

# 기업도산예측을 위한 통계적 모형과 인공지능 모형간의 예측력 비교에 관한 연구 : MDA, 귀납적 학습방법, 인공신경망

이건창\*

A Comparative Study on the Bankruptcy Prediction Power  
of Statistical Model and AI Models:MDA, Inductive Learning, Neural Network

Kun Chang Lee\*

## Abstract

This paper is concerned with analyzing the bankruptcy prediction power of three methods : Multivariate Discriminant Analysis(MDA), Inductive Learning, Neural Network. MDA has been famous for its effectiveness for predicting bankruptcy in accounting fields. However, it requires rigorous statistical assumptions, so that violating one of the assumptions may result in biased outputs. In this respect, we alternatively propose the use of two AI models for bankruptcy prediction—inductive learning and neural network. To compare the performance of those two AI models with that of MDA, we have performed massive experiments with a number of Korean bankrupt—cases. Experimental results show that AI models proposed in this study can yield more robust and generalizing bankruptcy prediction than the conventional MDA can do.

## 1. 서 론

기업의 재무적 건전도를 비도산과 도산으로  
판별하는 것은 감사인뿐만 아니라 투자자, 채

권자, 은행 및 잠재적인 투자자의 재무 및 투  
자의사결정에 영향을 주게 된다. 기업의 재무  
적 건전도의 정보를 감사인은 감사대상 기업의  
재무자료가 신뢰성이 있는지 여부에 대한 판정  
근거 자료로 활용할 수 있으며, 투자자는 최적

\* 경기대학교 경영정보학과

포트폴리오를 구성할 때 이를 위험평가에 대한 정보로 활용할 수 있다. 또한 은행은 대출을 위한 신용평가의 주요정보로 활용할 수도 있다.

기존 문헌을 살펴보면 도산예측과 같은 재무의사결정을 위하여 가장 많이 사용되는 통계기법은 다변량판별분석(Multivariate Discriminant Analysis : MDA) 기법이다. Altman [10]에 의해 MDA가 기업의 도산예측에 사용된 이후 이와 유사한 도산예측 연구나 주가의 행태예측 연구에 MDA는 폭넓게 사용되었다. 그러나 MDA는 다음과 같은 몇가지 방법론적, 통계학적 문제를 갖고 있다[17].

1) MDA는 독립변수들의 정규분포를 가정하고 있다. 그러나 실제로는 이러한 정규분포 가정이 위배되는 경우가 많으며 이 경우 그 결과가 상향편의(Upward Bias)될 가능성이 있다.

2) 독립변수로서 명목척도를 사용할 때 예측 오차가 크게 발생한다.

3) MDA에 의한 대부분의 도산예측모형은 분석용 표본으로부터 판별함수를 도출하고 이를 검증용 표본(Hold-out Sample)에 의해 그 타당성을 검증하는데, 이러한 검증용 표본을 분석용 표본과 같은 기간에 걸쳐 추출함으로써 미래에 대한 예측력 검증이 아니라 과거자료에 대한 판별의 타당성 검증에 그치는 경우가 많다.

이와 같은 MDA의 문제점을 해결하기 위하여 제안된 방법으로는 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.

본 연구에서는 도산예측에 대한 기존의 통계

학적인 방법론이 갖는 한계를 극복하고 보다 실용적이고 효과적인 도산예측 기법을 제안한다는 차원에서 인공지능 기법을 이용한 두 방법을 적용하여 그 결과를 기존의 MDA방법과 비교하고자 한다. 본 연구에서 적용하는 인공지능 기법은 귀납적 학습(inductive learning) 방법과 인공신경망(neural network) 이론이며, 일련의 엄격한 실험과정을 거쳐 기존의 도산예측방법과 비교할 때 본 연구에서 제안하는 인공지능 기법에 의한 도산예측의 장점을 구체적으로 제시하고자 한다.

본 연구에서 고려하는 MDA, 귀납적 학습방법, 그리고 인공신경망을 간략하게 비교하면 다음과 같다.

1) MDA는 독립변수의 분포가 정규분포라는 것을 가정하고 있으나 귀납적 학습방법과 인공신경망은 독립변수의 분포에 아무런 가정을 하지 않는다.

2) MDA는 독립변수와 종속변수간에 선형함수를 가정하고 있으나, 귀납적 학습방법은 특정한 함수를 가정하지 않으며, 인공신경망은 선형함수 뿐만 아니라 비선형함수도 가정할 수 있다.

3) 인공신경망은 새로운 유형의 사례를 학습할 수록 해당 지식베이스가 일반성을 갖게 되나, MDA와 귀납적 학습방법은 그러한 메카니즘이 없다.

4) 귀납적 학습방법은 추론과정에 대한 설명이 가능하나 인공신경망과 MDA는 추론과정에 대한 설명이 불분명하다.

결국 MDA는 사용방법이 간편한 반면 독립변수에 대한 정규성 가정, 환경의 변화에 따른 예측력 하락, 추론과정을 설명할 수 없다는 단점이 있다. 귀납적 학습방법은 학습된 자료에 대해서는 추론과정을 명확히 설명할 수 있으나

학습되지 않은 자료에 대해서는 추론기능이 급격히 저하된다는 단점이 있다. 한편 인공신경망은 귀납적 학습방법과는 대조적으로 추론과정을 명확히 설명하지는 못하나 새로운 입력자료에 대한 추론이 뛰어나며(일반성), 환경의 변화에 대한 적응력이(상황적응성) 우수하다는 장점이 있다.

본 연구에서는 보다 의미있는 도산예측율을 추정하기 위하여 분석용 기업표본과 검증용 기업표본을 동일한 기간내에서 추출하지 않고 검증용 기업표본을 분석용 기업표본의 추출년도 이후의 기간에서 추출하였다. 이는 도산예측의 타당성을 현재시점이 아닌 미래시점에서 검증하므로써 각 모형이 (MDA, 귀납적 학습방법, 인공신경망) 미래의 환경변화에 어느 정도의 적응력을 보이는지를 분석하고자 하는 동기때문이다. 또한 분석용 표본기업을 년도에 따라 크게 세 그룹으로 묶고 그룹 1은 66개의 표본기업으로 하고, 그룹 2는 그룹1의 표본기업에 85-90년도의 도산 및 비도산기업 30개를 추가하여 96개의 표본기업으로 구성하였으며, 그룹 3은 그룹 2의 표본기업에 91년의 새로운 사례 30개를 새롭게 추가하여 126개의 표본기업으로 구성하였다. 이와같이 표본기업을 년도에 따라 그룹별로 분류한 이유는 분석용 표본에 새로운 사례가 증가되어 학습되었을때 각 모형의 예측 메카니즘이 환경변화에 얼마나 잘 적응하고 그에 따라 도산예측의 정확성이 얼마나 향상되는지를 보기 위해서이다.

제2장에서는 본 연구에서 사용하는 인공지능 기법인 귀납적 학습방법과 인공신경망의 이론적 배경을 분석하고, 제3장에서는 도산예측에 사용되었던 통계적 모형과 귀납적 학습방법, 그리고 인공신경망 기법에 대한 기존 연구문헌을 검토한다. 제4장에서는 본 논문에서 제안하

는 연구방법을 제5장에서는 그 실험결과를 설명하며, 마지막으로 제6장에서는 본 연구의 한계점과 미래의 연구방향을 제시하였다.

## 2. 인공신경망과 귀납적 학습방법의 이론적 배경

본장의 제1절에서는 귀납적 학습방법의 지식 학습방법인 ID3(Iterative Dichotomizer 3)와 ACLS(Analog Concept Learning System)의 알고리즘에 대하여 설명하고 제2절에서는 인공신경망의 특성과 학습방법인 역전파학습(Back-propagation Learning)에 대하여 언급하고자 한다.

### 2.1 귀납적 학습방법

본 연구에서 사용하는 귀납적 학습방법이란 기존의 사례로부터 일정한 의사결정기준(decision rule), 즉 지식(knowledge)을 도출하는 방법이다. 이는 기존의 지식획득(knowledge acquisition) 방법과는 달리 객관성이 있고, 지식 유도 과정에 소용되는 시간이 상대적으로 짧다는 장점이 있다. 더우기 기존의 지식획득 방법은 대부분 해당분야의 전문가에게 크게 의존하기 때문에 지식획득 과정에서 시간과 비용상 많은 문제가 야기되었으나, 귀납적 학습방법은 전문가에게 의존하는 바가 별로 없이 오직 수집된 자료만을 가지고 해당문제에 대한 지식을 획득할 수가 있기 때문에 수집된 자료의 질만 보장된다면 상당히 유용한 지식획득 방법이 될 수 있다. 즉, 이 방법은 특정분야에 대한 기존

의 사례에서 지식을 학습하여 의사결정트리 형태로 구성된 지식을 유도하고 이를 이용한 지식베이스를 활용하여 해당 의사결정 분야의 의사결정에 이용하는 방법이다. 귀납적 학습방법의 판별·예측에 대한 정확성 여부는 추출된 지식의 질에 의하여 결정되므로 사용된 학습 알고리즘의 효율성이 매우 중요하게 된다. 현재까지 개발된 귀납적 학습방법으로는 ID3[28, 29]를 비롯하여 ID3의 일반형인 ACLS[29], CRIS[24], ID4[33], ID5[36] 등의 다양한 방법이 있다.

귀납적 학습방법은 주어진 학습자료의 특성을 감안한 분류규칙을 도출하는 것으로서 이는 주어진 학습자료를 특정개념 또는 계층으로 분류하는 기준이다. 이러한 기준이 곧 해당 학습자료에 대한 규칙 또는 지식이 된다. 결국 이 방법은 기존사례를 학습자료로 사용하여 각 사례를 각 계층에 분류할 수 있는 기준을 추론하고 추론된 기준을 새로운 사례에 적용하는 방법이다. 따라서 귀납적 학습방법은 다음과 같은 유용성을 제공할 수 있다.

1) 지식회특성 : 주어진 학습자료를 특정개념이나 계층으로 분류할 수 있는 지식을 도출하여 이를 유사한 실험자료를 인식하는데에 사용할 수 있다.

2) 지식대표성 : 획득된 지식의 규모는 원래의 학습자료의 규모와 비교할 때 상대적으로 매우 작으나 주어진 학습자료를 특정개념에 따라 모두 분류할 수 있는 정보를 포함하고 있다. 이는 정보관리상 매우 중요한 의미를 지니는 것으로서 컴퓨터의 저장용량의 절약과 계산의 효율성 제고라는 측면에 긍정적인 영향을 제공한다.

본 논문에서 사용하는 귀납적 학습방법은 ACLS로서 이를 설명하기 위하여 우선 ID3부

터 설명하기로 한다.

### 2.1.1 ID3(Iterative Dichotomizer 3)

귀납적 학습방법의 하나인 ID3는 Hunt, Marin and Stone[22]에 의하여 제시된 개념학습시스템(Concept Learning System: CLS)에 기초한 것으로서 Quinlan[28, 29]에 의해 실용화된 학습방법이다. 이는 학습한 지식을 의사결정트리로 표현하는 전형적인 방법으로서 의사결정트리의 노드에는 자료의 특성(Attribute)들이 위치하며 자료 특성의 값(value of attribute)에 따라 각 자료들은 특정계층이나 개념으로 분류된다. ID3는 효율적인 분류기준을 발견하기 위하여 반복적인 탐색작업을 수행하며 주어진 학습자료를 정확히 분류하는 분류기준이 완성될 때 그 분류기준 탐색작업을 마치게 된다. ID3는 의사결정트리의 각 노드에서 주어진 자료의 특성에 대한 기대정보내용(expected information content), 즉 엔트로피(entropy)를 계산한다. 이러한 엔트로피는 Shannon(1964)의 정보이론에서 제시된 개념으로서 정보의 선택 및 불확실성에 대한 의사결정시 가장 많은 정보내용을 갖는 특성을 찾는 기준으로서 이용된다.

ID3는 위에서 계산된 엔트로피 중 가장 높은 값을 가진 특성을 루트노드(root node)에 위치시키고 이 특성의 값에 근거하여 주어진 학습자료에 대한 분류작업을 수행한다. 분류작업 결과 모든 학습자료가 정확하게 분류되면 ID3는 작업수행을 마치게 되나 정확하게 분류되지 못하면 ID3는 분류되지 못한 학습자료만을 대상으로 하여 다시 엔트로피를 계산하여 새로운 특성을 하위노드에 위치시키고 재분류를 하게 된다. 이러한 과정은 모든 학습자료가 완전하게 분류될 때까지 반복적으로 수행된다. ID3의

장점은 많은 수의 자료와 특성이 존재할 때 복잡한 계산이 필요없이 반복적인 분류작업을 통하여 정확한 분류기준을 추론할 수 있다는 것이다. 그러나 실수형 변수가 사용될 때 ID3는 분류의 정확성이 감소된다는 약점이 있고 이러한 문제점을 해결하기 위하여 보다 일반화된 ACLS(Analog Concept Learning System)가 개발되었다.

2.1.2 ACLS(Analog Concept Learning System)

ACLS[29]는 ID3의 일반화된 지식학습 방법이다. ID3는 위에서 설명한 것처럼 의사결정트리 각 노드에서 엔트로피를 계산하여 분류하는 반복적인 과정을 통하여 분류기준을 구축하는 방법으로 그 적용이 간단한 장점이 있지만 범주형 변수(Catalog Variables)에서만 사용이 가능하다는 단점이 있다. 본 연구에서 사용하고자 하는 변수는 재무비율로서 이는 일반적으로 실수형 변수이므로 ID3를 이용하기에는 적합하지 못하다. 따라서 ID3를 보다 일반화시킨 ACLS를 이용한다.

ACLS의 메카니즘을 설명하기 위하여  $n(t)$ 를 노드 t에 할당된 사례의 수라 하고,  $n_i(t)$ 를 노드 t에서 계층 i에 속하는 사례의 수를 나타낸다고 하자. 이때 해당 노드 t에서의 엔트로피는 곧 노드 t에서의 기대정보내용(expected information content)으로서 이는 다음과 같이 표현할 수 있다.

$$ICT(t) = - \sum_{i=0}^k \left( \frac{n_i(t)}{n(t)} \right) \cdot \log_2 \left( \frac{n_i(t)}{n(t)} \right)$$

한편, 노드 t에서 하나의 사례가 계층 i에 속할 조건부 확률은  $p(i|t) = n_i(t)/n(t)$ 가 되고 하나의 사례가 특정 분할기준(splitting rule:sr)에 의하여 노드 t의 하위 노드인  $t_j$ 로 할당될 조건부 확률은  $p(t_j|t, sr) = n(t_j)/n(t)$ 가 된다.

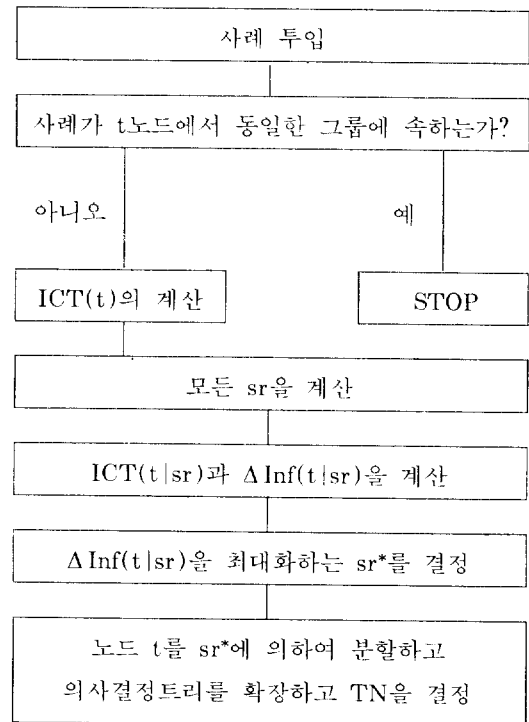
따라서 분류기준 sr에 대한 노드 t에서의 기대정보내용을  $ICT(t|sr)$ 이라고 정의하면 이는

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

라고 표현할 수 있다. 따라서 이와 같이 노드 t에서 특정 분할기준(sr)에 의하여 하위노드로 branch할 때 증가되는 정보량, 즉  $\Delta Inf$ 는

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

로 정의된다. 결과적으로 ACLS는 노드 t에서  $\Delta Inf(t|sr)$ 를 최대로 하는 분할기준을 선정하여 하위노드를 구성하며 이러한 과정은 최종노드(Terminal Node:TN)에 이르러 모든 사례를 정확히 구분할 때까지 반복적으로 수행된다. 다음 [그림 1]은 ACLS의 알고리즘을 플로우차트로 도시한 것이다.



[그림 1] ACLS의 알고리즘

## 2.2 인공신경망

귀납적 학습방법과 함께 인공지능의 한 분야인 인공신경망은 인간두뇌의 휴리스틱(heuristic)한 문제해결 방법을 모형화한 것으로서 그 학습능력과 추론능력이 매우 뛰어난 것으로 알려져 있다. 인공신경망의 구조는 여러가지 형태가 있으나, 가장 일반적으로 많이 쓰이는 형태는 '감독학습'(supervised learning)에 알맞는 다층 전향구조(multilayerd feedforward) 인공신경망이다. 이는 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)의 삼층 구조를 이루며 각 층마다 다수의 뉴런(neuron) 또는 노드(node), 즉 처리단위(processing unit)를 소유하고 있다. 서로 다른층에 존재하는 처리단위는 서로 연결되어 있으며(fully connected) 그러한 연결의 강도는 '연결가중치'(interconnection weight)로 계산된다. 결국 인공신경망은 주어진 문제를 해결하기 위한 지식을 이러한 다수의 연결가중치로 분산표현하고 있으며 따라서 이는 기존의 학습방법에서는 찾아볼 수 없는 강력한 학습성(learnability)과 견고성(robustness)을 갖고 있다. 이러한 인공신경망에 대한 보다 자세한 언급은 Freeman & Skapura[18]와 Lippmann[26]의 연구를 참조하기 바란다. 이와같이 인공신경망은 서로 연결되어 있는 다수의 처리단위들로 구성되어 있기 때문에 견고성과 학습성을 갖는바, 이를 구체적으로 설명하면 다음과 같다[26].


1) 견고성(robustness) : 인공신경망은 일반적으로 오류극복성(fault tolerance)을 갖는데 이는 곧 특정 몇몇 처리단위에 오류가 발생하여도 인공신경망의 전체적인 기능이 크게 영향을 받지 않음을 의미한다. 따라서 인공신경망의 성과는 오류의 정도가 증가됨에 따라 점차적으로

감소하는 추세를 보이므로써 급격히 변하는 환경이나 예측치 못했던 환경에서 인공신경망이 안정적으로 기능하는데 크게 이바지한다.

2) 학습성(learnability) : 인공신경망은 주어진 학습 입력력 자료로부터 숨겨진 규칙성(regularities)을 찾아낼 수 있다. 이러한 규칙성은 인공신경망내에 분산된 처리단위에 각각 저장되며 이는 결국 귀납적 학습방법의 지식베이스에 해당한다. 이와 같은 인공신경망의 지식은 수리적 가중치로 표현되고 학습기법에 의하여 어느정도 자동적으로 얻을 수 있다.

인공신경망의 추론결과는 0에서 1까지의 실수로 나타나게 된다. 이를 인공신경망에서는 퍼지화(fuzzification)라고 한다. 예로 도산기업의 추론 결과는 "도산 가능성(0.25) 비도산 가능성(0.78)"로 나타나게 되며 이때의 값 0.25와 0.78이 해당 도산 및 비도산 가능성의 퍼지값이 된다. 한편, 인공신경망의 지식베이스인 연결 가중치(connection weights)는 역전파학습(Rumelhart, Hinton and Williams 1986)과 같은 감독학습(supervised learning)에 의해서 결정되거나 또는 경쟁학습(competitive learning) (Rumelhart and Zipser 1985) 같은 비감독학습(unsupervised learning)에 의해서 결정된다. 이중 역전파학습은 인공신경망의 학습방법으로 가장 많이 이용되는바, 그 이유는 역전파학습이 갖는 넓은 응용력과 높은 일반화 능력에 기인한다. [그림 2]는 역전파학습(Backpropagation:BP)을 이용한 삼중 전향신경층(three-layer feedforward) 인공신경망을 도시하고 있다. [그림 2]에서의 입력층(input layer)은 환경과 상호반응하며 외부입력을 받아 인공신경망에 전달하는 역할을 한다. 또한 출력층(output layer)은 주어진 외부입력에 대한 적절한 출력을 내보내는 역할을 한다. 한편

입력층과 출력층 사이의 신경층을 중간층(intermediate layer) 또는 은닉층(hidden layer) 이라고 하며, 이는 주어진 입력으로부터 특성을 추출하여 출력층으로 보내는 기능을 한다. 은닉층의 수와 처리단위 규모의 결정은 주관적으로 결정되어 인공신경망의 응용에 따라 달라지며 따라서 그 타당성은 실험을 통하여 확인하여야 한다. 그러나 하나 또는 두개의 은닉층만 있어도 거의 모든 형태의 문제해결공간을 형성할 수 있다[19, 26].



[그림 2] 역전파 학습을 이용한 삼중 전향신경망 구조

역전파학습에서 사용되는 인공신경망은 무조건 입력층에서 은닉층, 은닉층에서 출력층으로 각 처리단위가 서로 연결되어 있는 것이 특징이다. 각각의 처리단위는 주어진 학습자료로부터 학습하는 학습기능(learning function)과 상호 연결된 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 특정 함수, 즉 전이함수로 처리하여 새로운 출력을 연결되어 있는 상부신경층의 처리단위에 전달한다. 그림 2에서 처리단위 j에서의 순입력(net input) I<sub>j</sub>는 다음과 같다.

$$I_j = \sum_{i=1}^n w_{ij} \cdot O_i$$

w<sub>ij</sub>는 i 처리단위와 j 처리단위를 연결하는 연결가중치이며 O<sub>i</sub>는 하부신경층내의 처리단위 j의 출력이다. 처리단위 j의 출력은 순입력 net를 특정한 함수형태에 의해서 전이시켜서 얻어지며 이러한 전이함수(transfer function)중 가장 대표적인 것은 다음과 같은 Sigmoid함수이다.

$$O_j = f(I_j) = \frac{1}{1 + e^{-I_j}}$$

이와 같은 과정을 출력층에 이르면 까지 계속되며 최종적으로 출력된다. 즉 출력처리단위에서 실제값과 인공신경망의 계산값 사이의 차이를 구하는데 일반적으로는 차이의 제곱합을 구하며 이를 시스템 오류(system error)라고 한다. 이같은 과정을 전향적 단계(forward pass)라고 한다. 다음 단계로서는 이러한 시스템 오류를 줄이기 위한 과정으로서 이를 위해 연결가중치를 조정하는데 이를 후향적 단계(backward pass)라 한다. 역전파학습은 이러한 시스템 오류를 작게 하기 위하여 다음과 같은 일반화된 연결가중치 조정규칙을 사용한다.

$$\Delta w_{ij} = \beta \cdot E_j \cdot f'(net_{ij}) + \alpha \cdot \Delta w_{ij}^{previous}$$

단, 0.0 < β < 1.0 그리고 0.0 < α < 1.0

여기서 β는 모멘텀(momentum)이고 α는 학습률(learning rate)이라고 한다. 한편 E<sub>j</sub>는 처리단위의 출력값과 실제값과의 차이로서, 출력층에서의 식과 은닉층에서의 식이 다음과 같이 서로 다르다. 출력층에서는

$$E_j = O_j^{\text{desired}} - O_j^{\text{actual}}$$

와같이 정의되고, 은닉층에서는

$$E_j = \frac{df(I_j^{\text{hidden}})}{dI} \cdot \sum_{i=1}^n w_{ji} \cdot E_i$$

와같이 정의된다. 역전파학습 과정중 전향적 단계에서는 출력층에서의 E가 계산되고 이에 기초하여 후향적 단계에서 은닉층의 E가 계산된다.

### 3. 기존 문헌의 고찰

지금까지의 기업도산 예측모형과 관련하여 제연구들을 고찰하여 보면 통계적 모형(Statistical Model)과 전문가시스템 모형 및 인공지능망 모형의 세가지 형태로 구분할 수 있다. 본 장에서는 지금까지 연구된 기업도산 예측에 관한 제연구들을 중심으로 고찰하고자 한다.

#### 3.1 통계적 모형

기업의 도산예측에 많이 사용되는 통계적 모형은 MDA, 로지트분석(logit analysis) 및 프로비트분석(probit analysis) 등을 들 수 있다. MDA는 Altman[10]에 의해 도산예측에 이용되어 이후에도 많은 연구가 시행되었는데, 우리나라에서도 이러한 MDA를 이용한 실증적 도산예측 연구가 박창길[3], 정준수[4], 김선기 등[2], 황석하[8], 강철승[1] 등에 의해 이루어졌다.

그러나 MDA는 제1장에서 언급한 바와같이 방법론적, 통계학적 문제점으로 인하여 그 현실적인 유용성에 제약을 받고 있다. 로지트분석과 프로비트분석은 MDA의 정규분포의 가정에 대한 문제점을 해결하기 위한 통계적 모형으로 사용되어 왔다. 국내에서도 황석하[8], 한인구[7] 등의 연구에서 프로비트분석이 사용되고 있다. Collins and Green[16]은 MDA와 로지트분석을 비교한 연구에서 로지트분석은 MDA와 별다른 차이를 보여주지 못하지만 MDA 보다는 로지트모형이 제1종의 오류를 적게한다는 것을 실증분석하였다. Liang등 [25]의 연구에 의하면 변수로서 명목척도가 사용되었을 때에는 귀납적 학습방법이 프로비트분석에 비하여 예측력이 우수하나 계량적 자료가 사용되었을 때는 프로비트 분석이 귀납적 학습방법보다 예측력이 우수하다고 보고하고 있다.

#### 3.2 귀납적 학습방법 모형

귀납적 학습방법 모형은 학습자료에서 유도된 분류기준을 의사결정트리로 표현하고 나머지 자료를 이용하여 예측력을 검증하는 방법이다. Biggs등[12]의 연구에서는 계속기업에 관한 감사인의 의견지침서인 SAS No.34 및 SAS No.59를 귀납적 학습방법을 통하여 GCX(Going Concern expert)라는 전문가시스템 프로그램을 만들었고, Shaw and Gentry[35]에서는 투자위험을 평가하는데 귀납적 학습방법을 이용하였다. Liang[24]은 복합규칙 추론시스템(Composite Rule Induction System:CRIS)을 이용하여 도산예측을 실증적으로 분석하였다. Braun and Chandler[13]는 귀납적 학습방법중



의 하나인 Quinlan의 ID3를 이용하여 주식시장에서 주가의 행태를 예측하였고, Meisser and Hansen[27]도 도산예측시 MDA보다 귀납적 학습방법(ACLS)의 예측력이 더욱 높게 나타났다고 보고하고 있다. 한편, Harris and Frishkoff[20]는 MDA와 로지트분석 및 귀납적 학습방법의 예측력 차이를 실증분석하였는데 그 결과는 로지트분석, 귀납적 학습방법, MDA의 순서로 예측력이 우수하다고 보고하고 있다.

국내의 연구를 보면 ID3와 프로비트분석을 기업도산예측에 사용한 결과 명목변수를 사용할 때 ID3의 예측력이 더 우수함을 실증분석한 연구[7]와 반복적 분할법(Recursive Partitioning Algorithm)과 ACLS를 각각 도산예측에 적용하여 각 방법의 차이를 비교분석한 연구[23]가 있다.

### 3.3 인공신경망 모형

최근의 인공신경망을 이용한 도산예측 연구들은 인공신경망 모형이 기존의 통계적 모형이나 귀납적 학습방법 모형에 비교하여 상대적으로 높은 예측력을 가지고 있음을 보고하고 있다. Liang등[25]의 연구에서는 프로비트분석과 ID3, 인공신경망을 도산예측에 각각 적용한 결과 인공신경망의 예측력이 가장 좋은 것으로 나타났고, 프로비트분석과 귀납적 학습방법은 그 예측력에 있어서 유의할 만한 차이가 없음이 나타났다. Coakley and Brown[15]의 연구에서는 인공신경망을 이용한 도산예측 실험시 인공신경망의 시스템오류가 작을수록 제2종의 오류(type II error)가 커진다는 흥미있는 사실이 보고되고 있다. Berry and Treigueiros

[11]의 연구와 Raghupathi등[30]의 연구는 인공신경망을 이용한 도산예측의 결과가 MDA를 이용할 때보다 더 우수하다고 보고하였다.

## 4. 연구방법론

본 장에서는 1절을 통해 실험을 위한 자료의 수집방법과 변수선정과정 및 MDA의 가정인 독립변수들의 정규분포를 실현하기 위하여 독립변수를 로그로 치환한 로그정규분포(log normality)에 대하여 설명하고자 한다. 다음 제2절에서는 각 모형의 지식베이스의 구축설계방법을 자세하게 설명하고자 한다.

### 4.1 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.

#### 4.1.1 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 현

재 법정관리대상으로 분류되어 있는 업체

4) 한국증권거래소에 상장폐지를 신고하였거나 한국증권거래소에 의하여 상장이 폐지된 기업

위의 개념적 정의에 해당되는 도산기업은 81개의 표본기업이 추출되었고, 도산기업과 대응되는 비도산기업은 매출액과 업종을 기준으로 하여 85개의 표본기업이 추출되었다. 결국 본 연구에서는 총 166개의 기업을 표본대상으로 하였다. 또한 위의 도산기업과 비도산기업은

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

표본 \ 그룹	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			70개 기업			40개 기업		
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 90년도까지의 전체 검증용 표본수는 30개, 91년도 검증용 표본수는 30개, 마지막 92년도 검증용 표본수는 40개이다. 따

라서 그룹1의 경우 검증년도가 85년에서 92년도이므로 검증용 표본수가 100개가 되며, 같은 방법으로 그룹2의 경우는 91년, 92년이 검증년도이므로 검증용 표본수는 70개, 그룹3의 경우는 92년만 검증년도에 해당되므로 검증용 표본수는 40개가 된다.

#### 4.1.2 변수의 선정

본 연구에 이용되는 변수는 기업도산을 잘 나타내주는 지표로서 자료의 입수가 용이하고 객관적이며 통계처리가 가능한 재무비율을 선정하였다. 재무비율은 재무계표상의 여러항목중에서 두 항목이상을 비교하여 계산되어지기 때문에 수없이 많이 구할 수 있지만 본 연구에서

<표 2> 선정된 재무비율(57개)

구 분	번 호	재 무 비 율
성 장 성	1	총자산
	2	자출액
	3	매경순이익
	4	순이익
	5	고정자산
	6	고정자산
	7	고정자산
	8	고정자산
	9	고정자산
	10	고정자산
	11	고정자산
수 익 성	12	총자산
	13	자출액
	14	매경순이익
	15	순이익
	16	고정자산
	17	고정자산
	18	고정자산
	19	고정자산
	20	고정자산
	21	고정자산
	22	고정자산
	23	고정자산
	안 전 성	25
25		유동비율
26		당좌비율
27		고정비율
28		고정비율
29		고정비율
30		유동부채비율
31		고정부채비율
32		차입금의
33		차입금의
34		차입금의
35		총부채구성
36		고정자산
37		재고자산
38		순자산
39	순자산	
40	순자산	
41	순자산	
현금흐름	42	현금흐름
	43	현금흐름
	44	현금흐름
	45	현금흐름
	45	현금흐름
활동성	46	총자산
	47	자출액
	48	매경순이익
	49	순이익
	50	고정자산
	51	고정자산
기업신용율	52	매입채무
	53	매입채무
	54	매입채무
	55	매입채무
	56	매입채무
	57	매입채무
	57	매입채무

는 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 있다.<sup>1)</sup> 57개의 재무비율은 특성에 따라 <표 2>와 같이 11개의 성장성 비율, 12개의 수익성 비율, 18개의 안정성 비율, 4개의 현금흐름 및 6개의 기업 신용율, 6개의 활동성 비율로 분류된다.

### 4.1.3 로그정규분포(Log Normality)

MDA에서는 중요한 가정 중의 하나로 모든 독립변수는 정규분포를 따른다는 것을 강조하고 있다. 독립변수를 정규분포로 전환하는 방

법을 기존 문헌을 통하여 살펴보면 1) trimming, 2) truncation, 3) log-normality를 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 기존문헌을 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 and 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 and Treigueiros (1991)의 연구에서는 기존 문헌검토를 통하여 trimming과 truncation에 대한 문제점을 제시하고 재무비율을 정규분포로 수정하기 위하여 로그를 이용할 것을 제안했다. Berry and

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

- 고정자산증가율 1 = 금년도 고정자산 / 전년도 고정자산
- 고정자산증가율 2 = (금년도 고정자산 / 전년도 고정자산) \* (전년도 부채 / 금년도 부채)
- 고정자산증가율 3 = (금년도 고정자산 / 전년도 고정자산) \* (금년도 부채 / 전년도 부채)
- 총부채증가율 1 = 금년도 부채 / 전년도 부채
- 총부채증가율 2 = (금년도 부채 / 전년도 부채) \* (전년도 매출 / 금년도 매출)
- 총부채증가율 3 = (금년도 부채 / 전년도 부채) \* (전년도 경상이익 / 금년도 경상이익)
- 총부채증가율 4 = (금년도 부채 / 전년도 부채) \* (전년도 이자비용 / 금년도 이자비용)
- 차입금의존도 1 = 차입금 / 총자산
- 차입금의존도 2 = 차입금 / 매출
- 차입금의존도 3 = 차입금 / 총부채

Treigueiros의 연구에서 재무비율  $y/x$ 를 로그로 변환한 방법을 살펴보면 다음과 같다.

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

본 연구에서도 위와 같은 방법을 이용한 방법을 통하여 재무비율을 로그값으로 변환하였다. 또한 변환결과를 SAS의 기술통계를 이용하여 검증한 결과 그룹 1에서는 유동비율과 당좌비율을 제외한 비율들이, 그룹 2와 3에서는 유동비율, 당좌비율, 총자본회전율을 제외한 모든 비율들이 5%의 유의수준에서 정규분포를 따른다는 결과를 얻을 수 있었다. 본 논문의 실험 중 로그로 변환하지 않은 자료를 이용하여 작모형에 예측력 차이가 발생하는지에 대한 실험도 실시하였다. 그러나 그 실험결과는 로그로 변환한 자료를 이용한 실험과 동일하였다.

## 4.2 기업도산예측 지식베이스모형의 구축방법

### 4.2.1 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 몇 개의 사전적 집단들 중의 어느 하나로 분류하거나 예측하는데 이용되는 통계적 분석기법으

로서 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.

### 4.2.2 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 Pascal언어로 Coding되었다. 사용된 ACLS의 개괄적인 알고리즘은 [그림 1]에 도시되어 있다. 보다 자세한 알고리즘의 내용을 위해서는 Braun & Chandler [13]와 Lee & Oh[23]의 연구논문을 참조하기 바란다. 귀납적 학습방법을 위해 입력될 정보는 t-검정과 MDA를 통하여 선정된 재무비율들이다(input). ACLS는 투입된 각각의 재무비

율들의 수치를 분할기준으로 사용하여 기대정보내용  $ICT(t_0)$ 와 분할기준에 의한 하위노드의 기대정보내용  $ICT(t_0|sr)$ 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)<sup>2)</sup>.

#### 4.2.3 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). 본연구에서는 인공신경망 실험을 위하여 2.2에서 설명한 역전파학습 알고리즘을 C언어로 코딩하여 사용하였다. 인공신경망 실험시 모멘텀( $\beta$ )과 학습률( $\alpha$ )은 각각 0.9와 0.7로 고정시켜서 사용하였고, 학습반복횟수는 최대 10000번으로 하였다.

## 5. 실증분석 결과

본 절에서는 변수의 t-검정의 결과를 기술하고 MDA, 귀납적 학습방법, 인공신경망의 실험 결과를 비교하여 이를 통하여 각 모형의 상황 변화에 따른 지식베이스의 일반화 능력 및 각 모형의 학습성과에 대하여 분석하고자 한다.

### 5.1 변수의 기술통계량분석

57개의 재무비율중 도산기업과 비도산기업의 차이를 잘 나타내주는 재무비율을 선정하기 위하여 각 그룹별로 t-검정을 실행하였다. <표 3>에는 t-검정의 결과가 제시되어 있다. <표 3>의 t-검정결과를 살펴보면 전체변수 57개 중 각 그룹마다 다수의 유효한 비율이 나타난다. 이를 구체적으로 5%의 유의수준에서 그룹별로 살펴보면 그룹 1에서는 40개의 재무비율이 선정되었고 그룹 2에서는 42개의 재무비율이 선정되었으며 그룹 3에서는 41개의 재무비율이 선정되었다.

### 5.2 MDA 적용결과

t-검정을 통하여 각 그룹별로 선정된 재무비율로 MDA분석을 수행하기 위하여 Wilks  $\lambda$ 를 통계량으로 하는 단계적 선택법에 의해 판별변수를 순차적으로 선택한 후 이를 이용한 판별

2) [그림 3]을 참조할 것.

〈표 3〉 t-검정의 결과

재 부 비 용	그룹 1	그룹 2	그룹 3
1 총자산증가율	**	*	*
2 매출액증가율	*	*	*
3 경상이익증가율	*	*	*
4 순이익증가율	*	*	*
5 고정자산증가율	*	**	**
6 고정자산증가율			
7 고정자산증가율			
8 총부채증가율		**	**
9 총부채증가율			
10 총부채증가율			
11 총부채증가율			
12 총자산순이익율	*	*	*
13 자기순이익율	**	*	*
14 자기순이익율	*	*	*
15 자기순이익율	*	*	*
16 자기순이익율	*	*	*
17 자기순이익율	**	**	*
18 매출액순이익율	*	*	*
19 매출액순이익율	*	*	*
20 매출액순이익율	**	**	*
21 매출액순이익율	**	*	*
22 금융비용대 매출액	*	*	*
23 배당금	*	*	*
24 자기자본비율	*	*	*
25 유동비율	*	*	*
26 당좌비율	*	*	*
27 고정성비율	*	*	*
28 고정성장기적합율	**	*	**
29 부채비율	*	*	*
30 유동부채비율	*	*	*
31 고정부채비율	*	*	*
32 차입금의존도	*	*	*
33 차입금의존도	*	*	*
34 차입금의존도	**	*	*
35 총부채구성율	*	*	*
36 고정자산구성율			
37 재고대유동자산			
38 재고대유동자산			
39 순운전자본	*	*	*
40 이자보상배율	*	*	*
41 이자배율	*	*	*
42 현금흐름대 자기자본비율	*	*	*
43 현금흐름대 차입비율	*	*	*
44 현금흐름대 총자산비율	*	*	*
45 현금흐름대 매출비율	*	*	*
46 총자산회전율	*	*	*
47 자기자본회전율	**	*	*
48 순운전자본회전율	*	*	*
49 고정자산회전율	**	**	*
50 재고자산회전율			
51 재고자산회전율의 변화율			
52 매입채무대 매출채권변화율			
53 매입채무대 유동부채변화율		**	**
54 매입채무대 유동부채변화율			
55 매출채권대 유동자산변화율			
56 매입채무대 매출채권			
57 매입채무대 재고자산			

(\* = P < 0.01

\*\* = P < 0.05)

함수를 구축한다. 구축된 판별함수의 분류정확도에 대하여는 검증용 표본을 중심으로 평가한

다. 각 그룹별 MDA분석 결과는 <표 4>, <표 5>, <표 6>에 제시되어 있다.

<표 4> 그룹 1(79-8년)의 MDA 결과

독립 변수	Wilks's $\lambda$	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 5> 그룹 2(79-90년)의 MDA 결과

독립 변수	Wilks's $\lambda$	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 : 현금흐름대 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	-4.100811
불변계수			-23.93467



〈표 6〉 그룹 3(79-91년)의 MDA 결과

독립 변수	Wilks's $\lambda$	Prob>F	판별함수 계수
X3 : 경상이익증가율	0.38273	0.0000	.3684922
X5 : 고정자산증가율 1	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 : 배당율	0.58411	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 : 현금흐름대 매출액	0.38942	0.0000	-.6035866
X47 : 자기자본회전율	0.43100	0.0000	-.6602921
X54 : 매입채무대 유동부채 변화율	0.45836	0.0000	.3338391
불변 계수			-3.452564

〈표 7〉 MDA의 도산예측 실험결과

검증 분석	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)

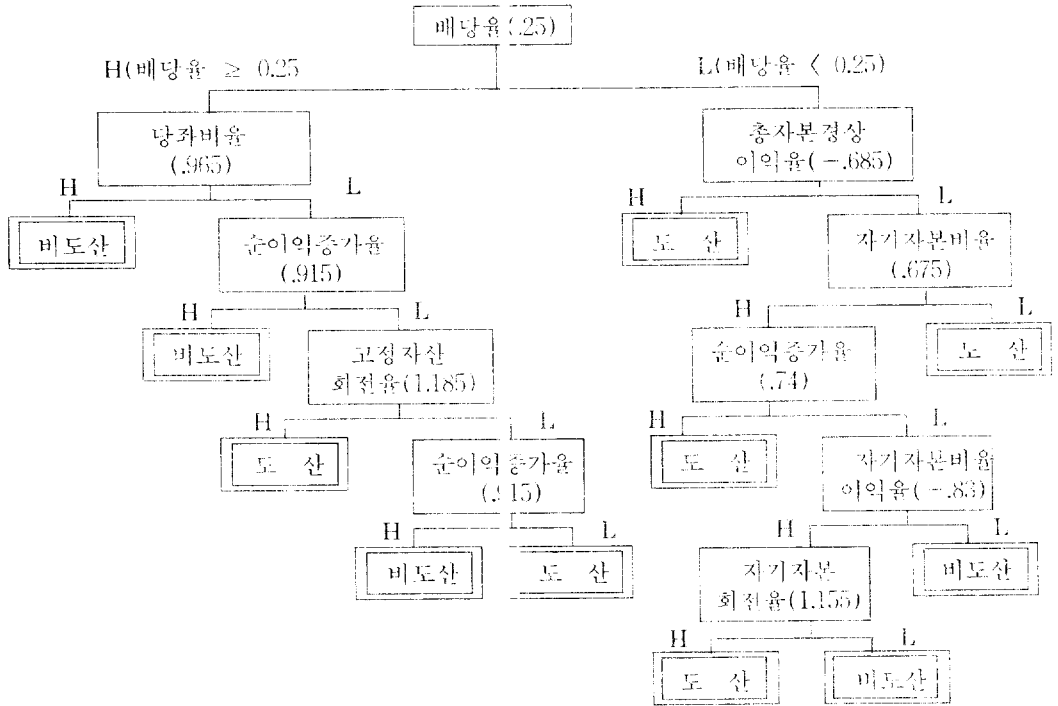
위의 각 그룹별 MDA결과를 살펴보면 그룹 1, 그룹 2, 그룹 3에서 Wilks's 랏다가 가장 큰 독립변수는 배당율임을 알 수 있다. 또한 선정된 변수의 수를 보면 그룹 1에서는 10개의 재무비율이 선정되었고, 그룹 2에서는 18개의 재무비율이, 그룹 3에서는 17개의 재무비율이 선정됨을 알 수 있다. 의사지식베이스인 MDA의 판별함수를 이용하여 검증용 실험자료에 대한 예측결과가 〈표 7〉에 제시되어 있다.

### 5.3 귀납적 학습방법 적용결과

귀납적 학습방법은 학습의 결과를 의사결정 트리라는 지식베이스로 구축하게 된다. 예를 들어 [그림 3]은 그룹 1의 자료에 대해 귀납적 학습방법을 통하여 도출된 의사결정트리를 나타내고 있다. [그림 3]에서 H의 방향으로는 선정된 분할기준보다 높은 수치를 가진 사례의 집단이 분류되고 L의 방향으로로는 낮은 수치를

가진 사례의 집단이 분류된다. 이와같이 귀납적 학습방법은 지식베이스를 의사결정트리로 제공함으로써 의사결정자가 의사결정트리의 흐름을 따라 각 사례가 어떠한 추론과정을 거쳐 도산, 비도산의 결론에 이르게 되었는가의 과정 즉, 의사결정의 추론과정을 명확히 알 수 있다. 귀납적 학습방법에서 도출된 이와같은 의사결정트리를 검증용 표본에 적용하였을 때의 결과는 <표 8>에 제시되어 있다. <표 8>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 예측정확률은 오히려 높다는 것은 주목할만한 사항이다.



[그림 3] 그룹 1(79-84년)에서 도출된 의사결정트리 지식베이스

<표 8> 귀납적 학습방법의 도산예측 실험결과

구분	집중	85-90년	91년	92년	평균예측율
분석					
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)

### 5.4 인공신경망 적용결과

인공신경망의 실험은 MDA에 의하여 선정된 재무비율을 입력층의 투입변수로 사용하는 인공신경망 I과 귀납적 학습방법을 통하여 선정된 재무비율을 투입변수로 사용하는 인공신경망 II로 나누어 실시하였다. 인공신경망 I에서 입력층의 노드에 투입된 변수는 MDA에서 선정된 변수이므로 그룹 1은 <표 4>의 10개의 변수를 처리하기 위하여 10개의 입력층의 처리단위를 가지며 그룹 2는 <표 5>의 18개, 그룹 3은 <표 6>의 17개의 처리단위를 가지게 된다. 은닉층의 처리단위의 수는 의사결정자가 입력층에 투입되는 정보가 어느 정도 고차원적인 정보인가의 판단에 따라 수평적으로 설정하지만 본 연구에서는 입력층의 처리단위와 관계

하였다. 출력층의 처리단위의 수는 2개로 하여 0(비도산)과 1(도산)의 값을 출력층의 처리단위에 부여하였다. 따라서 전체적인 인공신경망의 구성도는 그룹 1은(10(입력층 처리단위)×10(은닉층 처리단위)×2(출력층 처리단위))의 삼층전향층을, 그룹 2는 (18×18×2)의 삼층전향층을, 그룹 3은(17×17×2)의 삼층전향층을 가지게 된다. <표 9>는 인공신경망의 출력결과와 사례중 하나이다. <표 9>를 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. 위와 같은 분류기준에 의한 인공신경망 I의 결과는 <표 10>에 제시되어 있다.

<표 9> 인공신경망 결과의 해석사례

표본 1 : 도산의 예	sample 1 output 0 = <computed : 0.052407>
	sample 1 output 1 = <computed : 0.949991>
표본 2 : 비도산의 예	sample 2 output 0 = <computed : 0.961106>
	sample 2 output 1 = <computed : 0.039653>

<표 10> 인공신경망 I을 이용한 도산예측 실험결과

분석 \ 검증	85-90년	91년	92년	평균예측율
그룹 1	25/30	20/30	25/40	73% (70/100)
그룹 2	-	24/30	32/40	80% (56/70)
그룹 3	-	-	32/40	80% (32/40)

<표 11> 인공신경망 II를 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)

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 11>에 제시되어 있다.

## 5.5 실험결과의 비교 및 해석

이상에서 분석용 기업을 학습자료로 활용하고 검증용 기업을 예측자료로 활용하여 MDA, 귀납적 학습방법, 인공신경망 I, 인공신경망 II에 대한 실험을 수행하여 각 모형의 도산예측 정확성에 대한 결과를 살펴보았다. 그러나, 여기에서 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 따라서 그룹으로 분류하고 각 분석모형의 예측력을 해당 그룹별로 비교하였기 때문에 같은 그룹내에서는 검증표본수는 항상 동일하다. 따라서 분석모형간의 예측력을 비교측정하는 단위를 퍼센트로 하여도 그 결과가 의미하는 통계학적 의미에는 전혀 문제가 없다. 이는 실제로 도산

예측에 관한 기존연구에서도 확인할 수 있는 바이다[30].

한편, 본 연구의 주요목적은 MDA와 인공지능 모형간의 도산예측력 비교에 있지만, 아울러 보다 많은 분석용 표본이 학습되었을때 이 같은 도산예측력이 얼마나 향상되는지를 파악하는 것도 또한 본 연구의 부수적인 연구목적이 된다. 따라서 보다 정교한 도산예측을 위한 전도별 예측, 즉 1년 예측, 5년 예측등과 같은 방법은 사용하지 않았다. 그러나, 설령 이러한 전도별 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 통하여<sup>3)</sup> 각 분석모형에 통합적으로 반영되기 때문에 이를 기초로 검증표본에 대해 수행한 예측은 해당 검증기간에 따라 '1년 예측' 또는 그 이상의 연도별 예측이 될수 있는 것이다.

이러한 개념정립을 기초로 각 모형의 예측력 비교에 관한 비교 및 해석을 정리하면 다음과 같다. <표 12>는 각 모형의 도산예측력을 종합하여 하나의 도표로 제시한 것이다.

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

〈표 12〉 각 모형의 예측력 결과

그 룹	MDA	인공신경망 I	귀납적 학습	인공신경망 II
그룹 1	68%	70%	74%	73%
그룹 2	68.57%	80%	72.86%	81.43%
그룹 3	70%	80%	77.50%	82.5%

본 연구의 목적은 각 분석모형의 예측력을 상호비교하는데 있다. 예측력을 중심으로 각 결과를 비교하여 보면 〈표 12〉에 나타난 것처럼 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

인공신경망 II > 인공신경망 I > 귀납적 학습방법 > MDA

의 순으로 예측력이 우수하다고 할 수 있다. 즉, 인공지능에 기초한 각 모형은 통계적 모형인 MDA에 비하여 예측력이 우수함이 증명되었다. 또한 인공지능에 기초한 모형중에서도 인공신경망을 이용한 모형이 귀납적 학습모형보다 예측력이 우수하다는 사실을 확인하였다. 이러한 결과가 인공지능의 어떠한 특성에 기인하는지 구체적으로 고찰해보자. 본 연구는 미래환경에 대한 각 모형의 적응력을 고찰하기

위하여 각 그룹별 검증용 표본을 분석용 표본의 미래기간에서 추출하였다. 위의 〈표 12〉의 그룹별 예측력 결과는 결과적으로 각 모형의 미래환경에 대한 적응력을 나타낸다고 볼 수 있다. 따라서 각 모형의 미래환경에 대한 적응력은 〈표 12〉에서 나타난 바와 같이 인공신경망 II, 인공신경망 I, 귀납적 학습방법, MDA의 순으로 우수함을 알 수 있다. 이와 같이 인공신경망을 이용하는 모형이 미래환경에 대한 적응력을 가지는 현상을 견고성(robustness)이라고도 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 안정적으로 기업의 도산여부를 예측할 수 있다는 장점이 있다.

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 〈표 12〉의 결과를 중심으로 살펴보고자 한다. 인공신경망 I (70%에서 80%로 증가)과 인공신경

망 II(73%에서 82.5%로 증가)와 같이 인공신경망을 이용하는 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. 결론적으로 미래환경에 대한 적응력과 지식베이스의 일반성이라는 측면으로 보아도 인공신경망 II, 인공신경망 I, 귀납적 학습방법, MDA의 순으로 인공신경망 접근방법이 더 우수함이 확인되었다.

## 6. 결 론

본 연구는 기업 도산예측에 있어서 전통적으로 사용되어 오던 MDA의 방법론적, 통계학적 단점을 극복하고자 인공지능 기법에 기초한 귀납적 학습방법 및 인공신경망 모형을 제시하였다. 이러한 모형의 성과를 검증하기 위하여 MDA, 귀납적 학습, 그리고 인공신경망 방법과 상호비교하고 그 장단점을 고찰하였다.

실증분석의 결과는 인공신경망 모형이 다른 모형에 비하여 높은 예측정확성을 가지고 있고 귀납적 학습방법은 인공신경망 모형보다 낮은 예측정확성을 보이지만 MDA보다는 높은 예측정확성을 가지고 있음을 제시하고 있다. 또한 지식베이스의 일반성측면에서도 인공신경망의 모형을 이용한 인공신경망 II 모형, 인공신경망 I 모형이 높은 학습성과 일반성을 보이고 있다.

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

1) 현재 우리나라에서 발생하는 평균 부도 건수는 일일 평균 18건으로 대다수의 중소기업

업 등이 심각한 경영난을 겪고 있다. 그러나 본 연구는 표본대상기업을 상장기업으로만 한정하였는바, 이는 일반적으로 상장기업은 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 자료수집 대상기간이 장기간인 관계로(79년에서 92년까지) 최근의 질적 자료(예 : 기업어음평가등급, 한국신용평가주식회사의 신용평가 등급등)는 구할 수 있었으나, 과거의 자료는 이미 데이터베이스에서 삭제되어 이러한 질적인 정보를 제대로 활용하지 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, 상장여부별로 세분화된 실험이 요구된다.

2) 인공신경망과 귀납적 학습방법을 통합적으로 적용하면 더 우수한 결과가 예측된다. 이를 위해 저자는 두 모형을 결합한 '귀납적 학습방법 지원 인공신경망 모형(Inductive learning-assisted neural network model)'을 도산예측에 실험적용하고 있으며 그 결과도 예상대로 MDA를 비롯한 기타 모형보다 우수함이 증명되었다. 이에 대한 연구결과도 곧 발표할 예정이다. 그러나 이외에도 인공신경망과 MDA의 통합모형과 같이 기타 다른 모형간의 장단점을 보완할 수 있는 통합

모형도 가능하리라 본다.<sup>1)</sup>

### 참 고 문 헌

[1] 강철승, "부가가치 회계정보의 기업부실예측력에 관한 실증적 연구," 『회계학 연구』, 제12호 (1991년 7월), pp.79-100.

[2] 김선기, 황석하, 김진우, "기업부실화의 원인, 징후 및 예측," 한국신용평가(주), 1986.

[3] 박장길, "우리나라 세부채표의 기업실패 예측능력의 실증적 연구," 박사학위논문, 서울대, 1984.

[4] 정준수, "기업도산 예측 모델에 관한 연구," 박사학위논문, 경북대, 1985.

[5] 『한국기업채무총람』, 1985-1991, 한국신용평가주식회사.

[6] 『기업채무총람』, 1979-1991, 한국상정협의회.

[7] 한인규, "카남직 학습방법과 통계학적 방법의 예측력에 관한 비교연구," 『회계학 연구』, 제11호(1990년 12월), pp.245-267.

[8] 황석하, "기업부실예측에 관한 연구," 『회계학 연구』, 제12호(1991년 7월), pp.57-78.

[9] 『회계연감』, 1979-1991, 매일경제신문.

[10] Altman, E.I., "Financial Ratios, Discriminant Analysis and Prediction of Corporate Bankruptcy," *The Journal of Finance*, Vol. 23 (Sep. 1968), pp. 589-609.

[11] 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), pp.136-146.

[12] 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.

[13] 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), pp.415-429.

[14] Buipink, W. and M. Jegers, "Cross-Sectional Distributional Properties of Financial Ratios in Belgian Manufacturing Industries: Some Empirical Evidence," Technical Report, University of Antwerp, Belgium, 1981.

[15] 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), pp. 1-35.

[16] Collins, R. A. and R. D. Green, "Stat

1) 본 연구를 위해 자료수집과 원고작성을 도와준 김영종 (에게 이 지면을 빌어 감사할 표하는 바이다.

- istical Methods for Bankruptcy Forecasting," *Journal of Economics and Business*, Vol. 32(1982), pp. 349-354.
- [17] Eisenbeis, R. A., "Profits in the Application of Discriminant Analysis in Business, Finance, and Economics," *The Journal of Finance*, Vol.32(1979), pp. 875-900.
- [18] Freeman, J.A. and D.M. Skapura, *Neural Networks: Algorithms, Applications, and Programming Techniques*. Addison-Wesley Publishing Company, 1991.
- [19] Gorman, R.P. and T.J. Sejnowski, "Analysis of Hidden Units in a Layered Network Trained to Classify Sonar Targets," *Neural Networks*, 1(1988), pp.75-89.
- [20] 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.
- [21] Horrigan, J., "The Determination of Long Term Credit Standing with Financial Ratios," *Journal of Accounting Research*(1965), pp.41-68.
- [22] Hunt, E.B., J. Marin, and P.T. Stone, *Experiments in Induction*. Academic Press, New York, 1966.
- [23] 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), pp.403-416.
- [24] Liang, T.P., "A Composite Approach to Inducing Knowledge for Expert Systems Decision," *Management Science*, Vol.38, No.1(Jan 1992), pp.1-17
- [25] Liang, T.P., J.S. Chandler, H. Ingo and J. Roan, "An Empirical Investigation of Some Data Effects on the Classification Accuracy of Probit, ID3 and Neural Networks," Working Paper, University of Illinois at Urbana-Champaign, 1991.
- [26] Lippmann, R., "An Introduction to Computing with Neural Nets," *IEEE ASSP Magazine*(April 1988), pp.4-22.
- [27] Meisser, W.F. and J.V. Hansen, "Inducing Rules for System Development: An Example Using Default and Bankruptcy Data," *Management Science*, Vol.34, No.12 (Dec 1988), pp. 1403-1415.
- [28] 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.
- [29] Quinlan, J.R., "Induction of Decision Trees," *Machine Learning*, Vol.1 (1986), pp.81-106.
- [30] Raghupatihi, W., L.L. Schkade and B.S. Raju, "A Neural Network Application for Bankruptcy Prediction," *IEEE International Joint Conference on Neural Networks*(1991), pp. 147-155.



- [31] Rumelhart, D.E., G.E. Hinton and R.J. Williams, "Learning Internal Representations by Error Propagation," in E. Rumelhart and J.L. McClelland(Eds). *Parallel Distributed Processing:Exploration in the Microstructure of Cognition*. Cambridge, MA:MIT Press, 1986.
- [32] Rumelhart, D. and D. Zipser, "Feature Discovery by Competitive Learning," *Cognitive Science*, Vol.9(1985), pp. 75-112.
- [33] Schlimmer, J.C. and D. Fisher, "A Case Study of Incremental Concept Induction," *Proceedings of the Fifth National Conference on Artificial Intelligence*, 1986, pp.496-501.
- [34] 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.
- [35] Shaw, M.J. and J.A. Gentry, "Inductive Learning for Risk Classification," *IEEE Expert* (Feb 1990), pp.47-53.
- [36] Utgoff, P.E., "ID5: An Incremental ID3," *Proceedings of the Fifth International Conference on Machine Learning*, The University of Michigan at Ann Arbor, 1988, pp.107-120.