 II, 변수집합 I의 순으로 높은 예측력을 보이고 있다.

따라서 <표 8>과 <표 9>를 종합하면, 신경망의 투입변수로 변수집합 III을 사용할 때 평균적으로 높은 예측력을 보이고 있다. 변수집합 III과 같이 투입변수로서 기업의 전반적인 재무상태를 나타낼 수 있는 다양한 재무비율들을 속성별로 고르게 선정된 변수들을 사용하는 것이 단계적 판별분석에 의해 선정된 변수들을 사용할 때 보다 더 높은 예측력을 보였다. 또한 단계적판별분석을 사용한 경우에도 재무비율의 속성별로 변수를 선택한 경우(변수집합 II)가 그렇지 않은 경우(변수집합 I)보다 예측력이 높게 나타났다.

예측력에 영향을 미치는 3가지 요인인 표본구성, 투입변수 및 분석기법의 관점에서 실증연구 결과를 종합적으로 살펴볼 때, 우선 잠식, 도산, 건전기업의 수의 구성비율은 1:1:2, 둘째, 투입변수로는 변수집합 III, 분석기법으로는 신경망 II를 사용한 경우가 평균적으로 예측력이 높게 나타났다.

비교의 목적으로 종래의 연구와 같이 <표 4>의 구성비율이 1:1:2인 경우에 잠식과 도산 기업을 합한것을 부실기업으로 간주하여 두집단 부실예측을 위의 방법과 같이 실시한 결과, 단계적 판별분석을 사용하여 선정된 변수는 <표 10>과 같고, 각 예측기법에 대한 분석 결과는 <표 11>과 같다.

〈표 10〉 단계적판별분석에서 선택된 변수(두집단)

표 본	변수집합 I	변수집합 II
표본 1	X7 X10 X20	X7 X10 X16 X20 X28 X29
표본 2	X8 X10 X22 X23	X5 X8 X10 X15 X20 X21 X22 X27 X29 X35
표본 3	X5 X12 X21 X22 X24 X25 X32	X7 X10 X11 X12 X15 X22 X23 X29 X35
표본 4	X7 X10 X12 X20	X7 X8 X10 X12 X16 X20 X25 X29 X37

세집단에서와 같이 <표 11>에서 투입변수 I과 투입변수 III을 3가지 분석기법에 사용한 결과는 신경망 II, 신경망 I, MDA의 순으로, 투입변수 II를 사용한 결과는 신경망 I, 신경망 II, MDA의 순으로 높은 예측력을 보였다. 같은 기법을 3가지 투입변수에 적용한 결과는 변수집합 III, 변수집합 II, 변수집합 I의 순으로 높은 예측력을 보여주고 있다.

결론적으로 볼 때, 세집단에서와 같이 두집단을 대상으로 한 분석에서도 투입변수로는 변수집합 III을, 분석기법으로는 신경망 II를 사용한 경우가 평균적으로 예측력이 가장 높게 나타났다.

V. 요약 및 결론

기업부실은 경제적, 사회적으로 막대한 비용을 초래하기 때문에 기업부실화를 사전에 예측할 수 있다면 이러한 불필요한 비용을 최소화할 수 있다. 대부분의 기업부실은 순간적으로 일어나는 것이 아니라 점진적으로 전개되는 일련의 과정을 거치면서 최종적으로 파산에 이르게 된다.

이러한 관점에서 본 연구에서는 부실기업예측을 위해 부실기업을 잠식기업과 도산기업으로 구분하여 잠식기업, 도산기업, 건전기업과 같이 세집단으로 구분하여 세가지 예측기법이 세집단을 잘 판별할 수 있는가를 살펴보았다. 실증분석결과를 요약하면 다음과 같다.

1) 신경망기법이 두집단에서와 같이 세집단 분류문제에서도 MDA보다는 더 높은 예측력을 보였다.

2) 잠식, 도산, 건전기업의 수의 구성비율이 1:1:1인 경우보다는 1:1:2인 경우가 더 높은 예측력을 보였다. 이는 잠식과 도산기업의 수는 비슷하게 그리고 건전기업의 수는 잠식과 도산기업을 합한 수와 비슷하게 표본을 구성하는 것이 예측력을 향상하는 데 도움이 된다

〈표 11〉 두집단인 경우의 분류행렬과 예측률

구 분	표본 1	표본 2	표본 3	표본 4	평균 예측률
판별 1	13 5 7 11 (66.67%)	16 4 5 15 (77.50%)	18 6 8 16 (70.83%)	12 4 4 12 (75.00%)	72.50%
신경망 I-1	14 4 3 15 (80.56%)	17 3 5 15 (80.00%)	20 4 9 15 (72.92%)	14 2 3 13 (84.38%)	79.47%
신경망 II-1	15 3 4 14 (80.56%)	17 3 5 15 (80.00%)	20 4 6 18 (79.17%)	14 2 3 13 (84.38%)	81.03%
판별 2	15 3 9 9 (66.67%)	15 5 2 18 (82.50%)	21 3 8 16 (77.08%)	12 4 2 14 (81.25%)	76.88%
신경망 I-2	17 1 5 13 (83.33%)	16 4 3 17 (82.50%)	23 1 8 16 (81.25%)	13 3 3 13 (81.25%)	82.30%
신경망 II-2	16 2 5 13 (80.56%)	16 4 3 17 (82.50%)	23 1 8 16 (81.25%)	14 2 4 12 (81.25%)	81.39%
판별 3	16 2 7 11 (75.00%)	19 1 4 16 (87.50%)	23 1 8 16 (81.25%)	14 2 4 12 (81.25%)	81.25%
신경망 I-3	16 2 5 13 (80.56%)	17 3 3 17 (85.00%)	23 1 6 18 (85.42%)	12 4 2 14 (81.25%)	83.06%
신경망 II-3	15 3 3 15 (83.33%)	16 4 2 18 (85.00%)	23 1 5 19 (87.50%)	13 3 2 14 (84.38%)	85.06%

고 할 수 있다.

3) 속성별로 고르게 선정한 경우가 그렇지 않은 경우보다 더 높은 예측력을 보였다. 투입변수를 기업의 전반적인 재무상태를 나타낼 수 있는 다양한 재무비율들이 고르게 투입변수로 선정될 수 있도록 하는 것이 바람직하다고 할 수 있다.

4) 기존의 연구에서 많이 사용된 delta learning rule과 sigmoid함수를 사용하는 기법(신

경망 I) 보다는 normalized cumulative delta learning rule과 hyperbolic tangent를 사용한 기법(신경망 II)이 더 높은 예측력을 보였다. 이러한 현상은 두집단문제에서 보다 세집단문제에서 더 큰 차이를 나타내고 있다.

본 연구가 지니는 문제점이거나 한계점은 다음과 같다.

1) 표본기업으로서 부실기업을 많이 확보하기 위해 전산업을 대상으로 하였기 때문에 업종별 특성과 기업규모의 특성이 무시되었다.

2) 자료수집의 어려움때문에 부실 1년전에 해당되는 경우만을 살펴보았으나 이전의 년도에 대해서도 예측력의 변화를 살펴보는 것이 필요하다.

3) 부실과 건전기업을 판별을 할 수 있는 지표로서 재무비율만을 사용하였다. 부실과 건전기업을 판별할 수 있는 지표로는 이외에도 업종유망성, 판매전망, 기술개발, 경영자능력, 기업년수, 기업형태와 같은 질적인 정보 등을 사용하여 예측력의 변화를 살펴보는 것이 필요하다.

4) 신경망기법의 여러가지 매개변수의 값을 기본값을 사용하여 실험을 하였으나 여러가지 값을 사용하여 다양한 실험을 해보는 것이 필요하다.

5) 세집단분류에서는 6가지 유형의 오류가 발생할 수 있다. 본 연구에서는 각 유형의 오류에 대한 비용값은 동일한 것으로 간주하였으나 각 유형의 오류에 대한 비용값은 서로 다를 수 있다. 따라서 이들 비용에 관한 정보도 고려하여 예측하는 것이 바람직하다.

6) 본 연구의 결과를 일반화하기 위해서는 부실예측문제가 아닌 다른 유형의 분류문제에 대한 실험 그리고 더 많은 표본을 가지고 여러가지 다양한 표본구성비율을 설정하여 표본구성비율에 따라 어떤 예측력을 보이는지를 살펴보는 실험이 필요하다. 또한 분석용 표본의 구성비율뿐만 아니라 검정용표본의 구성비율도 다르게 하여 분석용의 구성비율이 검정용표본의 예측에 어떠한 영향을 미치는지를 살펴보는 것이 필요하다.

특히 금융기관들은 금리자유화 등 단계적인 금융시장 개방과정에서 부실거래 및 부실대출을 최소화하면서 국제경쟁력을 갖추기 위해서는 기업신용도별 신용거래한도의 차등화와 금리차등화는 필수불가결하게 되어가고 있다. 이를 효과적으로 실시하기 위해서는 본 연구에서는 비건전기업을 잠식과 도산의 두가지 부실화된 형태로 국한하였으나 이를 기업의 건전정도에 따라 부실화 유형을 더욱 정교하게 세분화할 수 있는 모형의 개발과, 세분화된 기업집단을 예측할 수 있는 방법에 관한 이론적 또는 실증적연구가 필요하다.

참 고 문 헌

- [1] 강철승, "부가가치회계정보의 기업부실예측력에 관한 실증적 연구," 회계학연구, 1991년 7월, pp. 79-98.
- [2] 김기영, 전명식, SAS 판별 및 분류분석, 자유아카데미, 1994.
- [3] 이건창, "기업도산예측을 위한 통계적모형과 인공지능간의 예측력 비교에 관한연구: MDA, 귀납적 학습방법, 인공신경망," 한국경영과학회지, 1993년 8월, pp. 57-81.
- [4] 이재식, 한재홍, "인공신경망을 이용한 중소기업도산예측에 있어서의 비재무정보의 유용성 검증," 한국전문가시스템학회지, 1995년 1월, pp. 123-134
- [5] 조홍규, 한인규, 이훈영, "판별분석, 사례기반예측, 신경회로망을 이용한 도산예측의 비교분석," 한국전문가시스템학회 '94년 추계 학술대회 논문집, 1994년 11월, pp. 385-399.
- [6] Dutta, S., S. Shekhar, and W.Y. Wong, "Decision Support in Non-Conservative Domains: Generalization with Neural Networks," *Decision Support Systems*, Vol. 11, No. 5, 1994, pp. 527-544.
- [7] Hair, Jr. J.F., R.E. Anderson, R.L. Tatham, and W.C. Black, *Multivariate Data Analysis with Readings*, Fourth Edition, Prentice Hall, Inc., 1995.
- [8] Klimasauskas C., "Applying Neural Networks," in R.R. Trippi and E. Turban (Eds.), *Neural Networks in Finance and Investing*, Probus Publishing Company, 1993, pp. 47-72.
- [9] Lippmann, R., "An Introduction to Computing with Neural Nets," *IEEE ASSP Magazine*, 1988, pp. 4-22.
- [10] Neuralware Inc., *Neuralworks Professional II: Neural Computing*, Neuralware Inc., Pittsburgh, PA, 1993.
- [11] Neuralware Inc., *Neuralworks Professional II: Using NeuralWorks*, Neuralware Inc., Pittsburgh, PA, 1993.
- [12] Odom, M.D. and R. Sharda, "A Neural Network Model for Bankruptcy Prediction," *Proceedings of the IEEE International Conference on Neural Networks*, pp. II163-II168
- [13] Perreaeault, W.D., D.N. Behrman, and G.M. Armstrong, "Alternative Approaches for Interpretation of Multiple Discriminant Analysis in Marketing Research," *Journal of Business Research*, Vol. 7, 1979, pp. 151-173.
- [14] Piramuthu, S., M.J. Shaw, and J.A. Gentry, "A Classification Approach Using Multi-Layered Neural Networks," *Decision Support Systems*, Vol. 11, No. 5, 1994, pp. 509-525.

- [15] Raghupathi, W., L.L. Schkade, and B.S. Raju, "A Neural Network Approach to Bankruptcy Prediction," *Proceedings of the IEEE 24th Annual Hawaii International Conference on Systems Sciences*, 1991.
- [16] Rahimain, E., S. Singh, T. Thammachote, and R. Virmani, "Bankruptcy Prediction by Neural Network," in R.R. Trippi and E. Turban (Eds.), *Neural Networks in Finance and Investing*, Probus Publishing Company, 1993, pp. 159-176.
- [17] Tam, K.Y. and M.Y. Kiang, "Managerial Applications of Neural Networks: The Case of Bank Failure Prediction," *Management Science*, Vol. 38, No. 7, July 1992, pp. 926-947.
- [18] Wilson, R.L. and R. Sharda, "Bankruptcy Prediction Using Neural Networks," *Decision Support Systems*, Vol. 11, No. 5, 1994, pp. 545-557.