

기업도산예측을 위한 귀납적 학습지원 인공신경망 접근방법: MDA, 귀납적 학습방법, 인공신경망 모형과의 성과비교

An Inductive Learning-Assisted Neural Network Approach to Bankruptcy Prediction: Comparison with MDA, Inductive Learning, and Neural Network Models

이 건 창*

김 명 종**

김 혁***

最初 論文 接受日 : 93. 7.

修 正 本 接受日 : 93. 12.

論文 掲載 確定日 : 94. 1.

초 록

본 연구는 기업도산예측에 관한 문제를 다루고 있다. 기존의 연구에서는 MDA, 로지트 분석, 프로비트 분석등과 같은 통계적 기법을 주로 사용하여 기업도산예측 문제를 해결하고자 하였지만, 통계적 기법이 갖고 있는 엄격한 가정이 만족되어야 한다는 방법론적인 한계를 갖고 있었다. 따라서 최근 인공지능 기법이 제반 경영학 문제에 보다 활발하게 적용되기 시작하면서 귀납적 학습방법(inductive learning), 인공신경망(neural network)등과 같은 인공지능 관련 기법을 기업도산예측 문제에 적용하는 연구가 활발히 소개되었고 그 성과 또한 기존의 통계적 기법보다는 우수함이 입증되었다. 그러나 이러한 연구의 경우 대개 기존의 통계적 기법과 예측성적을 단순비교하는 연구방법론이 주류이기 때문에 보다 새로운 방법론의 필요성이 대두되기에 이르렀다. 이러한 관점에서 본 연구에서는 단순히 기존의 통계적 기법과 비교하는 차원에서 벗어나, 귀납적 학습방법과 인공신경망 모형을 결합한 '귀납적 학습지원 인공신경망'(ILANN: Inductive Learning-Assisted Neural Network) 기법을 소개한다. 이는 제1종 오류(Type I Error)와 제2종 오류 (Type II Error)를 분석하여 귀납적 학습방법과 인공신경망 모형의 성과를 결합하는 방법을 채택하고 있다. 본 연구에서는 1979년에서 1992년까지의 166개 국내의 도산

* 경기대학교 경영정보학과 교수

**성균관대학교 회계학과 교수

***한국과학기술원 서울분원 경영정보공학과 박사과정

및 비도산 기업의 재무비율 자료를 기초로 하여 분석하였다. 사용된 재무비율은 전체 57개로서 이는 각각 성장성 관련비율 11개, 수익성 관련비율 12개, 안전성 관련비율 18개, 현금흐름 관련비율 4개, 활동성 관련비율 6개, 기업신용 관련비율 6개로 구성되어 있다. 실험결과 본 연구에서 제안한 귀납적 학습지원 인공신경망 모형이 MDA나 귀납적 학습 방법, 인공신경망 모형과 비교하여 가장 예측력이 우수한 것으로 실증되었다.

I. 서 론

인공신경망(neural networks)은 많은 영역에서 응용되었는바, 특히 ①모형화 및 예측분야, ②시그널 처리, ③전문가시스템 등의 분야에서 가장 두드러진 성과를 보여왔다(Lippmann 1987). 특히 인공신경망의 뛰어난 예측력은 일반화 (generalization)라는 인공신경망 특유의 특성에 기인한다 (Gorman & Sejnowski 1988). 일반화라함은 인간두뇌의 추론 능력 또는 응용능력과 비슷한 것으로서 이미 특정 학습자료에 의하여 학습된 인공신경망이 전혀 학습하지 않았던 새로운 자료에 대하여 예측력을 갖는 것을 의미하는 것으로서, 이는 약간 변형된 학습자료를 인식하는 '자동연관기억'(auto-associative memory)과는 다른 개념이라고 할 수 있다.

본 연구의 목적은 보다 효과적인 기업도산예측을 위하여, 귀납적 학습방법(inductive learning)을 사전처리기(pre-processor)로 한 새로운 개념의 인공신경망 기법을 개발하여 이를 기업도산예측에 적용하는데에 있다. 아울러 학습자료의 증대에 따른 모형의 예측정확도의 증대를 비교하는 것도 또다른 연구목적에 해당된다. 기업도산예측(bankruptcy prediction) 분야는 원래 회계학 분야에서 활발히 논의되어온 분야이다. 초기에 Beaver(1966)와 Altman(1968)에 의하여 주도된 기업도산예측 연구는 주로 재무비율(financial ratios) 자료로 MDA 판별식을 구하는 방식으로 전개되었다. 따라서 이들의 연구이후 어떠한 재무비율의 결합이 가장 예측력이 있을 것인가에 대한 연구가 많이 소개되었다 (Deakin 1972, Blum 1974, Moyer 1977, Altman et al. 1977, Karels & Prakash 1987). 그러나 MDA는 독립변수간에 정규분포를 가정하고, 이러한 통계적 가정이 만족되었을 때에만 그 결과를 신뢰할 수

있다. 따라서 이러한 통계적 가정이 만족되지 않는다면 그결과 또한 상당한 오류를 포함하고 있다고 간주하여야 할 것이다 (Karels & Prakash 1987). 이와 같은 MDA의 문제점을 해결하기 위하여 제안된 방법으로서는 반복적 분할법(Recursive Partitioning Algorithm), 로지트분석(Logit Analysis), 프로비트분석(Probit Analysis)등과 같은 통계적 모형들이 있으나, 이 역시 해당 방법론 자체가 갖고 있는 통계적 가정에 의해 그 사용범위가 제한을 받고 있다.

인공신경망은 MDA와는 달리 정규분포성이라는 통계적 가정에 구애를 받지 않는다. 이는 인공신경망 기법이 휴리스틱을 강조하는 인공지능 기법중의 하나이며, 특히 기계학습 이론(machine learning theory)중의 하나이기 때문에 특정 통계적 가정을 전제하지 않기 때문이다.

본 연구에서는 기업도산예측에 대한 기존의 통계학적인 방법론이 갖는 한계를 극복하고 보다 실용적이고 효과적인 도산예측을 위하여, 귀납적 학습(inductive learning)방법과 인공신경망(neural network) 모형을 통합한 '귀납적 학습지원 인공신경망' 모형을 제안한다. 그리고 이를 기업도산예측에 적용한 결과를 기존의 대표적 통계방법인 MDA와 비교하고, 또한 인공지능의 여타 방법인 귀납적 학습방법과 인공신경망 방법과 비교하고자 한다. 결국 본 연구의 목적은 다음과 같다.

- 1) Lee (1992)의 연구에서 언급된 코오퍼레이티브 추론엔진(Cooperative Inference Engine) 개념을 기초로 귀납적 학습방법과 인공신경망과의 결합을 통한 새로운 개념의 도산예측 방법을 제시하고 이를 '귀납적 학습지원 인공신경망'(Inductive Learning-Assisted Neural Network: 이후 ILANN이라 약함)이라고 명칭한다.
- 2) ILANN을 이용한 도산예측율과 기존의 통계적 연구방법인 MDA 기법에 의한 도산예측율을 비교분석 한다.
- 3) 또한 ILANN의 성과를 인공지능 방법과 비교하기 위하여 귀납적 학습방법과 인공신경망 방법에 의한 결과와도 비교하고자 한다.
- 4) 학습자료의 증대에 따른 각 모형의 예측정확성을 비교하고자 한다. 이를 위해 표본자료군을 기간의 경과에 따라 세그룹으로 나누고 각 그룹별로 모형을 적용함으로써 도산예측 정확도의 변화를 검증하고자 한다.

1)의 목적을 부연설명하면 다음과 같다. 즉, Lee (1992)의 연구에서 제시된 코오퍼레이티브 추론엔진은 전략계획(strategic planning) 분야에서 학습된 인공신경망으로부터 IF-THEN규칙을 추출하여 이를 해당 인공신경망의 설명기능을 강화시키는 방향으로 귀납적 학습방법과 인공신경망 모형을 결합하였지만, 본 연구에서는 기업도산예측을 위하여 이들 두 모형을 서로 보완적으로 적용함으로써 기업도산예측율을 향상시키고자 한다. 아울러 이진창(1993)의 연구는 우리나라 자료를 이용하여 기업도산예측에 있어서 통계모형(MDA)과 인공지능 기법(귀납적 학습방법, 인공신경망)간의 성과를 비교한 것으로서 본 연구의 기본적인 연구의도와 일치하나, 본 연구는 이들 모형뿐만 아니라 귀납적 학습방법과 인공신경망을 결합한 ILANN모형을 추가함으로써 연구범위를 보다 확장하였다.

II장에서는 도산예측에서 사용되었던 통계적 모형과 귀납적 학습방법, 그리고 인공신경망 기법에 대한 기존의 연구문헌을 검토한다. III장에서는 본 논문에서 제안하는 연구방법을 언급하고, IV장에서는 그 실험결과를 설명하며, 마지막 V장에서는 본 연구의 한계점과 미래의 연구방향을 제시하였다.

II. 기 준 연 구

2.1 통계적 모형

Collin & Green (1982)은 기업도산예측에서 자주 사용되는 세가지 통계적 모형인 MDA, 선형확률모형(linear probability models), 그리고 로지트 분석(logit analysis 또는 logistic regression)의 성과를 서로 비교하였다. Frydman등은(1985) 또다른 기법인 반복적 분할법, 즉 RPA(recursive partitioning algorithm)를 이용하여 기업도산예측을 실시하였다.

MDA는 주어진 관측치를 두개 이상의 그룹으로 분류하는데 사용되는 통계적 기법이다. 도산예측을 위해서는 미리 '도산' 및 '비도산'이라는 두개의 그룹을 설정하고, 여러 독립변수의 선형결합(linear combination)으로 표현되는 판별함수를 유도함으로써 MDA분석이 이뤄진다. 이때 판별함수는 판별오류(misclassification)확률을 최소화하는 방식으로 유도되

며, 이는 일반적으로 최소자승법의 한 형태로 표현된다. 그러나, MDA분석이 유효하려면 몇 가지 가정이 전제되어야 하는데, 이중 가장 대표적인 가정은 독립변수가 정규분포를 따라야 한다는 소위 '정규성'(normality)의 가정이다. 또한 각 그룹의 공분산 행렬(covariance matrix)이 동일하여야 한다. MDA를 이용한 도산예측 분석은 Altman(1968)에 의하여 처음 제시되었고, 그 후 여러나라의 학자들이 이 연구를 기초로 다양한 분석을 시도하였다. 이 연구는 개별적으로 연구되던 재무지율 관련 변수를 통계적으로 종합화하여 선형모형으로 유도하였다는데 의의가 있지만, 장기적 예측보다는 단기적 예측에 더 유용하다는 한계를 지니고 있었다. 우리나라에서도 MDA를 이용한 실증적 도산예측 연구가 박창길(1984), 정준수(1985), 김선기 외(1986), 황석하(1991), 강철승(1991) 등에 의해 이루어졌다.

로지트분석은 MDA의 정규분포의 가정에 대한 문제점을 해결하기 위한 통계적 모형으로 사용되어 왔다. Ohlson(1980)은 MDA가 기본적 통계가정 및 연구방법론상 많은 문제점을 가지고 있다고 지적하고 독립변수에 대한 정규분포의 가정을 필요로 하지 않으면서 계수의 유의성 검증이 가능한 '조건부 로지트 모형'을(conditional logit model) 제기하였다. 한편 로지트분석과 유사한 프로비트분석(probit analysis)도 MDA대신에 도산예측을 위하여 적용될 수 있다. 프로비트분석은 선형모형을 가정하며 각 계수도 最優推定法(maximum likelihood estimation method)에 의하여 추정된다. 국내에서도 한인구(1990) 등의 연구에서 프로비트분석이 사용되고 있다. Collins & Green(1982)에 의하면 로지트분석은 MDA와 비교하여 볼 때 제 1종의 오류, 즉 도산기업을 비도산기업으로 분류할 오류를 적게한다는 것을 실증분석 하였다. 그러나 도산예측률의 측면에서 보면 MDA와 큰차이는 없는 것으로 분석하였다. Liang등의 연구(1991)에 의하면 변수로서 명목척도가 사용되었을 때에는 인공지능 기법중의 하나인 귀납적 학습방법이 프로비트분석에 비하여 예측력이 우수하나 계량적 자료가 사용되었을 때는 프로비트 분석이 귀납적 학습방법보다 예측력이 우수하다고 보고하고 있다.

RPA는 패턴인식 기법에 기초한 비모수적 분류기법이다. RPA는 베이저안 개념에 따라 모집단에 대한 사전지식을 이용하여 의사결정에 따른 비용을 최소화하는 이진분류 트리형태를 유도하고자 한다. 이렇게 함으로써 각 분류대상을 사전에 정의된 그룹에 할당하고 그에 따라 착오분류(misclassification)의 기대비용을 최소화 하려는 알고리즘이다. 이러한 RPA를 이용한 기업도산 예측의 연구로써의 국외의 경우 Frydman 등(1985)의 연구가 가장 대표적

이고, 국내의 경우 이상빈과 오승현의 연구가(Lee & Oh 1990) 있다.

2.2 귀납적 학습방법 모형

귀납적 학습방법이란 기존의 사례로부터 일정한 의사결정기준(decision rule), 즉 지식(knowledge)을 도출하는 방법이다. 이 방법은 특정분야에 대한 기존의 사례에서 지식을 학습하여 의사결정트리 형태로 구성된 지식을 유도하고 이를 이용한 지식베이스를 활용하여 해당 의사결정 분야의 의사결정에 이용하는 방법이다. 현재까지 개발된 귀납적 학습방법으로는 ID3(Quinlan 1979, 1986)를 비롯하여 ID3의 일반형인 ACLS(Quinlan 1986), CRIS(Liang 1992), ID4(Schlimmer & Fisher 1986), ID5(Utgoff 1988)등의 다양한 방법이 있다. 이러한 귀납적 학습방법중 가장 널리 알려져 있는 알고리즘은 Quinlan(1976, 1986)의 ID3인데, 이는 명목척도에 의한 학습자료를 학습한 후 일정한 의사결정트리를 유도함으로써 이에 의하여 새로운 실험자료를 분류하는 기법이다. 이러한 ID3를 일반적인 실수형 자료로 확장시킨 것이 ACLS(Analog Concept learning System)이다.

ACLS(Quinlan 1986)의 메카니즘을 설명하기 위하여 $n(t)$ 를 노드 t 에 할당된 사례의 수라 하고, $n_i(t)$ 를 노드 t 에서 계층 i 에 속하는 사례의 수를 나타낸다고 하자. 이때 해당 노드 t 에서의 엔트로피는 곧 노드 t 에서의 기대정보내용(expected information content)으로서 이는 다음과 같이 표현할 수 있다(Shannon 1964).

$$ICT(t) = - \sum_{i=1}^k \left(\frac{n_i(t)}{n(t)} \right) \cdot \log_2 \left(\frac{n_i(t)}{n(t)} \right)$$

한편, 노드 t 에서 하나의 사례가 계층 i 에 속할 조건부 확률은 $P(i|t) = n_i(t)/n(t)$ 가 되고 하나의 사례가 특정 분할기준(splitting rule: sr)에 의하여 노드 t 의 하위 노드인 t_j 로 할당된 조건부 확률은 $P(t_j|t, sr) = n(t_j)/n(t)$ 가 된다. 따라서 분류기준 sr에 대한 노드 t 에서의 기대정보내용을 $ICT(t|sr)$ 이라고 정의하면 이는

$$ICT(t|sr) = \sum_{\forall t_j} ICT(t_j) \cdot P(t_j|t, sr)$$

라고 표현할 수 있다. 따라서 이와 같이 노드 t 에서 특정 분할기준(sr)에 의하여 하위노드로 branch할 때 증가되는 정보량, 즉 ΔInf 는

$$\Delta \text{Inf}(t|sr) = \text{ICT}(t) - \text{ICT}(t|sr)$$

로 정의되며 결과적으로 ACLS는 노드 t 에서 $\Delta \text{Inf}(t|sr)$ 를 최대로 하는 분할기준을 선정하여 하위노드를 구성하며 이러한 과정은 최종노드 (Terminal Node: TN)에 이르러 모든 사례를 구분할 때까지 반복적으로 수행된다.

이러한 귀납적 학습방법을 이용한 부실기업 예측에 관한 연구로써는 Braun & Chandler (1987), Meisser & Hansen (1988), Biggs등 (1989), Harris & Frishkoff (1989), Shaw & Gentry (1990), Liang (1992)등의 연구가 있다. Braun & Chandler (1987)는 귀납적 학습방법중의 하나인 Quinlan(1979, 1986)의 ID3를 이용하여 주식시장에서 주가의 행태를 예측하였고, Meisser & Hansen (1988)도 도산예측시 MDA보다 귀납적 학습방법 (ACLS)의 예측력이 더욱 높게 나타났다고 보고하고 있다. 한편, Biggs등의 연구 (1989)에서는 계속기업에 관한 감사인의 의견지침서인 SAS No.34 및 SAS No.59를 귀납적 학습방법을 통하여 GCX(Going Concern eXpert)라는 전문가시스템 프로그램을 만들었고, Harris & krishkoff(1989)는 MDA와 로지트 분석 및 귀납적 학습방법의 예측력차이를 실증분석하였는데, 그 결과는 로지트 분석, 귀납적 학습방법, MDA의 순서로 예측력이 우수하다고 보고하고 있다. Shaw & Gentry (1990)에서는 투자위험을 평가하는데 귀납적 학습방법을 이용하였다. Liang(1992)은 복합규칙 추론시스템(Composite Rule Induction System: CRIS)을 이용하여 도산예측을 실증적으로 분석하였다.

국내에서 이뤄진 연구를 보면 한인구 (1990)의 연구와 Lee & Oh (1990)의 연구가 있는데, 한인구 (1990)의 경우 ID3와 프로비트분석을 기업도산예측에 사용한 결과 명목변수를 사용할 때에 ID3의 예측력이 더 우수함을 실증분석하였다. Lee & Oh (1990)의 연구에서는 RPA와 ACLS를 각각 도산예측에 적용하여 각 방법의 차이를 비교분석 하였다.

2.3 인공지능망 모형

인공지능망 모형은 매우 뛰어난 학습능력과 인지능력을 있어서 기업도산예측과 같이 ‘분류문제’ (classification problem)에 있어서 여타 통계적 방법이나 귀납적 학습방법보다는 우수한 인식능력이 있음이 알려져 있다 (Freeman & Skapura 1991). 인공지능망에서 가장 일

반적으로 많이 쓰이는 형태는 '감독학습' (supervised learning)에 알맞는 다층 전향구조 (multilayered feedforward) 인공신경망이다. 이는 입력, 출력, 은닉의 삼층구조를 가지면 각 층마다 다수의 뉴런 (neuron) 또는 노드(node), 즉 처리단위(processing unit)를 소유하고 있다. 입력층의 처리단위는 외부로부터 입력을 받아들이는 처리 단위이며 출력층의 처리단위는 외부에 출력값을 내보내는 처리단위이고, 은닉층의 처리단위는 외부환경과 상호작용을 하지 않는 처리단위로서 따라서 외부로부터 은닉되어 있다. 서로 다른층에 존재하는 처리단위는 '연결가중치' (interconnection weight)로 서로 연결되어 있어(fully connected) 결국 인공신경망은 지식을 다수의 연결가중치로 분산표현하고 있다. 각 처리단위는 연결되어 있는 타 처리단위로부터 입력을 받아 입력함수를 통해 가중합을 하여 순입력값을 구한다. 이때 해당 처리단위의 출력값은 전이함수(transfer function)를 이용하여 순입력값을 구한다. 이때 해당 처리단위의 출력값은 전이함수(transfer function)를 이용하여 순입력값을 변환함으로써 구할 수 있다. (Rumelhart, Hinton & Williams 1986).

역전과 학습방법 (backpropagation learning algorithm)은 전향적 인공신경망의 대표적인 학습 알고리즘이다(Rumelhart, Hinton & Williams 1986). 각각의 처리단위는 주어진 학습자료를 학습하는 학습기능 (learning function)과 상호연결된 또다른 처리단위에 그 처리결과 (activation)를 보내는 전달기능 (transfer function)이 있다. 즉, 입력층을 제외한 각 신경층내의 처리단위는 하부신경층의 처리단위의 출력(outputs)을 입력요인(inputs)으로 받아들이고 이를 기초로 특정 함수, 즉 전이함수로 처리하여 새로운 출력을 연결되어 있는 상부신경층의 처리단위에 전달한다. 역전과 학습방법은 두단계로 나누어져 있다. 즉, 전향전파 (forward propagation) 단계와 후향전파 (backward propagation) 단계로 나눌 수 있다. 전향전파 단계에서는 입력자료가 입력층에 제공되고 그에 따라 출력값이 연결가중치에 의하여 계산된다. 실제값과 출력값과의 차이를 제공한 값을 시스템 오류라 하며 시스템 오류를 줄이기 위하여 후향적 단계에서는 연결가중치를 조정하여 실제값에 수렴하게 한다. 이에 대한 보다 자세한 설명은 Freeman & Skapura (1991)을 참조하기 바란다. 이와 같은 로직으로 작동되는 역전과 학습방법을 이용하여 얻어진 인공신경망의 추론결과는 대개 0에서 1까지의 실수로 나타나는데, 이는 인공신경망의 퍼지화(fuzzification) 기능을 보여주는 현상이라고 할 수 있다. 이러한 인공신경망 모형을 이용한 기업도산예측 연구로써는 국외의 경우 Odom & Sharda (1990), Berry & Treigueiros (1991), Coakley & Brown (1991),

Liang 등 (1991), Raghupathi 등(1991), Chung & Tam (1992), Tam & Kiang (1992)의 연구가 있고, 국내의 연구는 이진창 (1993)의 연구가 있다.

Odom & Sharda (1990)는 MDA와 인공지능망 모형을 기업도산예측에 적용하여 그 성과를 비교하였는바, MDA의 경우 도산예측률이 59.26%, 인공지능망의 경우 3-layer를 이용하여 81.48%의 성과를 보고하였다. Berry & Treigueiros의 연구 (1991)와 Raghupathi등의 연구(1991)도 인공지능망을 이용한 도산예측의 결과가 MDA를 이용할 때보다 더 우수하다고 보고하였다. Coakley & Brown(1991)의 연구에서는 인공지능망을 이용한 도산예측 실험 시 인공지능망의 시스템오류¹⁾가 작을수록 제 2 종의 오류(type II error)가 커진다는 흥미있는 사실이 보고되고 있다. Chung & Tam (1992)은 ID3와 AQ(이는 predicate calculus의 확장된 버전이다)와 같은 귀납적 학습방법 모형보다 (ID3의 경우 79.5%, AQ의 경우 77.5%) 인공지능망을 이용했을때 더 높은 도산예측률을 (85.3%) 얻을 수 있다고 보고하고 있다. 한편, Tam & Kiang (1992)은 MDA, 로지트분석, ID3 및 인공지능망의 성과를 비교한 결과, MDA 84.1%, 로지트 분석 81.8%, ID3 79.5%, 인공지능망의 경우 81.8% (2-layer의 경우), 85.2% (3-layer의 경우)의 도산예측 결과를 얻으므로써 여전히 인공지능망이 다른 방법과 비교하여 상대적으로 더 우수한 도산예측 도구임을 실증분석 하였다.

국내의 경우 이진창 (1993)은 국내의 166개의 업체를 대상으로 도산정보를 구하여 기존의 MDA, ID3, 인공지능망을 적용함으로써 국외의 연구와 같이 인공지능망이 가장 우수한 기업도산예측 모형임을 실증분석 하였다.

III. 연구방법론

본 장에서는 1절을 통해 실험을 위한 자료의 수집방법과 변수선정과정 및 MDA의 가정인 독립변수들의 정규분포를 실현하기 위하여 독립변수를 로그로 치환한 로그-정규분포(log

1) 이는 인공지능망을 학습시킬때 발생하는 오류로서 인공지능망에서 계산된 출력값과 학습자료 (training samples)의 실제값 사이의 차이를 종합하여 표현된 오류값이다. 따라서 이러한 시스템오류가 작으면 그만큼 인공지능망이 주어진 학습자료를 충실히 학습하였다는 것을 의미한다. 반면에 시스템오류가 크면 인공지능망이 주어진 학습자료를 제대로 학습하지 못하였다는 것을 의미한다.

normality)에 대하여 설명하고자 한다. 다음 제 2절에서는 각 모형의 지식베이스의 구축설계 방법을 자세하게 설명하고자 한다.

3.1 자료수집 및 변수선정

본 절에서는 표본기업의 선정을 위한 도산의 개념적 정의와 자료수집과정, 변수선정과정 및 변수의 정규분포화를 위하여 각 변수를 로그로 치환한 과정에 대해 상세히 설명하고자 한다.

3.1.1 표본기업의 선정 및 자료수집

본 연구에서는 1979년에서 1992년까지 한국증권거래소에 상장된 기업을 모집단으로 하여 도산의 개념적 정의에 해당되는 기업을 다음과 같이 표본대상으로 추출하였다.

- 1) 회사정리절차를 신청하였거나 정리절차를 개시 또는 정리절차가 진행중인 업체나 정리절차를 마감한 기업
- 2) 영업활동을 정지하였거나 또는 폐업한 업체
- 3) 자본잠식이 3년이상 계속된 기업으로 현재 법정관리대상으로 분류되어 있는 업체
- 4) 한국증권거래소에 상장폐지를 선고하였거나 한국증권거래소에 의하여 상장이 폐지된 기업

위의 개념적 정의에 해당되는 도산기업은 81개가 표본으로 추출되었고, 도산기업과 대응되는 비도산기업은 매출액과 업종을 기준으로 하여 거의 같은 수에 해당하는 85개의 표본기업이 추출되었다. 결국 본 연구에서는 총 166개의 기업을 표본대상으로 하였다. 그러나 본 연구에서와 같이 도산기업과 비도산기업과의 비율을 50대 50으로 하여 표본을 추출한다고 해서 모형의 예측정확성을 증대시킨다고 보기는 어렵다. 왜냐하면 도산예측에 관한 연구목적은 과거의 도산사례를 이용하여 앞으로 일어날지도 모르는 도산가능성을 효과적으로 예측하는 데에 있기 때문에, 현실적으로 비도산기업의 비율이 도산기업의 비율보다 훨씬 크다고 해서 그 비율대로 표본을 추출하는 것은 연구목적과 괴리되기 때문이다. 아울러 대부분의 기존 연구에서도 대부분 도산기업과 비도산기업의 비율을 거의 50대 50으로 하여 연구를 수행하

고 있기 때문에 이 같은 비율의 표본추출은 방법론상으로 입증된 것이라고 할 수 있다.

한편 추출된 도산기업과 비도산기업 표본은 각각 년도에 따라 세개의 그룹으로 분류하였다. 그 이유는 분석용 표본과 같은 기간의 검증용 표본에 대하여 그 정확성을 검토하는 기존의 분석방법과는 달리, 본 연구에서는 분석용 표본으로부터 지식베이스를 구축하고 이를 이용하여 분석용 표본기간 이후에 발생한 미래 자료인 검증용 표본을 대상으로 해당 모델의 예측성을 검증하기 때문이다. 각 년도에 따라 그룹별로 구분된 표본기업은 <표 1>에 제시되어 있다.

<표 1> 년도별로 구분한 표본기업

그룹 표본	그룹1(79-84년)			그룹2(79-90년)			그룹3(79-91년)		
	도산	비도산	총계	도산	비도산	총계	도산	비도산	총계
분석용 표본	33개	33개	66개	48개	48개	96개	61개	65개	126개
검증용 표본	100개 기업 (85-92년)			70개 기업 (91-92년)			40개 기업 (92년)		
총 표본	166개 기업			166개 기업			166개 기업		

위 표본기업에 관련된 재무비율 자료는 다음과 같은 방법을 통하여 수집하였다.

- 1) 비교적 회계 및 재무정보가 자세히 수록된 한국기업재무총람에서 1차적으로 자료를 수집하였다.
- 2) 한국기업재무총람에서 얻을 수 없는 자료는 회계연감과 기업재무총람에서 수집하였다.
- 3) 상기 자료에서 얻을 수 없는 정보는 증권거래소에 비치된 슬라이드 자료를 통하여 수집하였다.

<표 1>의 검증용 표본에 대하여 추가로 설명하면, 85년도에서 90년도 까지의 전체 검증용 표본수는 30개, 91년도 검증용 표본수는 30개, 마지막 92년도 검증용 표본수는 40개이다. 따라서 그룹 1의 경우 검증년도가 85년에서 92년도이므로 검증용 표본수가 100개가 되며, 같은 방법으로 그룹 2의 경우는 91년, 92년이 검증년도이므로 검증용 표본수는 70개, 그룹 3의 경우는 92년만 검증년도에 해당되므로 검증용 표본수는 40개가 된다. 아울러 분석용 표본내의 도산과 비도산기업의 비율이 50대 50으로 구성되어 있으므로 나머지 검증용 표본내의 도산기업과 비도산기업의 비율도 50대 50으로 구성되어 있다는 것을 쉽게 알 수 있다.

3.1.2 변수의 선정

본 연구에 이용되는 변수는 기업도산을 잘 나타내주는 지표로서 자료의 입수가 용이하고 객관적이며 통계처리가 가능한 재무비율을 선정하였다. 재무비율은 재무제표상의 여러항목 중에서 두항목 이상을 비교하여 계산되어지기 때문에 수없이 많이 구할 수 있지만 본 연구에서는 다음과 같은 선정기준에 의해 재무비율을 선택하였다.

- 1) 기존 국내외 연구문헌들을 검토한 결과 도산기업과 비도산기업의 차이를 잘 나타내주는 비율로서 종래 기업도산 연구에서 중요시되는 비율
- 2) 해석이 용이하고 일반적으로 이용되는 비율
- 3) 이론적으로 기업도산의 예측지표로서 유효한 비율
- 4) 실무에서 기업도산의 예측지표로서 자주 사용되는 비율

이러한 4가지 기준에 준하여 57개의 재무비율을 선정하였다. 위의 기준에 의하여 선정된 57개의 재무비율은 <표 2>에 제시되어 있다²⁾. 57개의 재무비율은 특성에 따라 <표 2>와 같이 11개의 성장성 비율, 12개의 수익성 비율, 18개의 안전성 비율, 4개의 현금흐름 및 6개의 기업 신용율, 6개의 활동성 비율(6개)로 분류된다.

3.1.3 로그정규분포(Log Normality)

MDA에서는 중요한 가정 중의 하나로 모든 독립변수는 정규분포를 따른다는 것을 강조하고

2) 이중 하나의 재무비율이 공식의 형태에 따라 여러개로 표현되는 고정자산증가율, 총부채증가율, 차입금의존도에 대해서는 다음과 같이 그 공식을 소개한다.

고정자산증가율1=금년도 고정자산/전년도 고정자산

고정자산증가율2=(금년도 고정자산/전년도 고정자산)*(전년도 부채/금년도 부채)

고정자산증가율3=(금년도 고정자산/전년도 고정자산)*(금년도 부채/전년도 부채)

총부채증가율1=금년도 부채/전년도 부채

총부채증가율2=(금년도 부채/전년도 부채)*(전년도 매출/금년도 매출)

총부채증가율3=(금년도 부채/전년도 부채)*(전년도 경상이익/금년도 경상이익)

총부채증가율4=(금년도 부채/전년도 부채)*(전년도 이자비용/금년도 이자비용)

차입금의존도1=차입금/총자산

차입금의존도2=차입금/매출

차입금의존도3=차입금/총부채

있다. 독립변수를 정규분포로 전환하는 방법을 기존 문헌을 통하여 살펴보면 1)trimming, 2)truncation, 3)log-normalization을 들 수 있다. 그러나 재무비율을 정규분포로 만들어 처리하는 방법에는 정립된 기준이 없으며 또한 기존 문헌에서도 이에 대한 일관된 기준을 찾아볼 수 없다. 재무비율의 확률분포를 연구한 기존 문헌을 고찰하여 보면, Horrigan(1965)의 연구에서는 이러한 비율변수들은 정(+)의 방향으로 변수들이 편향(positive skewed)되어 나타남을 보고하고 있는데 이는 재무비율의 분모와 분자가 대부분 0보다 큰 양수이기 때문이라고 분석하였다. Buijink & Jegers (1984)의 연구에서는 이러한 편향추세가 단기적인 극단치가 아닌 장기간 동안 수집한 재무변수에서도 일반적으로 관찰된다고 지적하였다. 따라서 이러한 극단치를 정규분포로부터 제거하기 위하여 해당되는 부분을 정규분포에서 절단하거나 조정하는 것을 trimming 또는 truncation방법이라고 한다. 그러나 부적절하게 절단하는 경우 심각한 오류를 야기할 수도 있다는 단점이 있다. Berry & Treigueiros (1991)의 연구에서는 기존 문헌검토를 통하여 trimming과 truncation에 대한 문제점을 제시하고 재무비율을 정규분포로 수정하기 위하여 로그를 이용할 것을 제안했다. Berry & Treigueiros(1991)의 연구에서 재무비율 y/x 를 로그로 변환한 방법을 살펴보면 다음과 같다.

$$y \rightarrow \begin{cases} \log(y) & y > 0 \\ 0 & y = 0 \\ -\log(-y) & y < 0 \end{cases} \quad y \rightarrow \begin{cases} \log(x) & x > 0 \\ 0 & x = 0 \\ -\log(-x) & x < 0 \end{cases}$$

본 연구에서도 위와 같은 방법을 이용한 방법을 통하여 재무비율을 로그값으로 변환하였다. 또한 변환결과를 SPSS의 기술통계를 이용하여 검증한 결과 그룹 1에서는 유동비율과 당좌비율을 제외한 비율들이, 그룹2와 3에서는 유동비율, 당좌비율, 총자본회전율을 제외한 모든 비율들이 5%의 유의수준에서 정규분포를 따른다는 결과를 얻을 수 있었다. 본 논문의 실험중 로그로 변환하지 않은 자료를 이용하여 각 모형에 예측력 차이가 발생하는지에 대한 실험도 실시하였다. 그러나 그 실험결과는 로그로 변환한 자료를 이용한 실험결과와 동일하였다. 결과적으로 본 연구에서는 로그에 의한 정규화 방법이 통계적으로 유의함이 입증되었으며 따라서 다른 정규화 변환방법을 채택할 이유가 없었다. 그러나 다른 형태의 자료로 연구를 수행할 때에는 또다른 변환방법이 타당할 수도 있다고 사료된다.

〈표 2〉

선정된 재무비율 (57개)

구분	번호	재무비율	구분	번호	재무비율
성 장 성	1	총자산증가율	안 전 성	30	유동부채비율
	2	매출액증가율		31	고정부채비율
	3	경상이익증가율		32	차입금의존도 1
	4	순이익증가율		33	차입금의존도 2
	5	고정자산증가율 1		34	차입금의존도 3
	6	고정자산증가율 2		35	총부채구성율
	7	고정자산증가율 3		36	고정자산 구성율
	8	총부채증가율 1		37	재고자산대 유동자산
	9	총부채증가율 2		38	재고자산대 유동자산변화율
	10	총부채증가율 3		39	순운전자본대 총자본
	11	총부채증가율 4		40	이자보상배율
수 익 성	12	총자본경상이익율	현 금 흐 름	41	이자배율
	13	총자본순이익율		42	현금흐름대 자기자본비율
	14	기업경상이익율		43	현금흐름대 차입금비율
	15	자기자본경상이익율		44	현금흐름대 총자산비율
	16	자기자본순이익율		45	현금흐름대 매출액비율
	17	자본금순이익율	활 동 성	46	총자본회전율
	18	매출액경상이익율		47	자기자본회전율
	19	매출액순이익율		48	순운전자본회전율
	20	매출액총이익율		49	고정자산회전율
	21	매출액영업이익율		50	재고자산회전율
	22	금융비용대 매출액		51	재고자산회전율의 변화
	23	배당율	기 업 신 용 율	52	매입채무대 매출채권변환율
안 전 성	24	자기자본비율		53	매입채무대 유동부채
	25	유동비율		54	매입채무대 유동부채변화율
	26	당좌비율		55	매입채권대 유동자산변화율
	27	고정비율		56	매입채무대 매출채권(신용율)
	28	고정장기적합율		57	매입채무대 재고자산
	29	부채비율			

3.2 기업도산예측 지식베이스모형의 구축방법

3.2.1 MDA의 의사지식베이스 구축방법

MDA의 의사지식베이스 (pseudo-knowledge base)를 구축하기 위한 투입변수를 결정하기 위하여 제1절에서 선정된 57개의 변수를 대상으로 t-검정을 실시하였다 (input). t-검정은 각 변수의 평균치가 통계적으로 유의한 차이를 지니고 있는지에 대한 검정이다. MDA는 예측변수들이 지닌 정보를 가지고 관찰대상기업을 몇개의 사전적 집단들 중의 어느 하나로 분류하거나 예측하는데 이용되는 통계적 분석기법으로서 여러개의 변수를 동시에 고려하여 둘 이상의 집단간의 차이를 연구하려고 할 경우 사용된다 (process). MDA의 의사지식베이스인 판별함수를 도출하기 위하여 이용되는 독립변수의 결합방법에는 모든 변수를 개별적인 판별능력에 관계없이 동시에 고려하여 함수를 결정하는 직접법(direct method)과 변수의 판별능력을 기준으로 함수에 포함될 변수를 순차적으로 선정하는 단계적 방법(stepwise method)이 있다(output).

본 연구에서 사용되는 재무비율의 수는 기타 다른 연구와 비교하여 상당히 많은 재무비율이 사용되고 있다. 이와 같이 다수의 재무비율이 연구에 사용되므로 개별적인 판별능력에 관계없이 모든 변수를 동시에 고려하는 직접법은 변수의 중요도를 고려하지 않는 방법이 되므로 윌크스의 람다(Wilks' Lambda)를 기준으로 의미있는 변수를 선정하는 단계적 MDA를 실시하였다. 본 연구에서는 SPSS를 이용하여 t-검정과 MDA의 실험을 수행하였다.

3.2.2 귀납적 학습방법의 지식베이스 구축방법

귀납적 학습방법은 이미 설명한 바와 같이 과거사례를 학습함에 따라 모든 사례를 각 계층으로 구분할 수 있는 기준인 의사결정트리를 지식베이스로 구축하는 방법이다. 본 논문에서 활용한 귀납적 학습방법은 ACLS이다. 본 연구에서 사용된 ACLS는 파스칼(Pascal) 언어로 코딩되었다. 보다 자세한 알고리즘의 내용을 위해서는 Braun & Chandler (1987)와 Lee & Oh (1990)의 연구논문을 참조하기 바란다. 귀납적 학습방법을 위해 입력될 정보는 t-검정과 MDA를 통하여 선정된 재무비율들이다 (input). ACLS는 투입된 각각의 재무비율들의 수치를 분할기준으로 사용하여 기대정보내용 $ICT(t_0)$ 와 분할기준에 의한 하위노드의 기대정

보내용 $ICT(t_0|sr)$ 을 계산하여 기대정보량 $\Delta Inf(t_0|sr)$ 을 최대로 하는 분할기준을 선정하여 (process), 주어진 모든 사례를 각 계층으로 구분할 수 있는 의사결정트리를 도출한다 (output).

3.2.3 인공신경망의 지식베이스 구축방법

인공신경망은 사례의 주요재무비율을 입력층에 투입시켰을 때 입력층과 은닉층, 은닉층과 출력층의 처리단위간에 상호연결된 연결가중치를 지식베이스로 구축한다. 그러나, 인공신경망은 MDA이나 귀납적 학습방법과 같이 투입변수를 시스템 자체에서 선정할 수 없다는 단점이 존재한다. 이러한 단점을 해결하기 위하여 본 연구에서는 MDA와 귀납적 학습방법에서 선정된 재무비율을 인공신경망의 투입변수로 활용하였다(input). 인공신경망은 입력층에 투입된 재무비율을 은닉층, 다시 은닉층에서 출력층으로 전달하는 과정에서 연결가중치로 구성된 지식베이스를 구축하게 되며 (process), 구축된 지식베이스를 활용하여 검증용 표본에 대하여 0에서 1사이의 실수값으로 비도산가능성과 도산 가능성에 대한 결과치를 산출하게 된다(output). 본 연구에서는 인공신경망 실험을 위하여 역전파학습 알고리즘을 C언어로 코딩하여 사용하였다. 인공신경망 실험시 모멘텀 (β)과 학습률(α)은 각각 0.9와 0.7로 고정시켜서 사용하였고, 학습반복횟수는 최대 100000번으로 하였다.

3.2.4 ILANN모형의 지식베이스 구축방법


ILANN모형은 다음과 같은 두가지 기본개념에 기초하고 있다.

- ① 귀납적 학습방법과 인공신경망 기법을 결합하여 각 방법이 갖고 있는 장점을 극대화하여 도산예측율을 보다 향상시키고자 한다.
- ② 인공지능 기법에 근간을 두고 있는 만큼 추론결과에 대한 설명기능 (Justification)을 강화한다.

즉, 귀납적 학습방법은 지식의 추론과정을 명확히 설명할 수 있는 장점이 있는 반면에 지식베이스에 저장되어 있지 않은 새로운 유형의 사례를 예측할 수 없다는 단점이 있다. 인공신경망은 새로운 사례에도 높은 예측력을 가진다는 장점은 있으나 추론과정을 명확히 제공할 수 없다는 단점이 있다. 이와 같은 두가지 접근방법의 단점을 보완하고 장점을 최대로 이

용하기 위하여 귀납적 학습방법과 인공지능망을 코오퍼레이티브 추론기관 (Cooperative Inference Engine)이라는 하나의 메카니즘으로 연결하여 새로운 기업도산예측 모형, 즉 ILANN (귀납적 학습지원 인공지능망) 모형을 구성하고자 한다. ILANN모형의 지식베이스 구축과 관련된 전체적인 시스템 구성도는 <그림 1>과 같다.

<그림 1> ILANN모형의 지식베이스의 구축과정



Coakley & Brown (1991)은 인공지능망의 시스템오류 수준을 변경시켜가며 제1종의 오류(도산기업을 비도산기업으로 분류)와 제 2종의 오류(비도산기업을 도산기업으로 분류)간의 관계를 분석하였다. 그들의 연구결과를 살펴보면 인공지능망은 시스템오류 수준이 낮아짐에 따라 제2종의 오류는 증가하고 제 1종의 오류는 감소한다는 사실을 제시하였다. 본 논문은 Coakley & Brown (1991)의 연구결과를 바탕으로 하여 인공지능망의 결과와 귀납적 학습방법의 결과를 연결하여 하나의 코오퍼레이티브 추론기관을 구성하려고 한다. 그러나, 검증용 표본과 관련하여 다음과 같은 문제점이 제기되었다. 즉, 본 논문의 검증용 표본은 분석용 표본의 추출기간 이후의 미래기간에서 추출한 것으로 도산여부에 대한 진실한 결과를 사전에 알 수 없다는 가정을 하고 있다. 따라서 사후적인 결과의 분석에 의하여 나타나는 제 1종의 오류와 제 2종의 오류를 구분할 수 없다는 문제점이 발생하게 된다. 이 문제점의 해결 방안으로 본 연구에서는 제 1종의 오류와 제 2종의 오류를 다음과 같이 가정하고자 한다. <표 3>은 이러한 가정을 구체적으로 설명하기 위하여 도시된 것이다. <표 3>과 같이 인공지능망의 결과와 귀납적 학습방법의 결과를 조합하여 보면 양자의 결과가 동일하거나 상이한 경우

가 발생하게 된다.

〈표 3〉 제 1종의 오류와 제 2종의 오류

인공신경망	귀납적 학습방법	오류 형태
도 산	도 산	인공신경망의 결과 확증
비도 산	비도 산	인공신경망의 결과 확증
도 산	비도 산	제 1 종의 오류
비도 산	도 산	제 2 종의 오류

ILANN모형은 위의 인공신경망의 결과를 귀납적 학습방법의 분석결과와 비교하여 양 모형의 예측 결과가 동일할 때에는 귀납적 학습방법의 결과는 인공신경망의 결과를 더욱 확증하여 주는 역할을 하는 것으로 간주하고 있다. 그러나 양 모형의 결과가 서로 상이할 때, ILANN모형은 인공신경망의 결과가 도산이며 귀납적 학습방법의 결과가 비도산일 경우를 제 1 종의 오류로 가정하게 되고 인공신경망의 결과가 비도산이며 귀납적 학습방법의 결과가 도산일 경우를 제 2 종의 오류로 가정한다. 이러한 가정을 바탕으로 하여 ILANN모형의 코오퍼레이티브 추론기관은 다음과 같은 방식의 추론을 수행하게 된다.

- 1) 인공신경망의 결과와 귀납적 학습방법의 결과가 동일한 사례에 대하여 코오퍼레이티브 추론기관은 인공신경망의 결과를 귀납적 학습방법의 결과가 더욱 강화하여 확증하여 주는 것으로 결과를 제시한다.
- 2) 인공신경망의 결과와 귀납적 학습방법의 결과가 서로 상이할 때 코오퍼레이티브 추론기관은 다음과 같은 기준에 따라 인공신경망과 귀납적 학습방법의 결과중 하나를 선택하여 추론결과를 제시한다.

① 시스템오류의 수준이 0.05이상일 때

본 연구에서는 인공신경망의 시스템오류 수준이 0.05이상일 때에는 인공신경망이 제 1 종의 오류를 많이 발생시키는 경향이 있음이 확인되었다. 따라서 1종의 오류발생시 귀납적 학습방법의 지식베이스를 이용하여 기업의 도산에 대한 예측을 하도록 하며 제 2 종의 오류발생시는 인공신경망의 지식베이스를 이용하여 기업 도산에 대한 예측을 하도록 한다.

② 시스템오류의 수준이 0.05이하일 때

본 연구에서는 인공지능망의 시스템오류 수준이 0.05이하일 때는 인공지능망은 제 2종의 오류를 많이 발생시키는 경향이 있다. 따라서 제 1종의 오류발생시 인공지능망의 지식베이스를 이용하여 기업의 도산여부에 대한 예측을 하고 제 2종의 오류 발생시 귀납적 학습방법의 지식베이스를 이용하여 기업도산에 대한 예측을 한다.

본 실험에서 사용되는 시스템오류 수준 0.05는 본 연구의 특성에 맞게 실험자의 주관에 따라 설정된 것으로 이 기준은 의사결정자의 환경에 따라 변동가능하다. <표 4>에는 코오퍼레이티브 추론기관의 실행시에 시스템오류와 오류종류간의 조합에 따라 이용되는 지식베이스를 간단하게 도시하였다.

<표 4> 코오퍼레이티브 추론기관의 지식베이스 이용방법

시스템오류 \ 오류타입	제1종의 오류	제2종의 오류
시스템오류(0.05이상)	ILKB 이용	NNKB 이용
시스템오류(0.05이하)	NNKB 이용	ILKB 이용

* ILKB: 귀납적 학습 지식베이스

NNKB: 인공지능망 지식베이스

IV. 실증분석

본 절에서는 변수의 t-검정의 결과를 기술하고 MDA, 귀납적 학습방법, 인공지능망 및 ILANN모형의 평균예측을 결과를 비교하고 이를 통하여 각 모형의 지식베이스의 안정성과 일반화 능력 및 각 모형의 학습성과에 대하여 고찰하고자 한다.

4.1 변수의 기술통계량분석

57개의 재무비율중 도산기업과 비도산기업의 차이를 잘 나타내주는 재무비율을 선정하기 위하여 각 그룹별로 t-검정을 실행하였다. <표 5>에는 t-검정의 결과가 제시되어 있다. <표 5>의 t-검정결과를 살펴보면 전체변수 57개 중 각 그룹마다 다수의 유효한 비율이 나타난다. 이

를 구체적으로 5%의 유의수준에서 그룹별로 살펴보면 그룹 1에서는 40개의 재무비율이 선정되었고 그룹 2에서는 42개의 재무비율이 선정되었으며 그룹 3에서는 41개의 재무비율이 선정되었음을 알 수 있다.

4.2 MDA 적용결과

t-검정을 통하여 각 그룹별로 선정된 재무비율로 MDA분석을 수행하기 위하여, Wilks λ 를 통계량으로 하는 단계적 선택법에 의해 판별변수를 순차적으로 선택한 후, 이를 이용한 판별함수를 구축한다. 구축된 판별함수의 분류정확도에 대하여는 검증용 표본을 중심으로 평가한다. 각 그룹별 MDA분석 결과는 <표 6>, <표 7>, <표 8>에 제시되어 있다. 이러한 MDA의 판별함수는 귀납적 학습방법의 의사결정트리 또는 인공신경망에서의 학습가중치와 같은 지식베이스의 역할을 하므로 이를 의사지식베이스 (pseudo-knowledge base)라 한다. 따라서 <표 6>, <표 7>, <표 8>은 MDA에 의한 각 자료그룹별 의사지식베이스이다. 이는 검증자료를 이용하여 MDA에 의한 기업도산예측을 하기 위한 지식베이스로 사용된다.

각 그룹별 MDA결과를 살펴보면 그룹 1, 그룹 2, 그룹 3에서 Wilk λ 가 가장 큰 독립변수는 배당률임을 알 수 있다. 또한 선정된 변수의 수를 보면 그룹 1에서는 10개의 재무비율이 선정되었고, 그룹 2에서는 18개의 재무비율이, 그룹 3에서는 17개의 재무비율이 선정됨을 알 수 있다. 의사지식 베이스인 MDA의 판별함수를 이용하여 검증용 실험자료에 대한 예측결과가 <표 9>에 제시되어 있다.

〈표 5〉

t-검정의 결과

채무비율	그룹 1	그룹 2	그룹 3	채무비율	그룹 1	그룹 2	그룹 3
1 총자산증가율	*	**	**	30 유동부채비율	**	**	**
2 매출액증가율	**	**	**	31 고정부채비율	**	**	**
3 경상이익증가율	**	**	**	32 차입금의존도 1	**	**	**
4 순이익증가율	**	**	**	33 차입금의존도 2	**	**	**
5 고정자산증가율 1	**	*	*	34 차입금의존도 3	*	**	**
6 고정자산증가율 2				35 총부채구성율	**	**	**
7 고정자산증가율 3				36 고정자산구성율			
8 총부채증가율 1				37 재고자산대 유동자산			
9 총부채증가율 2		*	*	38 재고대 유동자산변화율			
10 총부채증가율 3				39 순운전자본대 총자본	**	**	**
11 총부채증가율 4				40 이자보상배율	**	**	**
12 총자본경상이익율	**	**	**	41 이자배율	**	**	**
13 총자본순이익율	**	**	**	42 현금흐름대 자기자본비율	**	**	**
14 기업경상이익율	*	**	**	43 현금흐름대 차입금비율	**	**	**
15 자기자본경상이익율	**	**	**	44 현금흐름대 총자산비율	**	**	**
16 자기자본순이익율	**	**	**	45 현금흐름대 매출액비율	**	**	**
17 자본금순이익율	**	**	**	46 총자본회전율	**	**	**
18 매출액경상이익율	**	**	**	47 자기자본회전율	*	**	**
19 매출액순이익율	**	**	**	48 순운전자본회전율	**	**	**
20 매출액총이익율	*	*	**	49 고정자산회전율	*	*	
21 매출액영업이익율	*	**	**	50 재고자산회전율			
22 금융비용대 매출액	**	**	**	51 재고자산회전율의 변화율			
23 배당율	**	**	**	52 매입채무대 매출채권변화율			
24 자기자본비율	**	**	**	53 매입채무대 유동부채		*	*
25 유동비율	**	**	**	54 매입채무대 유동부채변화율			
26 당좌비율	**	**	**	55 매입채무대 유동자산변화율			
27 고정비율	**	**	**	56 매입채무대 매출채권			
28 고정 장기적합율	*	**	*	57 매입채무대 재고자산			
29 부채비율	**	**	**				

(**=P<0.01 * =P<0.05)

〈표 6〉

그룹 1(79~84년)의 MDA결과

독립변수	Wilks's λ	Prob>F	판별함수 계수
X4: 순이익증가율	0.45958	0.0000	.2807587
X12: 총자본경상이익율	0.29407	0.0000	-.5607472
X18: 매출액영업이익율	0.34206	0.0000	-1.227218
X23: <u>배당율</u>	<u>0.48159</u>	0.0000	3.871811
X24: 자기자본비율	0.36554	0.0000	2.149630
X26: 당좌비율	0.43109	0.0000	5.351551
X31: 고정부채비율	0.30236	0.0000	-2.812158
X46: 총자본회전율	0.31162	0.0000	10.68564
X47: 자기자본회전율	0.35251	0.0000	-.6462193
X49: 고정자산회전율	0.32575	0.0000	-8.145704
불변계수			-5.011395

〈표 7〉

그룹 2(79~90년)의 MDA 결과

독립변수	Wilks's λ	Prob>F	판별함수 계수
X4: 순이익증가율	0.40187	0.0000	.3156717
X5: 고정자산증가율 1	0.32671	0.0000	-.2623576
X9: 총부채증가율 2	0.34777	0.0000	-7.918077
X12: 총자본경상이익율	0.35616	0.0000	-15.55280
X13: 총자본순이익율	0.47133	0.0000	6.029362
X16: 자기자본순이익율	0.38720	0.0000	-3.690864
X18: 매출액경상이익율	0.29298	0.0000	14.77240
X23: <u>배당율</u>	<u>0.50334</u>	0.0000	2.059115
X24: 자기자본비율	0.36999	0.0000	2.496821
X26: 당좌비율	0.42133	0.0000	5.554235
X28: 고정장기적합율	0.28450	0.0000	3.098546
X30: 유동부채비율	0.37989	0.0000	-3.935763
X35: 총부채구성율	0.29298	0.0000	18.84880
X41: 이자배율	0.28839	0.0000	-.5671426
X42: 현금흐름 / 자기자본	0.31977	0.0000	19.75378
X44: 현금흐름대 매출액	0.33337	0.0000	-20.35451
X47: 자기자본회전율	0.27996	0.0000	-.3633394
X48: 순운전자본회전율	0.45011	0.0000	-.4100811
불변계수			-23.93467

〈표 8〉

그룹 3(79~91년)의 MDA 결과

독립변수	Wilks's λ	Prob>F	판별함수 계수
X3: 경상이익증가율	0.38273	0.0000	.3684922
X5: 고정자산증가율1	0.46688	0.0000	-.4667383
X9: 총부채증가율 2	0.39475	0.0000	-4.861948
X12: 총자본경상이익율	0.29407	0.0000	9.436876
X13: 총자본순이익율	0.41362	0.0000	-.6730449
X14: 기업경상이익율	0.41915	0.0000	-.4972269
X19: 매출액순이익율	0.40761	0.0000	-7.844558
X23: <u>배당율</u>	<u>0.58411</u>	0.0000	1.991760
X24: 자기자본비율	0.44148	0.0000	2.068574
X26: 당좌비율	0.47886	0.0000	2.740345
X28: 고정장기적합율	0.49619	0.0000	5.322400
X30: 유동부채비율	0.40202	0.0000	-3.077061
X33: 차입금의존도 2	0.51856	0.0000	-2.334340
X40: 이자보상배율	0.39475	0.0000	-.6744509
X45: 현금흐름대매출액	0.38942	0.0000	-.6035866
X47: 자기자본회전율	0.43100	0.0000	-.6602921
X54: 매입채무대 유동부채 변화율	0.45836	0.0000	.3338391
불변계수			-3.452564

〈표 9〉

MDA의 도산예측 실험결과

분석 \ 검증	85~90년	91년	92년	평균예측율
그룹 1	25 / 30	20 / 30	23 / 40	68% (68 / 100)
그룹 2	—	20 / 30	28 / 40	68.57% (48 / 70)
그룹 3	—	—	28 / 40	70% (28 / 40)

4.3 귀납적 학습방법 적용결과


귀납적 학습방법은 학습의 결과를 의사결정트리 (decision tree)라는 지식베이스로 구축하게 된다. 예를들어 그룹 1을 학습자료로 하여 귀납적 학습방법을 적용한 결과 유도되는 지식베이스는 〈그림 2〉에 도시된 것과 같이 의사결정트리로 표시가 된다. 컴퓨터에 의해서 선정된 분할기준을 중심으로 하여 선정된 분할기준보다 높은 수치를 가진 사례의 집단은 H의 방향으로 분류되고, 선정된 분할기준보다 낮은 수치를 가진 사례의 집단은 L의 방향으로 분류

된다. 따라서 귀납적 학습방법은 지식베이스를 의사결정트리로 제공함으로써 의사결정자가 의사결정트리의 흐름을 따라 각 사례가 어떠한 추론과정을 거쳐 도산, 비도산의 결론에 이르게 되었는가의 과정을 명확하게 설명할 수 있다.

〈그림 2〉와 같은 의사결정트리로 표현된 귀납적 학습방법의 지식베이스를 각 그룹별 학습자료에 대하여 유도한 다음, 이를 검증용 표본에 적용하였을 때의 결과는 〈표 10〉에 제시되어 있다. 〈표 10〉의 결과를 MDA의 결과(그룹 1: 68%, 그룹 2: 68.57%, 그룹 3: 70%)와 비교하면 귀납적 학습방법의 예측정확율이 MDA의 예측정확율보다 다소 우수함을 알 수 있다. 특히 귀납적 학습방법에 의하여 선정된 재무비율의 숫자가 각 그룹별로 볼때 그룹 1은 7개, 그룹 2는 7개, 또한 그룹 3은 9개로서 MDA의 경우보다 훨씬 적음에도 불구하고 예측정확율은 오히려 높다는 것은 주목할만한 사항이라고 생각한다.

〈그림 2〉

그룹 1(79~84년)의 귀납적 학습방법 지식베이스



〈표 10〉 귀납적 학습방법의 도산예측 실험결과

분석 \ 검증	85~90년	91년	92년	총예측율
그룹 1	26 / 30	22 / 30	26 / 40	74% (74 / 100)
그룹 2	—	23 / 30	28 / 40	72.86% (51 / 70)
그룹 3	—	—	31 / 40	77.50% (31 / 40)

4.4 인공지능망 적용결과

인공지능망의 실험은 MDA에 의하여 선정된 재무비율을 입력층의 투입변수로 사용하는 인공지능망 I과 귀납적 학습방법을 통하여 선정된 재무비율을 투입변수로 사용하는 인공지능망 II로 나누어 실시하였다. 인공지능망 I에서 입력층의 노드에 투입될 변수는 MDA에서 선정된 변수이므로 그룹 1은 〈표 6〉의 10개의 변수를 처리하기 위하여 10개의 입력층의 처리단위를 가지며, 그룹 2는 〈표 7〉의 18개, 그룹 3은 〈표 8〉의 17개의 처리단위를 가지게 된다. 은닉층의 처리단위의 수는 의사결정자가 입력층에 투입되는 정보가 어느 정도 고차원적인 정보인가의 판단에 따라 주관적으로 설정하지만, 본 연구에서는 입력층의 처리단위와 같게 하였다. 출력층의 처리단위의 수는 2개로 하여 0(비도산)과 1(도산)의 값을 출력층의 처리단위에 부여하였다. 따라서 전체적인 인공지능망의 구성도는 그룹 1은 $(10(\text{입력층 처리단위}) \times 10(\text{은닉층 처리단위}) \times 2(\text{출력층 처리단위}))$ 의 삼층전향층을, 그룹 2는 $(18 \times 18 \times 2)$ 의 삼층전향층을, 그룹 3은 $(17 \times 17 \times 2)$ 의 삼층전향층을 가지게 된다. 〈표 11〉은 인공지능망의 출력결과와 사례중 하나이다. 〈표 11〉을 살펴보면 표본 1과 같이 output 1의 결과값(0.949991)이 output 0의 결과값(0.052407)보다 큰 경우는 도산으로 분류된 것이며, 표본 2와 같이 output 1의 결과값(0.039653)이 output 0의 결과값(0.961106)보다 작은 경우는 비도산으로 분류된 것이다.

〈표 11〉 인공지능망 결과의 해석사례

표본 1: 도산의 예	sample 1	output	0= $\langle$ computed: 0.052407 $\rangle$
	sample 1	output	1= $\langle$ computed: 0.949991 $\rangle$
표본 2: 비도산의 예	sample 2	output	0= $\langle$ computed: 0.961106 $\rangle$
	sample 2	output	1= $\langle$ computed: 0.039653 $\rangle$

〈표 12〉 인공신경망 I을 이용한 도산예측 실험결과

분석 \ 검증	85~90년	91년	92년	평균예측율
그룹 1	25 / 30	20 / 30	25 / 40	70% (70 / 100)
그룹 2	—	24 / 30	32 / 40	80% (56 / 70)
그룹 3	—	—	32 / 40	80% (32 / 40)

인공신경망 II는 귀납적 학습방법에 의하여 선정된 변수를 투입변수로 사용하는 것외에는 인공신경망 I의 구성과 같게 설계하였다. 따라서 전체적인 구성도는 그룹 1은 (7×7×2)의 삼층전향층을, 그룹 2는 (7×7×2)의 삼층전향층을, 그룹 3은 (9×9×2)의 삼층전향층을 갖게 된다. 인공신경망 II의 실험결과는 〈표 13〉에 제시되어 있다.

〈표 13〉 인공신경망 II을 이용한 도산예측 실험결과

분석 \ 검증	85~90년	91년	92년	평균예측율
그룹 1	26 / 30	20 / 30	27 / 40	73% (73 / 100)
그룹 2	—	23 / 30	34 / 40	81.43% (57 / 70)
그룹 3	—	—	33 / 40	82.5% (33 / 40)

4.5 ILANN모형 적용결과

ILANN모형은 인공신경망 II와 귀납적 학습방법의 장·단점을 상호보완하기 위하여 코오퍼레이티브 추론기관을 통하여 구동된다. ILANN모형으로 실험한 결과는 〈표 14〉에 제시되어 있다.

〈표 14〉 ILANN모형의 도산예측 실험결과

분석 \ 검증	85~90년	91년	92년	평균예측율
그룹 1	27 / 30	23 / 30	27 / 40	77% (77 / 100)
그룹 2	—	24 / 30	36 / 40	85.71% (60 / 70)
그룹 3	—	—	37 / 40	92.5% (37 / 40)

4.6 결과의 비교 및 해석

이상에서 분석용 기업을 학습자료로 활용하고 검증용 기업을 예측자료로 활용하여 MDA, 귀납적 학습방법, 인공지능망 I, 인공지능망 II, 그리고 ILANN모형에 대한 실험을 수행하여 각 모형의 도산예측 정확성에 대한 결과를 살펴보았다. 그러나, 여기서 한가지 확인하고 넘어가야 할 사항은 예측력을 본 연구에서와 같이 퍼센트(%)로 나타내는 것이 통계적으로 타당한 것인가라는 점이다. 즉, 같은 80%라고 하여도 전체 몇개중의 80%이냐에 따라 그 의미는 사뭇 달라질 수가 있기 때문이다. 그러나, 본 연구에서 취한 방법론을 살펴보면 분석용 표본을 추출년도에 따라 세 그룹으로 분류하고 각 분석모형의 예측력을 해당 그룹별로 비교하였기 때문에, 같은 그룹내에서는 검증표본수는 항상 동일하다. 따라서 분석모형간의 예측력을 비교측정하는 단위를 퍼센트로 하여도 그결과가 의미하는 통계학적 의미에는 전혀 문제가 없다. 이는 실제로 도산예측에 관한 기존연구에서도 확인할 수 있는 바이다 (Raghupathi et al. 1991).

한편, 본 연구의 주요목적은 ILANN모형과 나머지 통계 및 인공지능 모형간의 도산예측력 비교에 있지만, 아울러 보다 많은 분석용 표본이 학습되었을때 이같은 도산예측력이 얼마나 향상되는지를 파악하는 것도 또한 본 연구의 부수적인 연구목적이 된다. 따라서 보다 정교한 도산예측을 위한 연도별 예측, 즉 2년 예측, 5년 예측등과 같은 방법은 사용하지 않았다. 그러나, 설령 이러한 연도별 예측을 적용한다고 하더라도 본 연구에서 지금까지 제시한 각 분석모형별 도산예측력의 의미는 변화되지 않는다. 왜냐하면 일정기간의 분석용 표본을 학습하여 이를 기초로 미래의 검증년도에 따른 예측력 검증을 수행하기 때문이다. 예를들어 그룹 2의 경우 91년의 도산예측은 과거 90년까지의 분석용 자료를 기초로 수행한 '도산 1년예측'에 해당되고, 92년도 도산예측은 '도산 2년예측'에 해당되기 때문이다. 결국 과거의 일정 분석기간에 걸쳐서 추출된 분석표본은 '학습'(learning)을 통하여³⁾ 각 분석모형에 통합적으로 반영되기 때문에 이를 기초로 검증표본에 대해 수행한 예측은 해당 검증기간에 따라 '1년 예측' 또는 그 이상의 연도별 예측이 될 수 있는 것이다.

이러한 개념정립을 기초로 각 모형의 예측력 비교에 관한 비교 및 해석을 정리하면 다음과

3) 단, MDA의 경우 학습이라기 보다는 과거 일정기간의 분석자료에 대한 '적합' (fitting)이라는 표현이 더 적절할 것이다. 그러나, 적합 역시 넓은 의미에서 보면 학습의 일종이라고 볼 수 있기 때문에, 결국 MDA에서 계수를 추정하는 문제도 학습이라고 간주할 수 있다.

같다. <표 15>는 각 모형의 도산예측력을 종합하여 하나의 도표로 제시한 것이다.

<표 15> 각 모형의 예측력 결과


그룹	MDA	인공신경망 I	귀납적 학습	인공신경망 II	ILANN모형
그룹 1	68%	70%	74%	73%	77%
그룹 2	68.57%	80%	72.86%	81.43%	85.71%
그룹 3	70%	80%	77.50%	82.5%	92.5%

본 연구의 목적은 각 모형의 예측력을 상호비교하는데 있다. 예측력을 중심으로 각 결과를 비교하여 보면 <표 15>에 나타난 것처럼 ILANN모형이 다른 모형에 비하여 가장 우수한 예측력을 나타내고 있으며, 다음으로 귀납적 학습방법에서 선정된 변수를 사용하는 인공신경망 II의 예측력이 MDA에서 선정된 변수를 사용하는 인공신경망 I의 예측력보다 다소 우수함을 알 수 있다. 또한 두 인공신경망 모형을 귀납적 학습방법의 예측력과 비교하여 보면, 그룹 1에서는 귀납적 학습방법의 예측력이 우수하나 그룹 2와 그룹 3에서는 인공신경망 I과 인공신경망 II의 예측력이 우수하여 전체적으로 인공신경망 I과 인공신경망 II의 예측력이 귀납적 학습방법보다 우수함을 알 수 있다. 마지막으로 MDA의 경우가 예측력이 가장 떨어진다. 이상의 결과를 종합하면

ILANN모형 > 인공신경망II > 인공신경망I > 귀납적 학습방법 > MDA

의 순으로 예측력이 우수하다고 할 수 있다. 즉, 인공지능에 기초한 각 모형은 통계적 모형인 MDA에 비하여 예측력이 우수함이 증명되었다. 또한 인공신경망을 이용한 모형중에서도 ILANN모형의 예측력이 가장 우수하다는 사실을 확인하였다. 이를 그래프로 살펴보면 [그림 3]과 같다.

[그림 3]



다음에서는 위의 결과가 인공지능의 어떠한 특성에 기인하는지 구체적으로 고찰하고자 한다. 본 연구는 미래환경에 대한 각 모형의 적응력을 고찰하기 위하여 각 그룹별 검증용 표본을 분석용 표본의 미래기간에서 추출하였다. 위의 <표 15>의 그룹별 예측력 결과는 결과적으로 각 모형의 미래환경에 대한 적응력을 나타낸다고 볼 수 있다. 따라서 각 모형의 미래환경에 대한 적응력은 <그림 3>에서 나타난 바와 같이 ILANN모형, 인공신경망 II, 인공신경망 I, 귀납적 학습방법, MDA의 순으로 우수함을 알 수 있다. 이와 같이 인공신경망을 이용하는 모형이 미래환경에 대한 적응력을 가지는 현상을 견고성(robustness)라고도 하는데 이는 인공신경망이 다수의 연결가중치로 상호연결되어 있기 때문이다. 즉, 입력자료중 몇개가 극단치를 지니고 있거나 또는 불확실한 정보가 들어온다고 하여도 이는 특정한 소수 처리단위의 연결가중치에만 영향을 미칠 뿐 다수의 연결가중치로 구성된 시스템 전체의 성과에는 크게 영향을 미치지 못한다는 것이다. 따라서 인공신경망에 기초한 도산예측 시스템은 급격히 변하는 환경이나 예측치 못했던 환경에서도 안정적인 도산예측률이 보장된다는 측면에서 매우 주목할 만하다고 하겠다.


기존 문헌을 고찰하여 보면 귀납적 학습방법과 인공신경망등의 인공지능 기법은 사례의 수가 증가하여 새로운 사례에 대한 학습이 증가될 수록 지식베이스의 견고성과 일반성이 향상된다. 인공지능의 이러한 특성에 대하여 본 연구에서는 <표 15>의 결과를 중심으로 살펴보고자 한다. 인공신경망 I (70%에서 80%로 증가)과 인공신경망 II(73%에서 82.5%로 증가) 및 ILANN모형 (77%에서 92.5%로 증가)과 같이 인공신경망을 이용하는 세 모형의 경우에는 새로운 사례가 첨가되어 학습되었을 때 예측력이 크게 향상되었음을 관찰할 수 있다. 그러나 귀납적 학습방법(74%에서 77.50%로 증가)과 MDA(68.67%에서 70%로 증가)의 경우에 새로운 사례를 학습함에도 예측력이 별로 향상되지 않았음을 관찰할 수 있다. 이러한 결과의 의미는 인공신경망을 이용하는 모형은 새로운 사례를 학습하여 지식베이스로 연결가중치를 가지게 되는데 새로운 사례가 학습될 수록 연결가중치가 일정한 수로 수렴하여 안정화되어가며 학습되지 않은 사례에 대하여도 일반성을 가지게 됨을 의미한다. 결론적으로 미래환경에 대한 적응력과 지식베이스의 일반성이라는 측면으로 보아도 위와같은 순서인 ILANN모형, 인공신경망 II, 인공신경망 I, 귀납적 학습방법, MDA의 순으로 나타났다.

본 연구의 각 모형 중 가장 주목해야 할 모형은 ILANN모형이라고 할 수 있다. 본 연구의 결과는 ILANN모형이 인공신경망의 장점인 예측력, 미래환경에 대한 적응력, 학습성과 일반

성면에서도 가장 우수하다는 것을 제시하고 있다. 이러한 인공지능망의 장점 이외에도 ILANN모형은 귀납적 학습방법의 장점인 지식의 추론과정을 확인할 수 있다는 장점이 있다. <그림 4>는 그룹 3을 분석용 자료로 이용하여 지식베이스를 구축하고 92년의 기업에 대해 예측력을 검증한 사례중 하나로 ILANN모형의 장점을 구체적으로 설명하기 위하여 제시한 기업표본이다.

<그림 4>

ILANN모형의 해석사례



이 기업에 대하여 인공지능망은 output 1의 결과값(0.989359)이 output 0의 결과값(0.010641) 보다 크므로 도산으로 해석하고 있다. 그러나 인공지능망은 지금까지 설명한 것처럼 환경에 대한 적응력 및 예측력이 우수하지만 추론과정을 설명할 수 없다는 단점이 있다. 그러나 본 연구에서 제시하는 ILANN모형은 귀납적 학습방법의 지식베이스를 인공지능망과 더불어 이용함으로써 추론과정에 대한 설명을 가능하게 한다. 도표에서 보는 바와 같이 사례

기업의 총자본경상이익율(-.66)은 분할기준(.615)보다 작으므로 L방향(화살표 방향)으로 분류과정을 진행한 후 2차적으로 자기자본비율(-.83)이 하위 노드 분할기준(.675)보다 크므로 H의 방향으로 분류되는 과정을 거쳐 결국 화살표 방향을 따라 도산이란 결론에 이르게 된다. 결론적으로 귀납적 학습방법을 이용하는 모든 사례에 대하여 ILANN모형은 그 추론과정을 이와 같이 설명할 수 있는 것이다.

V. 결 론

본 연구는 기업 도산예측에 있어서 전통적으로 사용되어 오던 MDA의 방법론적, 통계학적 단점을 극복하고자 인공지능 기법에 기초한 새로운 귀납적 학습지원 인공지능망 모형인 ILANN모형을 제시하였다. 이러한 모형의 성과를 검증하기 위하여 기업도산예측에 적용하여 MDA, 귀납적 학습, 그리고 인공지능망 방법과 상호비교하고 그 장단점을 고찰하였다.

실증분석의 결과는 ILANN모형이 가장 좋은 예측성을 가지며 그 다음으로 인공지능망이 ILANN모형을 제외한 다른 모형에 비하여 비교적 높은 예측정확성을 가지고 있음을 나타내고 있다. 또한 지식베이스의 일반성 측면에서도 인공지능망의 모형을 이용한 ILANN모형, 인공지능망 II 모형, 인공지능망 I 모형이 높은 학습성과 일반성을 가지고 있음을 제시하고 있다. 마지막으로 본 논문에서 처음 시도되었던 ILANN모형은 예측력이나 미래환경에 대한 적응력, 안정성과 일반성 측면에서도 다른 모형에 비하여 가장 우수하였고, 또한 추론 과정에 대한 부분적인 설명능력도 갖고 있음이 확인되었다.

그러나 본 연구는 몇가지 해결하여야 할 과제가 있는바, 이를 요약하면 다음과 같다.

- 1) 본 연구는 표본대상기업을 상장기업으로만 한정하였는바, 그 이유는 일반적으로 상장기업이 그 업계를 대표하는 기업으로 간주되기 때문이다. 따라서 본 논문에서는 상장되지 않은 중소기업의 특성이 반영되지 않았다.
- 2) 기업의 특성을 나타내는 지표로서는 계량적인 자료뿐만이 아니라 질적인 자료도 포함된다. 본 연구에서도 질적인 자료를 사용하고자 하였으나 일부의 자료밖에는 구할 수

없이 이 부분에 대한 연구는 시행하지 못하였다.

- 3) 표본기업은 각 업종별로 구분하지 못하고 전 산업을 대상으로 하였다. 표본기업을 각 업종별로 구분하여 실증분석을 한다면 더욱 정확한 예측력이 기대된다.

따라서 앞으로의 연구방향은 다음과 같다.

- 1) 보다 현실적으로 이용가능한 기업도산 예측모형의 개발을 위하여 업종별, 규모별, 상장 여부별로 세분화된 실험이 요구된다.
- 2) 본 연구는 ILANN모형을 통하여 인공신경망과 귀납적 학습방법만을 통합적으로 적용하였다. 그러나 이외에도 인공신경망과 MDA의 통합모형과 같이 기타 다른 모형간의 장단점을 보완할 수 있는 통합모형도 가능하리라 본다.

참 고 문 헌

〈국내 문헌〉

1. 강철승, “부가가치 회계정보의 기업부실예측력에 관한 실증적 연구”, 회계학 연구 제 12 호 (1991년 7월), 79-100.
2. 김선기, 황석하, 김건우, “기업부실화의 원인, 징후 및 예측”, 한국신용평가 (주), 1986.
3. 박창길, “우리나라 재무제표의 기업실패 예측능력의 실증적 연구”, 박사학위논문, 서울대, 1984.
4. 이건창, “기업도산예측을 위한 통계적 모형과 인공지능모형간의 예측력 비교에 관한 연구 : MDA, 귀납적 학습방법, 인공신경망”, 한국경영과학회지, 제 18 권 제 2 호 (1993년 8 월), 57~81.
5. 정준수, “기업도산 예측 모델에 관한 연구”, 박사학위논문, 경북대, 1985.
6. 한국기업재무총람, 1985~1991, 한국신용평가주식회사.
7. 기업재무총람, 1979~1991, 한국상장협의회.
8. 한인구, “귀납적 학습방법과 통계학적 방법의 예측력에 관한 비교연구”, 회계학 연구, 제 11 호 (1990년 12월), 245~267.
9. 황석하, “기업부실예측에 관한 연구”, 회계학 연구, 제 12 호 (1991년 7월), 57~78.
10. 회계연감, 1979~1991, 매일경제신문

〈국외 문헌〉

1. Altman, E.I., "Financial Ratios, Discriminant Analysis and Prediction of Corporate Bankruptcy", *The Journal of Finance*, Vol. 23 (Sep 1968), 589~609.
2. _____, R.G. Haldeman and P. Narayanan, "Zeta Analysis", *Journal of Banking and Finance* (June 1977), 29~51.
3. Beaver, W.H., "Financial Ratios as Predictors of Failure", *Empirical Research in Accounting: Selected Studies* (1966), 71~111.
4. Berry, R. and D. Treigueiros, "The Application of Neural Network Based Methods to The Extraction of Knowledge from Accounting Reports", *IEEE International Joint Conference on Neural Networks* (1991), 136~146.
5. Biggs, S.F., M. Selfridge and G.R. Krupka, "A Computational Model of Auditor Knowledge and Reasoning Process in the Going-Concern Judgment", *Working Paper*, University of Connecticut, 1989.
6. Blum, M., "Failing Company Discriminant Analysis", *Journal of Accounting Research* (Spring 1974), 1~25.
7. Braun, H. and J.S. Chandler, "Predicting Stock Market Behavior through Rule Induction: An Application of the Learning-From-Example Approach", *Decision Science*, Vol. 18 (1987), 415~429.
8. Buijink, W. and M. Jegers, "Cross-Sectional Distributional Properties of Financial Ratios in Belgian Manufacturing Industries: *Some Empirical Evidence*", *Technical Report*, University of Antwerp, Belgium, 1984.
9. Chung, H. and K. Tam, "A Comparative Analysis of Inductive-Learning Algorithm", *Intelligent Systems in Accounting, Finance and Management*, vol. 2 (1992), 3~18.
10. Coakley, J. R. and C. E. Brown, "Neural Networks Applied to Ratio Analysis in the Analytical Review Process", *The 4th International Symposium on Expert Systems in Accounting, Finance and Management* (1991), 1~35.
11. Collins, R. A. and R. D. Green "Statistical Methods for Bankruptcy Forecasting",

-
- Journal of Economics and Business*, Vol. 32 (1972), 349~354.
12. Deakin, E.B., "A Discriminant Analysis of Predictors of Business Failure", *Journal of Accounting Research* (Spring 1972), 167~179.
 13. Eisenbeis, R. A. "Profits in the Application of Discriminant Analysis in Business, Finance, and Economics", *The Journal of Finance*, vol. 32 (1979), 875~900.
 14. Freeman, J.A. and D.M. Skapura, *Neural Networks: Algorithms, Applications, and Programming Techniques*. Addison-Wesley Publishing Company, 1991.
 15. Frydman, F., E.I. Altman and D.L. Kao, "Introducing Recursive Partitioning for Financial Classification: The Case of Financial Distress", *The Journal of Finance*, vol. 40 (1985), 269~291.
 16. Gorman, R.P. and T.J. Sejnowski, "Analysis of Hidden Units in a Layered Network Trained to Classify Sonar Targets", *Neural Networks*, vol. 1 (1988), 75~89.
 17. Harris, C.H. and P.A. Frishkoff, "An Expert Decision Support System for Auditor Going Concern Evaluation", Ph. D. Dissertation, The University of Texas at Arlington, 1989.
 18. Horrigan, J., "The Determination of Long Term Credit Standing with Financial Ratios", *Journal of Accounting Research* (1965), 44~68.
 19. Hunt, E.B., J. Marin, and P.T. Stone, *Experiments in Induction*, Academic Press, New York, 1966.
 20. Karels, G.V. and A. Prakash, "Multivariate Normality and Forecasting of Business Bankruptcy", *Journal of Business Finance & Accounting* (Winter 1987), 573~593.
 21. Lee, K.C., "StratPlanner: A Self-Evolving Fuzzy DSS for Strategic Planning that Combines Neural Networks and Expert Systems", *Proceeding of 2nd International Society of Decision Support Systems Conference*, Ulm (Germany), 1992.
 22. Lee, S.B. and S.H. Oh, "A Comparative Study of Recursive Partitioning Algorithm and Analog Concept Learning System", *Expert Systems with Applications*, vol. 1 (1990), 403~416.
 23. Liang, T.P., "A Composite Approach to Inducing Knowledge for Expert Systems

- Decision", *Management Science*, vol. 38, no. 1 (Jan 1992), 1~17.
24. _____, J.S. Chandler, H. Ingoo and J. Roan, "An Emprical Investigation of Some Data Effects on the Classification Accuracy of Probit, ID3 and Neural Networks", *Working Paper*, University of Illinois at Urbana-Champaign, 1991.
 25. Lippmann, R., "An Introduction to Computing with Neural Nets", *IEEE ASSP Magazine* (April 1987), 4~22.
 26. Meisser, W.F. and J.V. Hansen, "Inducing Rules for Expert System Development: An Example Using Default and Bankruptcy data", *Management Science*, Vol. 34, No. 12 (Dec 1988), 1403~1415.
 27. Moyer, R.C., "Forecasting Financial Failure: A Reexamination", *Financial Management* (Spring 1977), 11~17.
 28. Odom, M. and R. Sharda, "A Neural Network Model for Bankruptcy Prediction", *Proceedings of the IEEE International Conference on Neural Network*, vol. 2 (1990), 163~168.
 29. Ohlson, J., "Financial Ratios and the Probabilistic Prediction of Bankruptcy", *Journal of Accounting Research*, Spring (1980), 109-131.
 30. Quinlan, J.R., "Discovering Rules by Induction from Large Collection of Examples", In D.Michie(Ed.), *Expert systems in the Micro Electronic Age*. Edinburg University Press, 1979.
 31. _____, "Induction of Decision Trees", *Machine Learning*, vol. 1 (1986), 81~106.
 32. Raghupathi, W., L.L. Schkade and B.S. Raju, "A Neural Network Application for Bankruptcy Prediction", *IEEE International Joint Conference on Neural Networks* (1991), 147~155.
 33. Rumelhart, D.E., G.E. Hinton and R.J. Williams, "Learning Internal Representations by Error Propagation", in D.E. Rumelhart and J.L. McClelland (Eds). *Parallel Distributed Processing: Exploration in the Microstructure of Cognition*. Cambridge, MA: MIT Press, 1986.
 34. Rumelhart, D. and D. Zipser, "Feature Discovery by Competitive Learning", *Cogni-*

- tive Science*, vol. 9 (1985), 75~112.
35. Schlimmer, J.C. and D. Fisher, "A Case Study of Incremental Concept Induction", Proceedings of the Fifth National Conference on Artificial Intelligence, 1986, 496~501.
 36. Shannon, C.E, "The Mathematical Theory of Communication", in C.E. Shannon and W. Weaver, *The Mathematical Theory of Communication*. University of Illinois Press, Urbana, 1964.
 37. Shaw, M.J. and J.A. Gentry, "Inductive Learning for Risk Classification", *IEEE Expert* (Feb 1990), 47~53.
 38. Tam, K. and M. Kiang, "Managerial Applications of Neural Networks: The Case of Bank Failure Predictions", *Management Science*, July (1992), 926~947.
 39. Utgoff, P.E., "ID5: An Incremental ID3", Proceedings of the Fifth International Conference on Machine Learning, The University of Michigan at Ann Arbor, 1988, 107~120.