

## 통계적 모형과 인공지능 모형을 결합한 기업신용평가 모형에 관한 연구†

이건창\* · 한인구\*\* · 김명종\*\*\*

### A Study on the Credit Evaluation Model Integrating Statistical Model and Artificial Intelligence Model\*

Kun Chang Lee\* · In Goo Han\*\* · Myoung Jong Kim\*\*\*

#### Abstract

본 연구에서는 보다 효과적인 기업신용평가를 위하여, 통계적 방법과 인공지능 방법을 결합한 결합모형을 제시하고자 한다. 이를 위하여 본 연구에서는 통계적인 모형중에서 가장 널리 활용되고 있는 MDA (Multivariate Discriminant Analysis)와 인공지능적인 방법으로서 최근에 널리 사용되고 있는 인공신경망 (neural network)모형을 휴리스틱한 방법으로 결합한다. 이러한 결합모형의 성과를 증명하기 위하여 우리나라의 대표적인 3대 기업신용평가 기관에서 수집한 1043개의 기업신용평가 자료를 기초로 실험을 하고, 그 결과를 기존의 MDA 및 인공신경망 방법에 의한 결과와 비교하였다. 실험결과, 통계적으로도 유의하고, 실무적인 관점에서도 의미가 있는 기업신용평가 결과를 유도할 수 있었다.

## 1. 서 론

### 1. 1 배경

기업의 신용을 합리적이고 객관적으로 평가하여 그 결과를 해당 투자자들에게 공개하는 것은 금융시장의 건전한 발전을 위하여 반드시 필요

한 과정이다. 따라서 각 나라마다 기업의 신용평가를 위한 전문기관이 존재하기 마련이다. 우리나라의 경우 한국신용정보(주), 한국신용평가(주), 한국기업평가(주) 등이 기업신용평가 전문기관이다. 이러한 기업신용평가 전문회사의 신용평가결과는 해당기업의 유가증권발행 또는 금융기관의 여신결정에서 대출여부 및 금리 등의 조건을 결정하는데 중요한 근거가 된다. 더

† 이 논문은 1994년도 한국학술진흥재단의 공모과제 연구비에 의하여 연구되었음.

\* 성균관대학교 경영학부 교수

\*\* 한국과학기술원 테크노 경영대학원 부교수

\*\*\* 한국과학기술원 테크노 경영대학원 경영공학 전공 박사과정

육이 금융시장이 개방되면서 국내 신용평가결과를 이용하여 국제금융시장에서 금융자본을 조달할 수 있을 수도 있다.

지금까지 국내외 기업신용평가 전문회사들은 기업도산 및 신용평가를 위해 MDA, 회귀분석, 프로비트 (probit), 로지트 (logit) 등의 통계적 기법들을 전통적으로 활용하여 왔다(Horrigan, 1966; Ang & Patel, 1975; Pinches & Mingo, 1975; Altman & Katz, 1976; Eisenbeis, 1977; Kaplan & Urwitz, 1979). 그러나, 1980년대 후반부터 귀납적 학습방법, 인공신경망 모형등의 인공지능적인 방법들이 기업도산 및 신용평가에 활용되면서 인공지능적인 방법들의 우수성이 인정받기에 이르렀다(이건창, 1993; 이진창 등, 1994ab; 조홍규, 1994; 한인구, 1990; 한인구 등, 1995ab; Dutta & Shekhar, 1988; Odom & Sharda, 1990; Surkan & Singleton, 1990; Tam & Kiang, 1992; Liang et al., 1992; Lee et al, 1994; Lee, 1996; Kwon et al., 1996).

본 연구에서는 이러한 최근 연구동향에 착안하여 기존의 통계학적인 방법과 인공지능적인 방법을 결합한 새로운 형태의 기업신용평가 방법을 제안하고자 한다. 이는 통계학적인 MDA 모형과 인공지능방법인 인공신경망 모형을 휴리스틱하게 결합한 결합모형이다. MDA는 독립변수간에 정규분포를 가정하고, 이러한 통계적 가정이 만족되었을때에만 그 결과를 신뢰할 수 있다. 따라서 이러한 통계적 가정이 만족되지 않는다면 그 결과 또한 상당한 오류를 포함하고 있다고 간주하여야 할 것이다. 이와같은 MDA의 문제점을 해결하기 위하여 제안된 방법으로는 반복적 분할법(Recursive Partitioning Algorithm), 로지트, 프로비트 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(machine learning) 이론 중의 하나이기 때문에 특정 통계적 가정을 전제하지 않는다. 따라서 이와같은 서로 상반된 특징을 갖는 MDA와 인공신경망 모형을 휴리스틱하게 결합하여 기업신용평가를 시도하므로써, 각각의 모형만을 사용하는 기존의 방법보다 더 우수한 결과를 제시하고자 한다. 이러한 결합모형의 성과를 검증하기 위하여, 한국신용정보(주), 한국신용평가(주), 한국기업평가(주) 등 3개 기업신용평가 전문기관에서 제시된 1000여개의 자료를 기초로 실험하였다.

## 1. 2. 기존연구

본 연구에서 대상으로 하는 기업신용평가 문제는 기업도산예측, 대출승인결정과 같은 2-그룹 분류 문제와 달리, 다중그룹(multi-group) 분류 문제이며, 따라서 그만큼 고도로 숙련된 신용평가 전문가들의 지식이 요구된다. 통계분야와 인공지능 분야에서 이러한 기업신용평가 문제를 효과적으로 해결하기 위한 많은 연구가 소개되었다. 이러한 방법들은 대개 정량적 분석방법들로 구성되어 있으나, 초기에는 회귀분석, MDA, 프로비트, 로지트 모형과 같은 통계적 방법들이 널리 이용되었으나 (Horrigan, 1966; Ang & Patel, 1975; Pinches & Mingo, 1975; Altman & Katz, 1976; Kaplan & Urwitz, 1979; Martin et al., 1984), 최근에는 인공신경망, ID3, CART (Classification

And Regression Tree), 유전자 알고리즘(genetic algorithm) 등과 같은 방법들이 활발하게 사용되고 있다 (Dutta & Shekhar, 1988; Surkan & Singleton, 1990; Kim, 1992; Salchenberger et al., 1992; Subramanian et al., 1993; 한인구 등, 1995b; Kwon et al., 1996). 이같은 기존연구들은, 통계적 방법이나 기타 ID3, CART, 유전자 알고리즘과 같은 방법보다 인공지능경망에 의한 기업신용평가의 예측률이 더 정확함을 보여주고 있다. 특히 한인구 등(1995b)의 논문에서는 본 연구에서 적용한 동일한 인공지능경망 모형을 이용한 실험결과를 제시하였는바, 특히 기업신용평가와 같은 다중그룹 분류문제에 대한 인공지능경망의 판별력을 향상시키기 위한 새로운 학습방법인 OPP (Ordinal Pairwise Partitioning)방법을 제안하였다. 본 연구에서는 이와같은 한인구 (1995b)의 연구방법을 따르되, 단순히 MDA와 인공지능경망의 결과를 비교하는 진부한 연구방법을 지양하고, 이 두 대표적인 방법을 결합하였을때 해당 모형의 판별력이 보다 향상됨을 보이고자 한다. 따라서 본 연구는 한인구 등(1995b)에서 사용한 기업신용평가 자료를 사용하여 그 실험

결과를 제시하고자 한다.

## 2. 연구자료 및 재무변수의 선택

본 연구에서는 한국신용정보, 한국신용평가 및 한국기업평가 등 3개사의 1991년 및 1992년의 신용평가자료에 해당된 기업을 표본으로 하였다. 이들 각 신용평가 회사별로 2년간 실시한 신용평가 결과를 요약하면 <표 1>에서 <표 4>와 같다. 각 표에서 사용한 신용등급 1,2,3,4, 5 등급은 각각 A<sup>+</sup>, A<sup>+</sup>, B, C, D등급을 의미한다. 본 연구에서는 <표 1,2,3>에 제시된 3개 신용평가회사의 자료를 기초로 하여 실험을 위한 전체자료를 <표 4>와 같이 구축하였다. 특히 자료의 중복성에 관하여 언급하면, 1995년부터 복수 신용평가제가 도입되어서 한 개의 기업을 두개의 신용평가기관이 심사한다. 따라서 1995년 이전에는 한 개의 기업은 한 개의 신용평가기관에 의해서만 평가가 되기 때문에 <표 1,2,3>에는 동일기업이 중복되어 있지 않다.

<표 1> 한국신용정보의 신용평가통계

| 등 급 | 1991년 | 비율      | 1992년 | 비율      | 합계  | 비율      |
|-----|-------|---------|-------|---------|-----|---------|
| 1   | 12    | 3.34%   | 12    | 3.54%   | 24  | 3.44%   |
| 2   | 62    | 17.27%  | 57    | 16.81%  | 119 | 17.05%  |
| 3   | 100   | 27.86%  | 90    | 26.55%  | 190 | 27.22%  |
| 4   | 136   | 37.88%  | 136   | 40.12%  | 272 | 38.97%  |
| 5   | 49    | 13.65%  | 44    | 12.98%  | 93  | 13.32%  |
| 합 계 | 359   | 100.00% | 339   | 100.00% | 698 | 100.00% |

〈표 2〉 한국신용평가의 신용평가통계

| 등 급 | 1991년 | 비율      | 1992년 | 비율      | 합계   | 비율      |
|-----|-------|---------|-------|---------|------|---------|
| 1   | 15    | 2.36%   | 17    | 3.48%   | 32   | 2.84%   |
| 2   | 81    | 12.74   | 69    | 14.11%  | 150  | 13.33%  |
| 3   | 179   | 28.14%  | 151   | 30.88%  | 330  | 29.33%  |
| 4   | 277   | 43.55%  | 221   | 45.19%  | 498  | 44.27%  |
| 5   | 84    | 13.21%  | 31    | 6.34%   | 115  | 10.23%  |
| 합 계 | 636   | 100.00% | 489   | 100.00% | 1125 | 100.00% |

〈표 3〉 한국기업평가의 신용평가통계

| 등 급 | 1991년 | 비율      | 1992년 | 비율      | 합계  | 비율      |
|-----|-------|---------|-------|---------|-----|---------|
| 1   | 22    | 9.48%   | 23    | 8.30%   | 45  | 8.84%   |
| 2   | 64    | 27.59%  | 69    | 24.91%  | 133 | 26.13%  |
| 3   | 62    | 26.72%  | 92    | 33.21%  | 154 | 30.26%  |
| 4   | 69    | 29.74%  | 74    | 26.71%  | 143 | 28.09%  |
| 5   | 15    | 6.47%   | 19    | 6.86%   | 34  | 6.68%   |
| 합 계 | 232   | 100.00% | 277   | 100.00% | 509 | 100.00% |

〈표 4〉 전체 신용평가 통계

| 등 급 | 1991년 | 비율      | 1992년 | 비율      | 합계   | 비율      |
|-----|-------|---------|-------|---------|------|---------|
| 1   | 49    | 3.99%   | 52    | 4.71%   | 101  | 4.33%   |
| 2   | 207   | 16.87%  | 195   | 17.65%  | 402  | 17.24%  |
| 3   | 341   | 27.79%  | 333   | 30.14%  | 674  | 28.90%  |
| 4   | 482   | 39.28%  | 431   | 39.00%  | 913  | 39.15%  |
| 5   | 148   | 12.06%  | 94    | 8.51%   | 242  | 10.38%  |
| 합 계 | 1227  | 100.00% | 1105  | 100.00% | 2332 | 100.00% |

그러나 이러한 전체신용평가 자료중에는 일부 재무변수의 값이 누락되어 있는 경우가 있기 때문에 이를 제거하여 실험에 적합한 형태로 다시 정리하였다. 이와같이 하여 최종적으로

본 연구를 위하여 선정된 기업신용평가 자료는 <표 5>와 같다. 결국 <표 5>는 <표 4>의 자료중 자료가 충분치 못한 재무변수가 있는 표본을 제외한 자료이다.

<표 5> 신용등급별 기업의 수

| 신용등급 | 1991년 |         | 1992년 |         |
|------|-------|---------|-------|---------|
|      | 기업 수  | 비율      | 기업 수  | 비율      |
| 1    | 47    | 4.15%   | 50    | 4.79%   |
| 2    | 198   | 17.49%  | 188   | 18.02%  |
| 3    | 322   | 28.45%  | 318   | 30.49%  |
| 4    | 444   | 39.22%  | 409   | 39.21%  |
| 5    | 121   | 10.67%  | 78    | 7.48%   |
| 합 계  | 1132  | 100.00% | 1043  | 100.00% |

기업신용평가 요인은 재무제표로부터 추출되는 재무변수와 기업의 형태, 산업 및 환경요인 등의 비재무변수로 나누어 볼 수 있다. 본 연구에서는 비록 계량적인 재무변수를 중심으로 하여 분석을 하였으나, 비재무변수가 가지는 추가적인 정보특성을 반영하기 위하여 측정가능한 비재무변수를 추가하여 분석한다. 분석대상이 되는 재무변수는 성장성, 규모, 수익성, 안전성, 활동성, 생산성, 현금흐름 지표 등 7개의 지표군으로 구분하여 총 128개 변수를 사용하였다 (변수에 대한 자세한 내용은 한인구 등 (1995b)의 논문을 참조할 것). 각 지표별 재무변수의 갯수를 정리하면 다음과 같다.

- 성장성지표 : 9 개
- 규모지표 : 14 개
- 수익성지표(수익/자본) : 18 개

- 수익성지표(비용/수익) : 12 개
- 수익성지표(비용구조) : 13 개
- 안전성지표 : 20 개
- 활동성지표 : 14 개
- 생산성지표 : 18 개
- 현금흐름지표 : 10 개

적정한 변수를 선택하기 위하여 기존의 문헌을 검토하고 Standard & Poors (1980, 1986), 일본의 금융기관, 국내 금융기관의 신용평가체제를 분석하고 신용평가 전문가와의 면담을 실시하였다. 여기에 포함된 변수는 신용평가연구에서 의미있는 것으로 나타난 변수, 주요 금융기관의 신용평가표에서 사용되는 변수 등 중요한 재무변수를 대부분 포함하고 있다. 본 연구에서 사용된 재무변수는 <표 6>에 정리되어 있다. 기업신용평가를 위하여 적정한 재무변수를

선택할 때에는 신용평가의 정확성만 고려할 것이 아니라, 일부 재무변수간의 다중공선성(multicollinearity) 문제도 고려하여야 한다. 상관관계가 매우 높은 두개 이상의 변수를 신용평가모형에 사용하는 것은 신용평가의 정확성에 부정적인 영향을 줄 가능성이 매우 높기 때문이다. 신용평가모형은 기업의 신용도를 다각적인 측면에서 평가할 수 있는 다양한 재무변수를 포함하는 것이 바람직하다. 따라서 신용평가에 포함되는 재무변수들은 서로 중복되지 않으며 각 기업의 특정한 성격을 측정할 수 있도록 설계되어야 한다.

많은 재무변수를 동시에 고려할 때 흔히 발생하는 다중공선성문제를 해결하고, 신용평가모형을 구축하기 위한 재무변수 선정기법으로는 단계적 MDA (Stepwise MDA)와 요인분석(Factor Analysis)이 있다. 단계적 MDA는 신용평가모형 수립시 고려대상이 되는 각 재무변수의 판별력에 의하여 순차적으로 재무변수를 선택하여 나가는 방법이다. 요인분석이란 재무변수들을 상호간에 상관관계가 높은 유사한 성격의 요인으로 분류하고 각 요인을 대표할 수 있는 재무변수들을 하나씩 선정하여 소수의 변수로 전체 변수를 설명할 수 있도록 하는 방법이다. 요인분석은 종속변수를 고려하지 않고 독립변수(여기에서는 재무변수)간의 유사성을 판별하게 되므로 종속변수인 신용평가결과가 재무변수의 선정에 영향을 미치지 않게 된다. 단계적 MDA는 종속변수(즉, 신용평가등급)에 대한 판별력에 의하여 독립변수(즉, 재무변수)를 선정하는 기법이므로 신용평가결과가 직접적으로 독립변수의 선정에 관련된다. 본 연구에서는 단계적 MDA를 이용하여 총 128개의 재무변수중에서 종속변수(즉, 신용평가등급)에 대한 판별력이 높은 24개의 재무변수를 선택하

였다. 이중 업력(業歷)과 기업형태 등 2개의 변수가 비재무변수이며 나머지 22개는 재무변수이다. 따라서 본 연구에서 사용되는 24개의 재무변수안에는 이같은 비재무변수가 포함되어 있으나, 논문기술의 편의를 위하여 통상적으로 '24개의 재무변수'라는 용어를 그대로 사용하기로 한다. 단계적 MDA에 의하면 년도별, 그리고 신용평가회사별로 다소 상이한 변수선택 결과를 보여주고 있다. 단계적 MDA에 의한 재무변수 선택결과는 <표 6>과 같으며, 각 판별함수에 있어서 해당변수의 중요성을 나타내는 표준화된 정준계수는 <표 7-1>와 <표 7-2>에 정리되어 있다. 판별함수 1은 1등급과 2등급을 판별하는 함수이며, 판별함수 2는 2등급과 3등급을 판별하는 함수, 판별함수 3은 3등급과 4등급을 판별하는 함수, 그리고 판별함수 4는 4등급과 5등급을 판별하는 함수이다. <표 7-1>의 91년 자료에 의한 24개 변수의 표준화된 정준계수를 보면, 판별함수 1에서는 부가가치 변수가 가장 중요성을 가지며, 판별함수 2에서는 총차입금, 판별함수 3에서는 감가상각비, 판별함수 4에서는 매출액총이익율 변수가 가장 중요한 변수임을 알 수 있다.

한편, 본 연구에서는 <표 6>의 24개 변수외에, 신용등급간 판별력을 높여 줄 수 있을 것으로 예상되는 산업코드와 그룹관계(그룹코드)변수를 추가하여 총 26개의 변수를 사용하였다. 이들 변수는 <표 8>에 정리되어 있다. 산업코드는 ①농수산, ②음식료, ③섬유, ④목재/가구, ⑤화학/비금속광물, ⑥철강/금속, ⑦기계/전자/자동차, ⑧건설, ⑨도소매/숙박/운수, ⑩서비스 등 10가지로 구분하였고, 그룹코드는 5대 그룹, 10대 그룹, 30대 그룹, 기타그룹, 비그룹으로 나누었다.

〈표 6〉 단계적 MDA에 의하여 선정된 24개 재무변수

|  |
|--|
| (1) 규모지표<br>유형고정자산, 자기자본, 부가가치, 업력, 기업형태, 총차입금, 총수익, 감가상각비             |
| (2) 수익성지표<br>총자산 사업이익율, 유보액/총자산, 매출액총이익율, 금융비용/부채, 금융비용/총비용, 감가상각비/총비용 |
| (3) 안전성지표<br>고정자산 구성율, 차입금 의존도, 재고자산/유동자산, 단기차입금/총차입금                  |
| (4) 현금흐름지표<br>현금흐름/총부채, 현금흐름/고정부채, 현금흐름/총자산, 부채상환계수                    |
| (5) 생산성지표<br>총자산투자효율, 1인당 매출액  |

〈표 7-1〉 91년 자료에 의한 24개 변수의 표준화된 정준계수

| 변수번호 | 변수이름       | 판별합수 1  | 판별합수 2   | 판별합수 3  | 판별합수 4  |
|------|------------|---------|----------|---------|---------|
| 1    | 유형고정자산     | .27535  | .13131   | .23131  | -.18670 |
| 2    | 자기자본       | .18387  | .35528   | .27137  | -.64860 |
| 3    | 부가가치       | .63943  | .46842   | -.60629 | .14010  |
| 4    | 업력         | .18435  | .03067   | -.02913 | -.23523 |
| 5    | 기업형태       | -.43415 | .09394   | .43920  | -.07831 |
| 6    | 총차입금       | -.34061 | -1.19612 | -.88814 | .35745  |
| 7    | 총수익        | .11702  | .48925   | .36578  | .09018  |
| 8    | 감가상각비      | -.43163 | .33572   | 1.08724 | .25307  |
| 9    | 총자산사업이익율   | .32393  | -.12127  | -.30895 | -.29052 |
| 10   | 유보액/총자산    | .06037  | .04001   | -.05302 | -.25757 |
| 11   | 매출액총이익률    | .08478  | .02983   | .08350  | .89303  |
| 12   | 금융비용/부채    | -.11369 | -.28670  | .50828  | .15492  |
| 13   | 금융비용/총비용   | -.24506 | .26114   | -.14654 | .10132  |
| 14   | 감가상각비/총비용  | .14891  | .05072   | -.10729 | -.11216 |
| 15   | 고정자산 구성률   | .16740  | .06273   | -.06982 | .01173  |
| 16   | 차입금 의존도    | -.34068 | .60259   | -.21474 | -.13270 |
| 17   | 재고자산/유동자산  | -.14694 | .09124   | -.22927 | -.01745 |
| 18   | 단기차입금/총차입금 | -.07984 | .24932   | .03506  | -.14414 |
| 19   | 현금흐름/총부채   | .60519  | .70448   | -.52207 | .45816  |
| 20   | 현금흐름/고정부채  | -.20926 | .42506   | -.19611 | .22415  |
| 21   | 현금흐름/총자산   | -.22265 | -.96408  | .90052  | -.35084 |
| 22   | 부채상환계수     | .03624  | .40972   | -.12875 | -.10002 |
| 23   | 총자산투자효율    | -.13234 | .00457   | -.19662 | .28980  |
| 24   | 1인당 매출액    | .09308  | .00655   | .02923  | .32850  |

〈표 7-2〉 92년 자료에 의한 24개 변수의 표준화된 정준계수

| 변수번호 | 변수이름         | 판별함수 1  | 판별함수 2   | 판별함수 3   | 판별함수 4   |
|------|--------------|---------|----------|----------|----------|
| 1    | 유형고정자산       | .24700  | .19921   | .10816   | -.52028  |
| 2    | 자기자본         | .47791  | .87042   | .18551   | -.14798  |
| 3    | 부가가치         | .82088  | .83822   | -.07592  | -.44865  |
| 4    | 업력           | .15925  | -.11348  | .06478   | .23296   |
| 5    | 기업형태         | -.43574 | .10946   | .45196   | -.23598  |
| 6    | 총차입금         | -.85762 | -2.14142 | -.56008  | .46105   |
| 7    | 총수익          | .08075  | .48830   | -.03012  | -.28112  |
| 8    | 감가상각비        | -.30775 | .37069   | .71245   | .79178   |
| 9    | 총자본사업이익률     | .23630  | -.07058  | -.24424  | .07444   |
| 10   | 유보액 / 총자산    | .07144  | -.04603  | .15944   | -.22367  |
| 11   | 매출액총이익률      | .14246  | -.04932  | .23724   | .27232   |
| 12   | 금융비용 / 부채    | -.12681 | -.29650  | .48964   | -.35025  |
| 13   | 금융비용 / 총비용   | -.27507 | .40525   | -.42328  | .33099   |
| 14   | 감가상각비 / 총비용  | .21702  | .05134   | .06267   | -.26201  |
| 15   | 고정자산 구성률     | .10389  | .01863   | -.09441  | .42699   |
| 16   | 차입금 의존도      | -.23771 | .41963   | .00345   | -.17219  |
| 17   | 채고자산 / 유동자산  | -.13077 | .00016   | -.16120  | .20664   |
| 18   | 단기차입금 / 총차입금 | -.05759 | .24695   | -.12582  | -.05442  |
| 19   | 현금흐름 / 총부채   | .79921  | .34108   | -1.07456 | -1.29481 |
| 20   | 현금흐름 / 고정부채  | -.10250 | .18236   | -.01150  | -.44236  |
| 21   | 현금흐름 / 총자본   | -.47058 | -.64828  | 1.03561  | .84112   |
| 22   | 부채상환계수       | .01841  | .17822   | .05097   | .54240   |
| 23   | 총자본투자효율      | -.19814 | .02384   | -.08693  | .39511   |
| 24   | 1인당 매출액      | .10812  | -.04077  | .26510   | .39839   |



〈표 8〉 본 연구의 실험에서 사용된 총 26개 변수

| 변수번호 | 변수이름       | 변수코드 | 변수번호 | 변수이름         | 변수코드      |
|------|------------|------|------|--------------|-----------|
| 1    | 유형고정자산     | V12  | 14   | 감가상각비 / 총비용  | V65       |
| 2    | 자기자본       | V13  | 15   | 고정자산구성률      | V72       |
| 3    | 부가가치       | V16  | 16   | 차입금의존도       | V74       |
| 4    | 업력         | V18  | 17   | 재고자산 / 유동자산  | V80       |
| 5    | 기업형태       | V19  | 18   | 단기차입금 / 총차입금 | V84       |
| 6    | 총차입금       | V20  | 19   | 현금흐름 / 총부채   | V101      |
| 7    | 총수익        | V21  | 20   | 현금흐름 / 고정부채  | V102      |
| 8    | 감가상각비      | V23  | 21   | 현금흐름 / 총자본   | V104      |
| 9    | 총자본사업이익률   | V26  | 22   | 부채상환계수       | V106      |
| 10   | 유보액 / 총자산  | V41  | 23   | 총자본투자효율      | V117      |
| 11   | 매출액총이익률    | V42  | 24   | 1인당 매출액      | V126      |
| 12   | 금융비용 / 부채  | V55  | 25   | 산업코드         | IND. CODE |
| 13   | 금융비용 / 총비용 | V56  | 26   | 그룹코드         | GROUPCOD  |

### 3. MDA 및 인공지능망에 의한 실험

#### 3. 1 MDA에 의한 실험

MDA에 의한 예측력을 검증하기 위하여 년도별로 실험을 실시하였다. 1991년 자료를 이용하여 분류하고 1992년 자료를 이용하여 예측하였다. 우선 25번 변수(산업코드)와 26번 (그룹코드)를 제외한 24개의 변수를 이용하여 실험한 결과는 〈표 9〉와 같다.

25번 변수(산업코드)와 26번 (그룹코드)를

포함하여 26개의 변수를 이용한 실험한 결과는 〈표 10〉과 같다.

24개 변수를 이용하여 MDA실험을 한 결과는 전체적으로 61.65%의 예측력을 보인 반면에, 26개 변수로 실험한 결과는 62.3%로서 약간의 향상을 보이고 있다. 이를 각 신용등급별로 보면, 2등급을 제외하고 나머지 모든 등급에서 24개 변수를 이용할 때보다 26개 변수를 이용할 때에 예측률이 약간씩 향상함을 알 수 있다. 각 신용평가회사별로 MDA실험을 했을 때의 결과는 한국신용정보(주)의 경우 분류는 66.57% 예측은 56.93%, 한국신용평가(주)의 경우 분류는 66.98% 예측은 61.35%, 그리고 한

〈표 9〉 24개 변수를 이용한 MDA 실험결과

| 신용등급 | 자료총수 | 예측자료  |        |
|------|------|-------|--------|
|      |      | 예 측 수 | 예측률(%) |
| 1    | 50   | 20    | 40     |
| 2    | 188  | 114   | 60.6   |
| 3    | 318  | 173   | 54.4   |
| 4    | 409  | 277   | 67.7   |
| 5    | 78   | 59    | 75.6   |
| 합 계  | 1043 | 643   | 61.65% |

〈표 10〉 26개 변수를 이용한 MDA 실험결과

| 신용등급 | 자료총수 | 예측자료  |        |
|------|------|-------|--------|
|      |      | 예 측 수 | 예측률(%) |
| 1    | 50   | 21    | 42     |
| 2    | 188  | 109   | 58.0   |
| 3    | 318  | 172   | 54.1   |
| 4    | 409  | 288   | 70.49  |
| 5    | 78   | 60    | 76.9   |
| 합 계  | 1043 | 650   | 62.3%  |

국기업평가(주)의 경우 분류는 58.62% 예측은 55.60%이다. 결국 〈표 5〉에서와 같은 전체자료를 이용하여 신용평가를 했을 때가 각 신용평가회사의 자료로 신용평가 했을 때보다 예측률이 상승하는 바, 그 이유는 전체자료의 경우는 표본의 수가 많아짐에 따라 분류시에 평가모형이 보다 일반성을 가져서 예측의 정확성이 다소 높아지기 때문이다.

한편, 본 연구에서는 기존의 신용평가에서 흔히 해오는 평가방법과는 달리, 각 신용등급별로 이분법적으로 분석을 행하여 신용평가의 예측력을 높히는 방법을 시도하였다 (Kwon et al., 1996). 즉, 실무적으로 볼때에 기업신용평가와 같이 다중그룹 분류문제는 2-그룹 분류문제(예를 들어 기업도산 예측문제)와 비교하여 여러 판별함수가 나타나고 여러 판별점이 존재

하므로 분류의 정확성이 감소하게 된다는 문제점이 존재한다. 본 연구에서는 기업신용평가 문제와 같이 다중그룹 분류의 어려움을 개선하고자 새로운 학습방법인 OPP(Ordinal Pairwise Partitioning)방법을 사용한다(Kwon et al., 1996). 본 연구에서 소개되는 OPP방법에 의한 실험결과는 다른 학습방법과는 달리 분류 및 예측의 정확성이 향상됨이 입증되었다. OPP방법은 전향적 방법(forward method)과 후향적 방법(backward method)으로 양분되는데, OPP방법은 다음과 같은 절차로 학습이 진행된다. 기업신용평가 자료는 신용등급별로 다중그룹으로 나누어지게 됨에 따라 재무자료의 특성치가 불분명하여지는 어려움을 해결하기 위하여, 1등급과 기타등급(2, 3, 4, 5 등급), 2등급과 기타등급(3, 4, 5등급), 3등급과 기타등급(4, 5등급), 4등급과 5등급의 양등급으로 구분하여 다음과 같이 4단계로 학습절차를 수행한다.

1단계: 1등급으로 판명된 자료는 1등급으로 인식하고, 기타등급으로 인식된 경우에는 2단계로 넘긴다.

2단계: 1단계에서 넘어온 자료가 2등급으로 판명되면 2등급으로 인식하고, 기타등급으로 인식된 경우는 3단계로 넘긴다.

3단계: 2단계에서 넘어온 자료가 3등급으로 판명되면 3등급으로 인식하고, 기타등급으로 인식된 경우는 4단계로 넘긴다.

4단계: 3단계에서 넘어온 자료가 4등급으로 판명되면 4등급으로 인식하고, 5등급으로 인식된 경우는 5 등급으로 인식한다.

반면에 후향적 OPP방법은 전향적 OPP방법과는 달리, 1단계에서는 5등급과 나머지 등급을 구분하고, 2단계에서는 4등급과 나머지 3,2,1 등급을 구분한다. 또한, 3단계에서는 3등급과 1등급을 구분하고, 4단계에서는 2등과 1등급을 구분하는 것으로 구성된다. 실험결과 후향적 OPP방법과 전향적 OPP방법간의 예측률 차이는 통계적으로 거의 없는 것으로 밝혀졌다(Kwon et al., 1996). 본 연구에서는 전향적 OPP방법으로 학습하여 예측하였으며, 사용 소프트웨어는 윈도우용 SPSS를 사용하였다. 그 결과는 <표 11>과 같다.

<표 11> 전향적 OPP방법을 이용한 MDA실험결과

| 신용등급 | 자료총수 | MDA:24 |        | MDA:26 |        |
|------|------|--------|--------|--------|--------|
|      |      | 예측수    | 예측률(%) | 예측수    | 예측률(%) |
| 1    | 50   | 26     | 52     | 26     | 52     |
| 2    | 188  | 147    | 78.2   | 147    | 78.2   |
| 3    | 318  | 232    | 73.0   | 235    | 73.9   |
| 4    | 409  | 343    | 83.9   | 345    | 84.4   |
| 5    | 78   | 61     | 78.2   | 63     | 80.8   |
| 합계   | 1043 | 809    | 77.56% | 816    | 78.2%  |

〈표 11〉에서 MDA:24와 MDA:26은 각각 24개 변수를 이용한 MDA 실험결과, 26개 변수를 이용한 MDA 실험결과를 의미한다. 그러나, 본 연구에서는 26개 변수를 이용하여 인공신경망 실험을 하였고, 또한 실제로 MDA 실험결과중 가장 높은 예측률을 나타내는 것이 MDA:26이기 때문에, 이후부터는 MDA:26의 결과로 벤치마킹(benchmarking)한다. 따라서, 이후 인공신경망의 실험과정에서는 26개의 변수를 적용한 실험결과를 소개한다.

### 3. 2 인공신경망에 의한 실험

인공신경망은 입력층, 은닉층, 출력층으로 구성된 세개의 layer를 가진 모형으로 실험하였다. 학습 알고리즘은 가장 널리 사용되는 감독 학습 알고리즘인 역전파 학습 (backpropagation learning) 알고리즘 (Rumelhart et al., 1986)을 사용하였다. 한편, 인공신경망 실험을 위해 Categorical 변수는 다중입력(multiple input)형태로 바꾸어 주어야 한다. 이에 따라, 기업형태를 상장법인(1 0 0), 등록법인(0 1 0), 외감법대상법인(0 0 1)로 변환하였고, 산업코드는 ①농수산, ②음식료, ③섬유, ④목재/가구, ⑤화학/비금속광물, ⑥철강/금속, ⑦기계/전자/자동차, ⑧건설, ⑨도소매/숙박/운수, ⑩서비스 등 10가지로 구분하였다. 예를 들면 음식료업은 (0 1 0 0 0 0 0 0 0)으로 나타난다. 그룹코드는 그룹크기순으로 5대 그룹은 (1 0 0 0 0), 10대 그룹은 (0 1 0 0 0), 30대 그룹은 (0 0 1 0 0), 기타그룹은 (0 0 0 1 0), 비그룹은 (0 0 0 0 1)으로 표시된다. 한편, 업력은 기업이 창업된 이후의 연도를 나타내는 실수이기 때문에 해당값을 그대로 사용하되, 이후에서 언급하는 전처리(pre-proc-

essing) 과정을 거쳐서 입력하였다. 이와같이 입력자료를 표현하게 됨에 따라 입력층은 41개의 뉴런(neuron)을 가지며, 은닉층은 20개, 출력층은 2개의 뉴런을 갖도록 구성하였다. 인공신경망 실험의 경우도 MDA실험에서 적용하였던 전향적 OPP방법을 적용하였다. 출력층의 뉴런이 2개인 것은 전향적 OPP방법을 적용하기 때문이다. 그러나, 기존의 전통적 인공신경망 방법에서는 5개의 신용등급을 전부 출력층 뉴런수로 하기 때문에 5개의 출력층 뉴런수를 사용한다. 본 연구에서는 결합모형에 의한 성과를 보다 면밀하게 해석하기 위하여, 전통적 인공신경망 방법에 의한 실험결과와 전향적 OPP방법을 이용한 인공신경망 실험결과를 모두 제시한다. 한편, 입력자료는 ((최대값-변수값)/최대값)의 공식을 통하여 전처리 과정을 거치게 하였다. 은닉층 및 출력층의 전이함수(transfer function)는 sigmoid함수를 사용하였다. 학습기준은 50000번의 반복과정과 시스템 에러율을 0.01이 되도록 하였고, 사용 소프트웨어는 Neuro Shell 2를 이용하였다.

전통적 인공신경망에 의한 실험결과와 전향적 OPP방법에 의한 인공신경망 실험결과가 각각 〈표 12-1〉과 〈표 12-2〉에 요약되어 있다. 전통적 인공신경망의 경우 67.2%의 예측률을 나타내고 있고, 전향적 OPP방법에 의한 인공신경망 실험결과는 82.17%의 결과를 보이고 있다. 따라서 전향적 OPP방법에 의한 인공신경망의 예측률이 전통적 인공신경망의 예측률보다 훨씬 높다는 것을 알 수 있다. 한편, 〈표 12-2〉에 나타나 있는 입력층 뉴런수, 은닉층 뉴런수, 출력층 뉴런수는 인공신경망 실험을 위하여 전향적 OPP방법의 각 단계별로 적용된 인공신경망 모형의 구조를 나타내는 것이다.

〈표 12-1〉 전통적 인공신경망 실험결과

| 신용등급 | 자료총수 | 인공신경망 |        |
|------|------|-------|--------|
|      |      | 예측수   | 예측률(%) |
| 1    | 50   | 38    | 76     |
| 2    | 188  | 105   | 55.9   |
| 3    | 318  | 202   | 63.5   |
| 4    | 409  | 300   | 73.3   |
| 5    | 78   | 56    | 71.8   |
| 합계   | 1043 | 838   | 67.2%  |

〈표 12-2〉 전향적 OPP방법을 이용한 인공신경망 실험결과

| 신용등급 | 입력층<br>뉴런수 | 은닉층<br>뉴런수 | 출력층<br>뉴런수 | 자료총수 | 인공신경망 |        |
|------|------------|------------|------------|------|-------|--------|
|      |            |            |            |      | 예측수   | 예측률(%) |
| 1    | 41         | 35         | 2          | 50   | 36    | 72     |
| 2    | 41         | 35         | 2          | 188  | 130   | 69.15  |
| 3    | 41         | 30         | 2          | 318  | 249   | 78.30  |
| 4    | 41         | 40         | 2          | 409  | 392   | 95.84  |
| 5    | 41         | 40         | 2          | 78   | 50    | 64.10  |
| 합계   |            |            |            | 1043 | 857   | 82.17% |

3. 3 비교

이상의 MDA결과와 인공신경망에 의한 실험결과를 정리하면 〈표 13〉과 같다.

〈표 13〉 MDA와 인공신경망에 의한 실험결과 비교

| 모형            | 학습방법        | 전통적 방법을 적용할때 | 전향적 OPP방법을 적용할때 |
|---------------|-------------|--------------|-----------------|
|               | MDA에 의한 예측률 |              | 62.3 %          |
| 인공신경망에 의한 예측률 |             | 67.2 %       | 82.2 %          |

결국 전체적으로 보면, 기존연구의 결과에서 처럼 인공지능망에 의한 예측률이 MDA에 의한 예측률보다 높다는 것을 알 수가 있다. 그러나, 전향적 OPP방법을 적용하면, MDA의 경우는 약 16%정도 예측률이 향상되고, 인공지능망의 경우는 15% 정도 예측률이 향상된다. 본 연구에서는 가장 예측률이 높은 전향적 OPP방법에 의한 인공지능망의 예측률을 벤치마킹하여 결합모형에 의한 성과를 검증하고자 한다.

#### 4. 결합모형의 설계 및 실험결과

조흥규 등 (1994)의 논문에서는 MDA와 사례기반추론 (Case-Based Reasoning), 그리고

인공지능망의 실험결과를 단순히 가중평균하여 결합을 하여도 그 예측률이 향상됨을 보였다. 그러나, 본 연구에서는 이러한 단순 가중평균하여 결합하는 방법을 지양하고, MDA에 의한 실험결과를 다시 인공지능망의 입력으로 하는 휴리스틱을 적용하여 두 모형을 결합하고자 한다. 따라서 본 연구에서 제안하는 결합모형에서 활용되는 자료는, 인공지능망에서 활용된 41개의 입력자료외에 MDA의 결과 및 인공지능망의 결과가 새로운 입력자료로 활용되므로 총 43개의 입력자료가 활용된다.

MDA의 결과 및 인공지능망의 결과를 상호 비교하여 볼 때 < 표 14 >와 같은 네가지 결합패턴을 고려할 수 있다. 특정자료에 대하여 MDA와 인공지능망이 각각 같은 신용등급을 나타내면 이는 결론의 강화로서의 패턴으로 인식한다 (결합패턴 1과 4). 마찬가지로 MDA와

<표 14> MDA와 인공지능망의 결합패턴

| 통합패턴 | MDA   | 인공지능망 | 결합모형의 해석 |
|------|-------|-------|----------|
| 1    | 해당 등급 | 해당 등급 | 결론의 강화   |
| 2    | 해당 등급 | 기타 등급 | 새로운 패턴인식 |
| 3    | 기타등급  | 해당 등급 | 새로운 패턴인식 |
| 4    | 기타등급  | 기타 등급 | 결론의 강화   |

인공지능망이 서로 다른 신용등급을 나타내면 이는 새로운 패턴으로서 인식하여 이를 다시 인공지능망으로 학습한다. 따라서 결합모형에 의한 신용평가 방법은

1) 기존의 MDA와 인공지능망중 어느 하나에만 의존하는 방식을 탈피하고,

2) 두 모형으로부터 도출되는 결과를 인공지능망으로 학습하여 신용평가등급에 대한 예측력을 강화하고자 하는 것이다. 결합모형에 의한 실험에도 MDA와 인공지능망 실험과 마찬가지로 전향적 OPP방법을 적용하였기 때문에, 결합모형에서 사용된 인공지능망의 구조는  $43 \times 25 \times 2$ 의 삼층구조를 가지고 있다.

결합모형에 의한 신용평가 과정을 구체적인 예를 통하여 살펴보기로 하자. 우선 3등급과 4등급간의 판별을 예로 들어보자. 인공지능경망의 경우 학습 및 테스트 결과가 0.5이상일 때는 3

등급으로, 0.5 미만일 때는 4등급 이하로 판정하는 규칙을 따른다고 하자. <표 15>에서 요약된 예를 살펴보자.

<표 15> 결합모형 실험예

| 결합패턴 | 실제등급 | 인공신경망 결과           | 판별분석 결과 | 결합모형 결과            | 학습결과       |
|------|------|--------------------|---------|--------------------|------------|
| 1    | 3등급  | 3등급 판별<br>0.842172 | 3 등급 판별 | 3등급<br>0.907555    | 결론의 강화     |
| 2    | 3등급  | 4등급 판별<br>0.45778  | 3등급 판별  | 3등급 판별<br>0.699325 | 결합된 결과의 제시 |
| 3    | 3등급  | 3등급 판별<br>0.74261  | 4등급 판별  | 3등급 판별<br>0.69762  | 결합된 결과의 제시 |
| 4    | 4등급  | 4등급 판별<br>0.393666 | 4등급 판별  | 4등급 판별<br>0.21817  | 결론의 강화     |

결합패턴 1과 4는 인공신경망과 MDA 모형의 결과가 서로 일치한다는 점을 표시하는 것이다. 그러나, 단지 실제등급을 정확히 맞추면서 두 모형의 결과가 일치하느냐 여부만을 구분하기 위하여, 맞추면서 일치하면 (즉, 두 모형이 모두 맞는 경우임) 결합패턴 1, 틀리면서 일치하면 (즉, 두 모형이 모두 틀리는 경우임) 결합패턴 4로 표시하였다. 한편, 결합패턴 2와 3은 인공신경망과 MDA의 결과가 상이한 경우를 나타내는 것인바, 그중 MDA가 실제등급을 맞춘 경우를 결합패턴 2, 인공신경망이 실제등급을 맞춘 경우를 결합패턴 3으로 명칭하였다. 인공신경망과 MDA의 결과가 일치하는 결합패턴 1과 4의 경우, 결합모형의 테스트 결과는 기존의 인공신경망 결과에 비하여 보다 강화된 결과를 나타내고 있다. 즉, 결합패턴 1과 4의 경우 3,4 등급간의 판별값이 결합모형에 의하

여 보다 강화됨을 알 수 있다. 결합패턴 1에서는 0.842172에서 0.907555로, 결합패턴 4의 경우 0.393666에서 0.21817로 더욱 분명하게 등급간을 판별하고 있음을 알 수 있다. 그러나 보다 중요한 경우는 인공신경망과 MDA의 결과가 상이한 경우(결합패턴 2 와 3)인데, 이 경우 결합모형은 기존의 인공신경망 자료에 인공신경망의 학습결과와 MDA의 학습결과를 추가하여 재학습하게 된다. 결합패턴 2의 경우, 인공신경망의 결과는 4 등급으로 誤分類(misclassified)되어 있고 MDA는 3등급으로 정확히 분류되어 있다. 이를 결합모형을 통하여 분류한 결과 3등급으로 신용평가 결과가 제대로 수정되어 있음을 볼 수 있다. 또한 결합패턴 3의 경우, 인공신경망의 경우는 3등급으로 정확하게 분류하고 있고 MDA는 4등급으로 오분류하고 있다. 이를 다시 결합모형으로 수

정한 결과 판별값이 약간 수정되어 있으나 3등급으로 제대로 분류하고 있음을 알 수 있다. 이와같은 결합모형에 의한 실험결과는 <표 16>과 같다. 결합모형의 실험결과 예측률이 85.

81%로서 MDA의 78.2%와 전향적 OPP방법에 의한 인공신경망의 82.17% 보다 높은 결과가 도출되었다.

<표 16> 결합모형에 의한 실험결과

| 신용등급 | 입력 층 | 은닉 층 | 출력 층 | 자료총수 | 결합모형 |        |
|------|------|------|------|------|------|--------|
|      |      |      |      |      | 예측수  | 예측률(%) |
| 1    | 43   | 25   | 2    | 50   | 36   | 72     |
| 2    | 43   | 20   | 2    | 188  | 130  | 69.15  |
| 3    | 43   | 50   | 2    | 318  | 279  | 87.74  |
| 4    | 43   | 45   | 2    | 409  | 395  | 96.58  |
| 5    | 43   | 45   | 2    | 78   | 55   | 70.51  |
| 합 계  |      |      |      | 1043 | 895  | 85.81% |

각 모형별 예측률간에 통계적으로 유의하게 차이가 있는지를 검증하기 위하여, 본 연구에서는 비모수 검정방법중의 하나인 카크란(Cochran)의 Q-통계량을 사용하였다. <표 17>에 제시된 결과를 해석하면 다음과 같다.

1) MDA:26은 MDA:24보다 .0082수준에서 유의적으로 예측력 차이를 보이고 있어 2개 변수를 추가할 때 통계적으로 유의한 예측력 차이를 보인다.

2) 전통적 인공신경망 모형은 24개와 26개의 변수를 이용한 전통적인 MDA보다는 우수하지만, 전향적 OPP방법에 의한 MDA보다는 예측률이 떨어진다. 따라서 5등급으로 평가하는 전통적인 평가모형보다는 전향적 OPP방법에 의한 결과가 전체적으로 높은 예측률을 나타낸다.

3) 전향적 OPP방법에 의한 MDA모형은

MDA:26모형보다 통계적으로 매우 유의한 예측력 향상을 보이고 있다. 따라서, 5등급의 전통적인 모형보다 2등급으로 구성된 전향적 OPP방법이 보다 높은 예측률을 나타냄을 알 수 있다.

4) 전향적 OPP방법에 의한 인공신경망 모형과 결합모형은 통계적 모형인 MDA모형보다 매우 높은 예측률을 나타낸다.

5) 특히 본 연구에서 제안한 결합모형은 기타 다른 어떠한 모형보다 높은 예측률을 보이고 있으며, 이러한 예측률 향상은 통계적으로도 매우 유의하다.

이상의 결과를 종합하여 보면, 본 연구에서 제안한 결합모형이 전통적 인공신경망에 의한 예측률(67.2%)보다 18.61%의 예측률 상승을 보이고 있고, 전향적 OPP방법에 의한 인공신경망과 비교하면 3.64%의 예측률 상승을



<표 16> 각 모형별 예측률을 비교하기 위한 카르란의 Q-통계량

| 모형 및 예측률               |        | MDA:24 | MDA:26 | 전통적<br>인공신경망 | 전향적 OPP방법에<br>의한 MDA | 전향적 OPP방법에<br>의한 인공신경망 |
|------------------------|--------|--------|--------|--------------|----------------------|------------------------|
| 모형                     | 예측률    |        |        |              |                      |                        |
| MDA:24                 | 61.65% | --     | -      | -            | -                    |                        |
| MDA:26                 | 62.3%  | .0082  | -      | -            | -                    |                        |
| 전통적<br>인공신경망           | 67.2%  | .0000  | .0000  | -            | -                    |                        |
| 전향적 OPP방법에<br>의한 MDA   | 78.2%  | .0000  | .0000  | .0000        | -                    | -                      |
| 전향적 OPP방법에<br>의한 인공신경망 | 82.17% | .0000  | .0000  | .0000        | .0000                | -                      |
| 결합모형                   | 85.81% | .0000  | .0000  | .0000        | .0000                | .0000                  |

보이고 있다. 결국 통계적 검증결과 결합모형은 나머지 모든 모형의 결과보다 통계적으로 유의하게 향상된 예측률을 보이고 있다는 것을 알 수가 있다. 또한, 현실적으로 막대한 평균여신액을 가지고있는 우리나라 시중은행의 현실을 감안할 때에, 전향적 OPP방법에 의한 인공신경망보다 결합모형에 의한 3.64%의 예측률 증가는 실무적으로 큰 의의가 있다.

### 5. 결 론

본 논문에서는 MDA와 인공신경망 방법을 결합하여 예측률이 보다 개선된 기업신용평가를 위한 결합모형을 제시하였다. 본 연구에서 제안하는 결합모형은 인공신경망 모형과 통계모형인 MDA모형을 휴리스틱하게 결합한 형태이다. 1991년과 1992년의 우리나라 3개 신용평

가기관의 신용평가 자료를 기초로 하여 실험을 하였고, 그 결과 결합모형이 통계적으로나 실무적으로 유의한 예측률 향상을 보임을 검증하였다. 특히 본 연구에서는 기존의 인공신경망을 이용한 신용평가 방법에서 흔히 택하는 신용평가 등급을 한꺼번에 학습시키려는 방법을 탈피하여, 전향적 OPP방법이라는 새로운 방법을 적용하였다. 따라서, 본 연구에서 비교대상이 되는 예측률은 기존의 전통적 인공신경망의 예측률이 아니라, 전향적 OPP방법에 의한 인공신경망의 예측률이다.

기업신용평가 문제에 있어서, 인공신경망 모형의 예측률이 MDA모형의 예측률보다 우수하다는 것은 이미 기존연구를 통하여 충분히 실증된 사실이다. 따라서 본 연구에서는 전향적 OPP방법에 의한 인공신경망의 예측률과 결합모형의 예측률을 비교하는 방법으로, 결합모형의 성과를 검증하였다. 검증결과 전통적 인공신경망의 예측률 보다는 18.61%나 높은 결과

를 얻을 수가 있었고, 전향적 OPP방법에 의한 인공신경망 모형의 예측률보다는 3.64%의 향상을 기할 수가 있었다. 또한 이러한 결합모형에 의한 예측률의 향상은 통계적으로도 유의하였으며, 또한 실무적으로도 의미가 있는 결과이다.

이상 본 연구가 제시하는 공헌을 정리하면, 결국 전향적 OPP방법에 의한 인공신경망 모형과 MDA모형을 휴리스틱하게 결합한 결합모형이, 기존의 MDA나 전향적 OPP방법에 의한 인공신경망보다 높은 예측률을 보여준다는 사실을 실증적으로 검증한 것이다. 또한 그 의미가 통계적으로나 실무적으로도 의미가 있음을 보여 주었다. 본 연구와 관련된 향후 연구과제를 정리하면 다음과 같다.

첫째, 본 연구에서처럼 1000여개에 달하는 기업신용평가 자료를 다루는 것이 실증분석 과정에 있어서 많은 부담을 준다. 전향적 OPP방법보다 더 간편하면서도 예측률의 향상을 꾀할 수 있는 학습방법을 개발할 필요가 있다.

둘째, 다른 형태의 인공지능 모형과 MDA의 또 다른 형태의 통계모형과의 결합을 시도하는 결합모형을 개발할 필요가 있다.

## 참 고 문 헌

- [1] 이진창 (1993), "A Comparative Study on the Bankruptcy Prediction Power of Statistical Model and AI Models: MDA, Inductive Learning, Neural Network", 한국경영과학회지 18 (2), 57-81.
- [2] 이진창, 김명종, 김혁 (1994a), "An Inductive Learning-Assisted Neural Network Approach to Bankruptcy Prediction: Comparison with Multivariate Discriminant Analysis, Inductive Learning, and Neural Network Models", 경영학 연구 23 (3), 109-144.
- [3] 이진창, 한인구, 권영식 (1994b), "A DSS-Oriented Neural Network Simulation Framework for Business Classification", 한국경영정보학회 '94 춘계학술대회 발표논문집, 127-148.
- [4] 조홍규, 한인구, 이훈영 (1994), "Comparative Analysis of Bankruptcy Prediction Accuracy: Using Discriminant Analysis, Case-based Forecasting, and Neural Networks", 전문가시스템학회 '94 추계학술대회 발표논문집, 385-399.
- [5] 한국기업평가, 신용등급편람, 한국기업평가주식회사, 1990-1993.
- [6] 한국신용정보, 신용등급편람, 한국신용정보주식회사, 1990-1993.
- [7] 한국신용평가, 신용등급편람, 한국신용평가주식회사, 1990-1993.
- [8] 한인구 (1990), "귀납적 학습방법과 통계학적 방법의 예측력에 관한 비교연구", 회계학연구, 12월, 245-264.
- [9] 한인구, 권영식, 조홍규 (1995a), "A Review of Artificial Intelligence Models in Business Classification", 한국전문가시스템학회지 창간호, 23-41.
- [10] 한인구, 권영식, 이진창 (1995b), "지능형 기업신용평가시스템의 개발: NICE-AI", 경영학 연구, 24(4), 91-117.
- [11] Altman, E. and S. Katz (1976), "Statistical Bond Rating Classification

- using Financial and Accounting Data”, *Proceedings of the Conference on Topical Research in Accounting*, New York University, School of Business, N. Y.
- [12] Ang, J. S. and K. A. Patel (1975), “Bond Rating Methods: Comparison and Validation”, *The Journal of Finance*, 30, No. 2, 631-640.
- [13] Dutta, S. and S. Shekhar (1988), “Bond Rating: A Non-Conservative Application of Neural Networks”, *Proceedings of the IEEE International Conference on Neural Networks*, II443-450.
- [14] Eisenbeis, R. A. (1977), “Pitfalls in the Application of Discriminant Analysis in Business, Finance, and Economics”, *The Journal of Finance*, 32, 875-900.
- [15] Horrigan, J. (1966), “The Determination of Long Term Credit Sharing with Financial Ratios”, *Journal of Accounting Research*, 4, 44-62.
- [16] Kaplan, R., and G. Urwitz (1979), “Statistical Models of Bond Ratings: A Methodological Inquiry”, *Journal of Business*, 231-261.
- [17] Kim, J. (1992), “A Comparative Study of Rule-Based, Neural Networks, and Statistical Classification Systems for the Bond Rating Problem”, Unpublished doctoral dissertation, Virginia Commonwealth University, Richmond, VA.
- [18] Kwon, Y., I. Han, and K. Lee (1996), “Ordinal Pairwise Partitioning (OPP) Approach to Neural Networks Training: Bond Rating Case”, accepted for publication in *Intelligent Systems in Accounting Finance & Management*.
- [19] Lee, K., I. Han, and Y. Kwon (1994a), “A Comparative Study of the Bankruptcy Prediction Accuracy of Statistical and Artificial Intelligence Models: MDA, ACLS, and Neural Networks,” *Proceedings of Japan/Korea Joint Conference on Expert Systems*, Tokyo, Japan, 272-282.
- [20] Lee, K., I. Han, and Y. Kwon (1994b), “Neural Networks Applications for Business Classification: Structured Approach to Neural Networks Simulations(SANNS)”, *Proceedings of Spring Conference of Korea Management Information Systems Society*, Korea, 129-148.
- [22] Lee, K., I. Han, and Y. Kwon (1996), “Hybrid Neural Models for Bankrupt Prediction,” *accepted for publication in Decision Support Systems*.
- [23] Liang, T., J. Chandler, I. Han, and J. Roan (1992), “An Empirical Investigation of some Data Effects on the Classification Accuracy of Probit, ID3, and Neural Networks”, *Contemporary Accounting Research*, 9, No. 1, 306-328.
- [24] Martin, L., G. Herderson, L. Perry, and T. Cronan (1984/85-3), “Bond

- Ratings: Predictions using Rating Agency Criteria”, Working paper, Arizona State University, Tempe, AZ.
- [25] Odom, M. and R. Sharda (1990), “A Neural Networks Model for Bankruptcy Prediction”, *Proceedings of the IEEE International Conference on Neural Networks*, III63-168.
- [26] Pinches, G. and K. Mingo (1975), “A Multivariate Analysis of Industrial Bond Ratings”, *The Journal of Finance*, 28, 1-18.
- [27] Rumelhart, D. E., G. E. Hinton, and R. J. Williams (1986), “Learning Internal Representations by Error Propagation”, in D. E. Rumelhart and J. L. McClelland (Eds.), *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Vol. 1: Foundations. MIT Press.
- [28] Salchenberger, L. M., E. M. Cinar, and N. A. Lash (1992), “Neural Networks: A New Tool for Predicting Thrift Failures”, *Decision Sciences*, 23, No. 4, 899-915.
- [29] Standard & Poor’s Corporation (1980), *Debt Ratings Criteria: Industrial Overview*. New York.
- [30] Standard & Poor’s (1986), *Credit Overview*. Standard & Poor’s Corporation.
- [31] Subramanian, V., M. S. Hung, and M. Y. Hu (1993), “An Experimental Evaluation of Neural Networks for Classification”, *Computers and Operations Research*, 20, No. 7, 769-782.
- [32] Surkan, A., and J. Singleton (1990), “Neural Networks for Bond Rating Improved by Multiple Hidden Layers”, *Proceedings of the IEEE International Conference on Neural Networks*, 157-162.
- [33] Tam, K., and M. Kiang (1992), “Managerial Applications of Neural Networks: The Case of Bank Failure Predictions”, *Management Science*, 926-947.