

귀납적 학습방법들의 분류성능 비교 : 기업신용평가의 경우^{*}

이상호^{*} · 지원철^{**}

Classification Performance Comparison of Inductive Learning Methods : The Case of Corporate Credit Rating^{*}

Lee, Sang-Ho^{*} · Jhee, Won Chul^{**}

요 약

귀납적 학습방법들의 분류성능을 비교 평가하기 위하여 대표적 분류문제의 하나인 신용평가 문제를 사용하였다. 분류기로서 사용된 귀납적 학습방법론들은 통계학의 다변량 판별분석(MDA), 기계 학습 분야의 C4.5, 신경망의 다계층 퍼셉트론(MLP) 및 Cascade Correlation Network(CCN)의 4 가지이며, 학습자료로는 국내 3개 신용평가기관이 발표한 신용등급 및 공포된 재무제표를 사용하였다. 신용등급 예측의 정확도에 의한 분류성능을 평가하였는데 연도별 평가와 시계열 평가의 두 가지를 실시하였다. Cascade Correlation Network이 가장 좋은 분류성능을 보였지만 4가지 분류기들 사이에 통계적으로 유의한 차이는 발견되지 않았다. 이는 사용된 학습자료가 갖는 한계로 인한 것으로 추정되지만, 성능평가 과정에 있어 학습자료의 전처리 과정이 분류성과의 제고에 매우 유효함이 입증되었다.

<Key Words> 귀납적 학습방법, 분류, 판별분석, C4.5, 다계층 퍼셉트론, Cascade Correlation Network, 학습자료의 전처리, 신용평가

※ 본 연구는 정통부 국책기술개발사업의 지원을 받았습니다.

* 홍익대 산업공학과

** 홍익대 산업공학과

1. 서론

귀납적 추론은 인류가 오랜 세월을 거쳐 자연스럽게 사용 발전시켜 온 추론 방법의 하나이다. 따라서, 전문가시스템 분야에서 지식획득의 어려움을 해결하기 위해 자동학습방법의 개발에 많은 노력을 기울여 온 사실을 감안할 때, 귀납적 추론을 사용하는 학습방법들의 개발 및 사용이 보편화된 것은 당연하다 하겠다.

귀납적 학습방법에 대한 공식적 정의는 다음과 같다. 주어진 한 쌍의 입력력 ($x, f(x)$)을 예제(Example)라고 하면 $f(x)$ 는 입력값 x 가 주어졌을 때 함수 f 의 출력값이다. 여기서 귀납적 학습방법이란 함수 f 의 예제들이 주어졌을 때, f 의 근사함수(Approximator) h 를 구하는 것이다. 추정하여야 할 함수 h 는 가설(Hypothesis)이라고도 불린다[Russel & Norvig, 1995]. 이와 같은 귀납적 학습방법의 정의는 매우 폭넓게 적용할 수 있다. 즉, 인공지능에서 귀납적 학습방법을 대표하는 의사결정수(Decision Tree) 기법들 외에도, 학습 전략에 의한 학습방법의 분류에서 사례 또는 예제로부터의 학습(Learning From Examples)에 해당되는 모든 학습방법들은 귀납적 학습방법에 속한다. 따라서, 신경망은 대표적인 귀납적 학습방법으로 분류될 수 있으며, 통계학의 많은 분석방법들도 귀납적 학습방법들이라고 볼 수 있다.

본 논문에서는 분류작업에 사용할 수 있는 네 가지 귀납적 학습방법들, 즉 통계학의 다변량 판별분석(Multiple Discriminant Analysis, MDA), 자동학습 분야에서 발전된 의사결정수 기법인 C4.5, 및 다계층 퍼셉트론(Multilayer Perceptron, MLP)과 Cascade Correlation Networks(CCN) 두

개의 신경망 모형들을 대표적 분류문제인 신용평가에 적용하여 분류성능을 비교 분석하고자 한다. 귀납적 학습방법들에 대한 분류성능의 비교평가에 관한 대표적 연구로는 EC에 의해 주도된 ESPRIT Programme의 기초 연구로 수행되었던 Statlog 프로젝트[Michie et al, 1994]와 ELENA (Enhanced Learning for Evolutive Neural Architecture) 프로젝트[Blayo et al, 1995]가 있다. 이 연구들에서는 다양한 자료들에 대해 학습 알고리즘들의 분류성능을 평가하고 자료가 갖는 특성에 따라 가장 적합한 분류 알고리즘을 파악하고자 노력하였다. 또, 학습 알고리즘의 객관적 성능평가를 위하여 벤치마크 데이터의 중요성을 인식하고 준비하는 기관들이 생겼는데 UCI Repository of Machine Learning Database[Murphy & Aha, 1991]가 대표적인 것이다.

본 연구에서 네 가지 귀납적 학습방법들의 분류성능을 비교평가하기 위해 사용할 기업 신용평가 문제는 국내에서도 통계학이나 신경망을 이용하여 이미 연구되었던 문제이다[한국은행, 1982; Jhee, 1989; Han & Jhee, 1993; Lee et al, 1994; 이재식과 한재홍 et al, 1995; Kwon et al, 1996]. 따라서, 본 연구에서는 국내에서 분류성능에 대한 검증작업이 아직 이루어지지 않은 C4.5와 CCN의 국내 신용평가 자료에의 적용가능성을 검토함과 동시에 분류작업시 고려하여야 할 자료의 특성들이 무엇인가를 파악하고자 한다.

본 논문의 구성은 다음과 같다. 2절에서 일반적인 분류모형에 대한 설명과 본 연구에서 사용된 분류방법들에 대해 간단히 설명한 후, 3절에서 본 연구에 사용된 국내 신용평가 자료의 성격 및 분류성능의 제고를 위한 자료의 전처리에 관

런된 사항들을 설명한다. 4절에서는 채택된 귀납적 학습방법들의 분류성능에 대해 분석한 후, 결론으로 5절에서 국내 신용평가 자료에 대한 분류성능의 제고 방안에 대해 논의하였다.

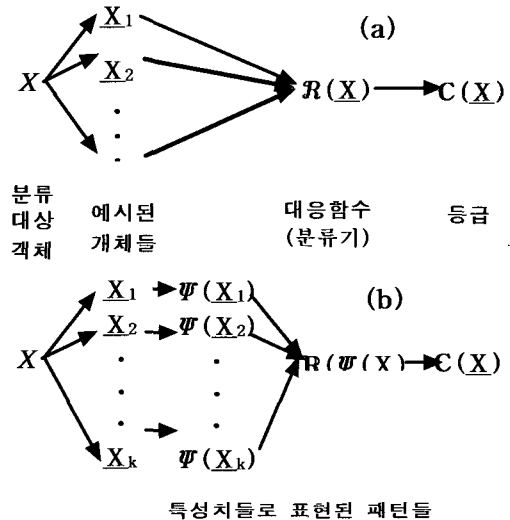
2. 분류함수로서의 귀납적 학습방법론들

2.1. 분류작업의 일반적 모형

<그림 1-(a)>는 인간이 자연스럽게 행하는 분류작업을 도형화한 것이다. 인간이 분류작업을 행할 때는 분류할 집단내의 각 개체들을 인식하고 표현할 수는 없지만 어떤 기준, 즉 해당 개체(X_k)를 사전에 정해진 등급중의 하나(Class Index, $C(X)$)로 대응시키는 함수(Mapping Function, $R(X)$)를 사용하는 것이 분명하다. <그림 1-(b)>는 분류작업을 컴퓨터 내에 구현했을 때의 모형으로서 <그림 1-(a)>와의 차이점은 개체의 인식을 위하여 개체의 특성치들을 확정짓는 특성추출기(Feature Extractor, $\Psi(X)$)들이 필요하다는 것이다. 즉, 대응함수 또는 분류함수에의 입력값들을 제공하는 별도의 기능이 필요하며, 대응함수($R(\Psi(X))$)도 구체적인 함수의 형태로 표현되어야 한다는 것이다. [Pao, 1988]

<그림 1-(b)>는 분류작업을 컴퓨터에 의해 행할 경우 두 가지 요소, 즉 특성추출기와 대응함수 또는 분류기(Classifier)의 성능이 바로 분류작업의 성능을 좌우하며, 이 양자는 서로 보완적인 관계에 있다는 사실을 말해준다. 즉, 원하는 분류성과를 얻기 위해 사용된 특성추출기의 기능이 약할 경우에는 강력한 분류기를 사용하여야 하며, 역의 관계도 마찬가지로 성립된다. 따

라서, 분류기들의 공정한 성능평가를 위해서는 가능한 동일한 특성추출기들이 사용되어야 한다.



(그림 1) 분류작업의 일반적 모형
(a) 인간의 분류작업 (b) 컴퓨터구현 분류작업

본 연구에서는 기업의 신용평가 자료를 대상으로 귀납적 학습방법들의 분류성능을 비교하는 것이므로 특성추출기들로서는 기업의 재무적 비재무적 지표들이 사용될 수 있다. 물론 앞서 언급한 바와 같이 어떤 특성추출기 즉 입력변수들을 선택하는가는 분류함수의 성능을 결정하는 가장 중요한 요인이다. 하지만, 본 연구의 목적이 신용평가의 예측모형을 수립함에 있어 효과적인 분류기로서 사용할 수 있는 방법론을 찾기 위해 귀납적 학습방법론들간의 성능평가를 하는데 있으므로 어떤 특성추출기가 신용평가 예측모형의 성능향상에 더 중요한가에 주안점을 두기보다는 평가대상 분류기들의 공정한 성능평가를 위해 가능한 동일한 특성추출기들이 사용되도록 하였다.

이하에서는 본 연구에서 분류기로서 사용할 네 가지 귀납적 학습방법들, 즉 통계학의 다변량 판별분석, 자동학습 분야에서 발전된 의사결정수 기법인 C4.5, 및 신경망 모형들인 다계층 퍼셉트론과 Cascade Correlation Networks에 대해 설명한다.

2.2. 다변량 판별분석 (Multiple Discriminant Analysis, MDA)

MDA은 다수의 변수들을 가지고 집단간의 차이를 연구하는 통계적 기법이다. MDA를 적용하기 위해서는 다음과 같은 가정들이 만족되어야 한다. (1) 둘 이상의 집단이 존재한다. (2) 각 집단 내에 둘 이상의 학습자료가 있다. (3) 판별 변수(Discriminating Variable)의 수는 총 학습자료의 수에서 2를 뺀 것 보다 작아야 한다. (4) 판별 변수들은 구간척도에 의해 측정되어야 한다. (5) 각 집단의 공분산 행렬(Covariance Matrices)은 같아야 한다. (6) 각 집단은 다변량 정규분포를 따르는 모집단으로부터 추출되어야 한다. 이와 같이 MDA는 엄격한 통계적 가정을 요구하지만 아직도 다양한 응용분야에서 기본적인 분류함수로서 이용되고 있다[Klecka, 1981; Hair et al, 1995].

본 연구에서는 MDA에 있어 단계적(Stepwise) 절차를 사용하여 많은 입력변수들 중에서 판별력 있는 입력변수를 선정할 수 있도록 하였다. 집단간의 차이를 분석하는 과정에서 가장 유용하다고 판단되는 변수들의 집합을 선택하는 절차인 단계적 판별분석법에는 전진적 도입(Forward Inclusion)과 후진적 제거(Backward Elimination)의 두 가지 방법이 있으며, 판별 변수를 선택하는

기준으로는 Wilks' Lambda, Rao's V 통계량 및 Mahalanobis' Distance 등이 사용된다. 본 연구에서는 Wilkes' Lambda와 전진적 도입방법에 의해 변수의 선택방법을 사용하였다.

2.3. C4.5

C4.5는 Quinlan[1992]이 ID3에 이어 개발한 의사결정수 기법의 하나이다. C4.5 이전의 의사결정수 기법들로는 개념학습시스템(Concept Learning System)이라는 이름 하에 발전되어온 CLS, ACLS, ID3 등과, 통계학에 기반을 둔 CART(Classification and Regression Tree) 등이 있다. C4.5는 주어진 학습자료들을 분류하기 위하여 사전에 정의된 등급(Classes)과 속성(Properties)들간의 관계를 파악하여 단계적으로 의사결정수를 형성해 나간다. 특히 C4.5는 ID3가 가지고 있는 문제점들, 즉 의사결정수의 생성과정에서 사용되었던 Gain Criterion이 가지는 편향성과 연속값을 갖는 변수 처리의 비효율성을 개선한 것이다.

C4.5에 의해 생성된 의사결정수가 지나치게 많은 단계와 리프 노드를 가질 경우 학습된 의사결정수의 일반화 능력의 저하, 즉 예측성능 향상을 위해 가지치기 작업을 시행하게 된다. 일반적으로 가지치기는 학습자료에 대한 오류율을 증가시키게 되므로 C4.5에서는 오류기반 가지치기 방법을 사용하여 가지치기로 인한 오류율의 증가를 제어한다. 또, C4.5는 의사결정수의 해석이 복잡하다는 점에 착안하여 의사결정수로부터 자동적으로 IF-THEN 규칙을 생성해낼 수 있는 기능을 제공하고 있는데 규칙의 생성은 가지치기를 하지 않은 의사결정수로부터 규칙들을 생성한 후, 명시적 삭제, Contingency Table 및


유의성 검증 등의 방법을 통해 생성된 규칙들을 간략화 한다.

2.4. 다계층 퍼셉트론 (Multilayer Perceptron, MLP)

MLP는 다양한 신경망 모형들 중에서도 가장 많이 사용되고 있는 모형으로 백프로퍼게이션 알고리즘에 의해 학습되어진다[Rumelhart & McClelland, 1986; Lippman, 1989]. <그림 2>는 분류작업을 위한 MLP의 구조를 나타낸 것으로 출력층에 대응된 A1, A2, A3, B는 신용등급을 의미한다. 신경망 학습자료의 출력값은 해당 입력패턴의 소속집단을 나타내는 역할을 담당하는 출력노드 하나만 1의 값을 가지고 나머지 출력노드들은 모두 0의 값을 갖도록 구성하였다. 따라서, 어느 기업의 신용등급이 A2라면 학습자료 내 출력패턴은 [0,1,0,0]가 된다.

MLP의 분류성능을 결정하는 요소들은 여러 가지가 있지만 입출력패턴의 형태가 주어졌다면 은닉노드 수의 결정이 가장 중요하지만, 사전에 은닉노드 수의 최적값을 알 수 없으므로 좋은 예측성능을 얻기 위해서는 많은 시행착오를 거쳐야 한다. 최근 연구결과는 MLP를 학습시키는 과정에서 Bias-Variance Dilemma [Geman & Bienenstock, 1992]가 있다는 사실이 보고되었는데, 이는 학습과정에서 MLP의 과잉 또는 과소 학습을 막기 위해 적절한 크기의 신경망을 사용하고 적절한 시점에서 학습을 멈추는 방안을 강구해야함을 강조한 것이다. 하지만, MLP는 구조결정의 어려움에도 불구하고 MDA와는 달리 분석대상 자료에 대한 엄격한 통계적 가정을 요구하지 않으며 비선형 모형에 의한 집단간 분류가

가능하다는 장점이 있어 가장 많이 이용되어 온 신경망 모형으로, MLP를 이용한 신용등급의 예측은 국내외에서 여러 번 연구되었다[Dutta & Shekhar, 1988; Jhee, 1989; Surkan & Singleton, 1990; Garavaglia, 1991; Han & Jhee, 1993; Moody & Utans, 1994; Lee et al, 1994; Kwon et al, 1996].



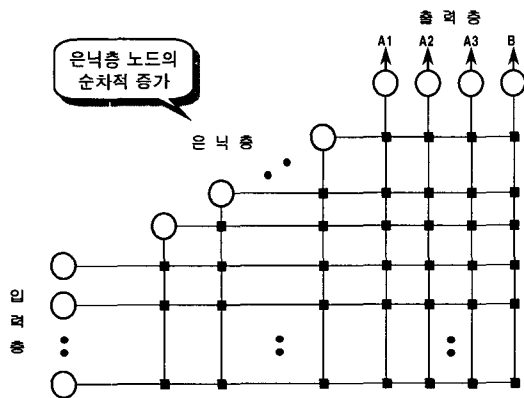
(그림 2) 분류작업을 위한 다계층 퍼셉트론의 구조

2.5. Cascade Correlation Networks (CCN)

Fahlman과 Lebiere[1990]는 MLP의 학습속도가 느린 원인으로 학습과정상의 두 가지 문제점을 지적하고 있다. 첫 번째는 Step-size 결정문제표준 백프로퍼게이션 학습에 있어 전역오차함수에 대해 1차 부분도함수만을 사용하여 가중치의 갱신량을 계산하기 때문에 발생한다. 이 문제를 완화시키기 위해 관성항을 사용하거나 2차 도함수를 사용하는 방법들이 많이 제시되었다. 두 번째는 Moving Target 문제로 MLP의 경우 신경

망의 구조가 고정되어 있고 변화하는 입출력 패턴에 대해 내부가중치들이 동시에 모두 변화하게 되므로 생기는 문제이다. 즉 MLP 내부의 모든 노드들이 동시에 유용한 특성검출기가 되려 하기 때문에 오히려 학습속도를 늦추고 경우에 따라서는 학습결과의 편차가 심해지는 현상을 보이게 된다는 것이다.

CCN은 백프로퍼게이션 학습방법에 의한 MLP의 한계를 벗어나기 위하여 Step-size결정문제는 Quickprop 학습방법에 의해 해결하고[Fahlman, 1988], Moving Target 문제에 대해서는 <그림 3>에서와 같은 새로운 신경망 구조를 채택하였다. CCN의 구조는 학습초기 은닉층이 없는 상태로 시작하여 학습이 진행되면서 은닉노드를 하나씩 추가해 나가는 데, 새로이 추가된 은닉노드에는 모든 입력노드와 기존의 은닉노드들이 함께 연결되는 층화 구조를 가진다. 이와 같은 층화 구조의 장점은 은닉노드들이 입력에 대한 고차원 특성검출기(High-order Feature Detector)로서 작용한다는 점과 사전에 은닉층의 노드 수를 결정할 필요가 없다는 것이다.



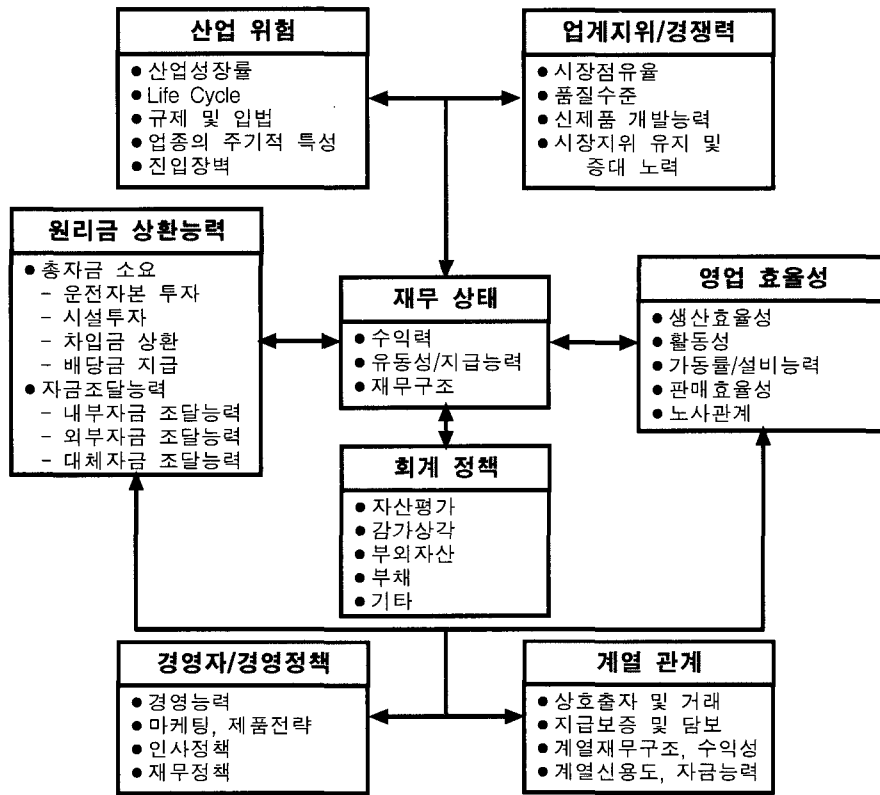
(그림 3) CCN의 구조

CCN이 MLP가 가진 두 가지의 단점, 즉 느린 학습속도와 은닉노드 수 결정 문제를 해결했다고는 하지만, CCN의 경우도 MLP와 마찬가지로 주어진 문제에 대한 최적의 신경망 구조를 자동으로 결정해 주지는 않는다. 다시 말해 CCN의 학습과정에서 목표 출력오차 값을 너무 작게 주는 경우에는 주어진 목표 오차 값을 달성하기 위하여 지나치게 많은 은닉노드들을 생성하게 되어 학습된 CCN의 예측성능이 급격히 저하되는 현상이 발생한다. 특히, CCN의 은닉노드들은 MLP의 경우와는 달리 고차원 특성검출기로서의 역할을 하므로 과잉적합에 의한 부작용은 MLP보다 심하다는 사실을 염두에 두어야 한다. 따라서 CCN을 사용할 경우에도 문제성격에 적절한 학습 멈춤 조건을 충분히 검토하여 CCN의 크기가 필요이상으로 커지는 것을 방지하여야 한다. 최근 은닉층의 노드를 하나의 층으로 하는 구조를 채택하거나 추가되는 은닉노드의 선정방법들을 개선하는 알고리즘들이 개발되고 있는데[Prechelt, 1997] 본 연구에서는 표준적인 CCN을 사용하였다.

3. 분석대상 자료

3.1. 신용평가절차의 개요

기업의 부채에 대한 원리금 상환능력을 평가하려면 해당기업의 미래 자금소요 규모와 자금조달능력의 정도를 비교하여야 한다. 하지만 <그림 4>에서 볼 수 있는 바와 같이 미래 자금소요 규모와 자금조달 능력에 영향을 미치는 요인들이 매우 많으며 또 요인들 상호간에 밀접한 관계를 가지고 있다는 사실은 신용평가 문제가 단순하지 않음을 나타내는 것이다.



(그림 4) 기업신용평가에 영향을 미치는 요인들

따라서 신용평가 기관들은 기업신용평가를 예비평가와 본 평가의 두 단계로 나누어 실시하고 있다. 예비평가에서는 기업내부분석에서 출발하여 계열분석, 동종표본업체분석, 산업분석으로 확대한 후 다시 기업내부 상황과의 연계분석이 순환적으로 반복되면서 기업원리금 상환능력을 종합 평가하게 된다. 본 평가에서는 예비 분석 시 나타난 주요 문제점에 관한 문의 및 이에 대한 근거자료를 피평가 기업에 요청한 후 최고경영자와의 면담을 통해 경영정책의 타당성, 합리성, 우월성 등을 평가하여 작성한 평가보고서를 근거로 평가조정회의를 거쳐 최종적인 신용등급을 부여한다. 이와 같은 평가과정의 채택은 복잡한 경제상황하에 놓여있는 기업의 위험을 정

확히 평가하기 위해서는 많은 양의 자료와 함께 평가자의 주관적 판단을 요구하는 경우가 일반적이라는 사실에 입각한 것이다. 특히, 신용평가 기관들이 평가위원회 제도를 채택하고 있는 이유는 부여한 등급의 공신력을 높이려는 노력의 일환으로 볼 수 있으며, 신용평가 과정은 통계적 분석의 결과인 단순한 선형모형에 의해 결코 설명되어질 수 없다고 주장하는 근거이기도 하다.

하지만, 신용평가과정은 대표적인 분류작업의 한 예이며, 분류작업의 경우 오랜 기간 통계적 모형들이 여러 분야에서 효과적으로 사용되어왔으며, 관련 연구 결과들은 통계적 분석이 적어도 복잡하고 주관적인 신용평가 과정에 대한 근

사치로써 사용될 수 있음을 보여주었다[Pinches & Mingo, 1975; Altman & Katz, 1976; Kaplan & Urwitz, 1979]. 따라서, 신용평가의 사전예측모형을 수립할 수 있다면 신용평가기관은 예비평가과정에서 보조 수단으로 사용하여 신속하고 일관성 있는 신용평가과정을 보장할 수 있으며, 피평가기업은 신용평가 의뢰 전에 자신의 신용등급을 사전 예측함으로써 원하는 신용등급을 얻기 위해 보완하여야 할 사항들을 사전 점검할 수 있도록 해주는 효과를 얻을 수 있다.

3.2. 분석자료의 수집

네 가지 귀납적 학습방법들의 분류성능을 평가하기 위하여 국내 기업어음(CP)의 신용평가등급자료를 사용하여 등급 예측력을 비교 분석하였다. 분석에 사용된 자료들은 국내 3대 신용평가기관들인 한국신용평가(주), 한국신용정보(주), 한국기업평가(주)가 발표한 신용등급과 한국신용평가(주)의 재무정보프로그램인 FAS에서 분석대상기간인 1992년, 1993년, 및 1994년의 3개년 동안 해당기업의 재무정보를 얻을 수 있는 경우로 한정하였다.

1992년도 한국신용평가(주)에서 제공된 자료에는 피평가 기업들을 10개의 업종으로 대분류하고 있지만 이 분류에 따라 업종별로 분석에 필요한 충분한 자료들을 확보할 수 없어서 제조업으로 한정하였다. 제조업 관련 피평가 기업의 수는 92년 231개, 93년 235개, 94년 198개였다. 또, 제조업 내에서도 한국신용평가(주)는 1992년도에는 11개, 1993년도, 1994년도에는 18개의 업종으로 구분하고 있어서 제조업 내에서도 업종구분을 정리할 필요가 있었다. 본 연구에서는

1993년도와 1994년도의 18개의 업종을 1992년도의 11개의 업종으로 재분류한 뒤 총자산 및 자기자본의 평균과 표준편차를 기준으로 분포의 형태를 고려하여 다시 8개 업종으로 구분하였다. <표 1>은 학습자료의 수를 연도별 업종별로 정리한 것이다.

현재 국내 3개 신용평가 기관들은 기업어음에 대한 신용등급으로 A1, A2, A3, B, C, D의 6개 등급을 사용하며 동일 등급 내에서의 차이를 나타내기 위해 \pm 기호를 겸용하고 있다. 본 연구에서는 \pm 에 의한 구분은 사용하지 않았으며, C 등급과 D등급의 경우는 분석기간의 데이터 수가 총 10개 미만이어서 제외하였다. <표 1>에서 92, 93년의 기업수가 각각 하나씩 적어진 이유는 제조업의 경우 C등급의 기업이 하나씩 있었기 때문이다. 수집된 자료들은 분류함수들을 추정하기 위한 훈련집합과 추정된 분류함수의 성능을 평가하기 위한 검증집합의 두 개의 집합으로 나누어 졌는데, 임의추출 방법에 의해 다섯개의 훈련집합 및 검증집합의 쌍을 생성하여 반복 실험을 하였다. <표 2>는 학습자료의 수를 연도별, 등급별로 정리한 것이다.

<표 2> 학습자료의 연도별 업종별 구분

업종	92년	93년	94년
기계 및 조립금속	24	22	15
비금속광물 및 제1차금속	35	33	28
섬유	38	37	38
운수장비	13	15	10
음식료업	25	29	20
전기 및 전자	33	31	34
화학물 및 화학	46	50	41
기타	16	17	12
합계	230	234	198

<표 3> 분석에 사용된 연도별 자료 수

연도	자료구분	A1	A2	A3	B	합계
92	훈련집합	16	68	59	28	171
	검증집합	6	23	20	10	59
	합계	22	91	79	38	230
93	훈련집합	21	69	59	25	174
	검증집합	8	23	20	9	60
	합계	29	92	79	34	234
94	훈련집합	18	50	48	31	147
	검증집합	6	17	17	11	51
	합계	24	67	65	42	198

분류함수들을 위한 입력변수들은 <그림 4>에서 볼 수 있었듯이 재무변수와 비재무적 변수의 두 가지로 크게 나눌 수 있으며 각각의 항목들은 다시 많은 특성치들이나 재무비율들에 의해 구성된다. 본 연구에서는 입력변수들을 선정하기 위하여 기존의 문헌들을 참조하여 입력변수로서 사용 가능한 재무변수들을 모은 후, FAS로부터 해당변수들의 값을 얻을 수 있는지의 여부를 검토하였다. 그 결과 <표 3>에서와 같이 (1)성장성 지표 9개 (2)기업규모 지표 12개 (3)수익성 지표 37개 (4)안전성 지표 17개 (5)활동성 지표 13개 (6)생산성 지표 16개 (7) 현금흐름 지표 6개 등 총 7개 지표 110개의 입력변수들이 사용 가능하였으며 비재무적 변수로는 업종만이 고려되었다.

신용평가에 사용될 특성추출기들 다시 말해서

<표 4> 본 연구에 사용된 특성추출기들

성장성지표(9개)		총자산증가율, 유형고정자산증가율, 유동자산증가율, 재고자산증가율, 자기자본증가율, 매출액증가율, 경상이익증가율, 순이익증가율, 종업원증가율
규모지표(12개)		총자산, 경영자본, 유형고정자산, 자기자본, 매출액, 부가가치, 종업원수, 총차입금, 당기순이익, 총비용, 감가상각비, 업종
수익성지표군(37개)	수익/자본(18개)	총자본경상이익률, 총자본순이익률, 총자본영업이익률, 기업경상이익률, 기업순이익률, 경영자본영업이익률, 경영자본순이익률, 자기자본경상이익률, 자기자본순이익률, 자본금경상이익률, 자본금순이익률, 배당률, 자기자본배당률, 배당성향, 적립금비율, 유보액/총자산, 유보액/납입자본, 사내유보율
	비용/수익(9개)	매출액총이익률, 매출액영업이익률, 매출액경상이익률, 매출액순이익률, 수지비율, 영업비용, 매출원가율, 영업외비용대매출액비율, 금융비용대매출액비율
	비용구조(10개)	차입금평균이자율, 금융비용대부채비율, 금융비용대총비용비율, 이자보상율, 감가상각율, 감가상각비대총비용비율, 고정재무비용보상배율, 인건비대총비용비율, 조세공과금대총비용비율, 법인세부담률
안전성지표(17개)		유동비율, 당좌비율, 고정비율, 고정장기적합율, 고정장기적합율의 역, 고정자산구성율, 부채비율, 자기자본구성율, 차입금의존도, 매출채권대매입채무비율, 매출채권대상(제)품비율, 매입채무대재고자산비율, 순운전자본비율, 유동부채비율, 고정부채비율, 재고자산대유동자산비율, 단기차입금/총차입금
활동성지표(13개)		총자본회전율, 자기자본회전율, 자본금회전율, 경영자본회전율, 순운전자본회전율, 고정자산회전율, 유형고정자산회전율, 재고자산회전율, 상(계)품회전율, 원재료회전율, 재공품회전율, 매출채권회전율, 매입채무회전율
생산성지표(16개)		1인당부가가치증가율, 1인당매출액증가율, 1인당인건비증가율, 고정장비율, 기계장비율, 자본집약도, 총자본투자효율, 설비투자효율, 기계투자효율, 부가가치율, 노동소득분배율, 이윤분배율, 자본분배율, 1인당부가가치, 1인당매출액, 1인당인건비
현금흐름(6개)		현금흐름/총부채, 현금흐름/고정부채, 현금흐름/차입금, 현금흐름/총자본, 현금흐름/매출액, 현금흐름/유동부채

3.3. 학습자료의 전처리

수집된 자료들을 이용하여 먼저 MDA와 C4.5만을 이용한 예비분석을 하였으며 결과를 <표 4>에 나타내었다. 예비분석을 실시한 이유는 수집된 학습자료의 성격을 파악하고 신경망에 사용될 입력 변수들을 결정하기 위함이었다. 하지만 <표 4>에서 볼 수 있듯이 MDA나 C4.5 모두 학습자료에 대해서는 비교적 높은 정확도를 보였지만, 검증자료에 대해 높은 에러율을 나타내고 있어, 신용등급 예측함수로서의 기능을 전혀 수행할 수 없음을 볼 수 있다. 특히, C4.5는 MDA에 비해서 학습자료에 대한 예측을, 즉 학습율이 매우 높음에도 불구하고, 검증집합에 대해서는 오히려 MDA에 비해서도 매우 낮은 신용등급 예측의 정확성을 나타내고 있는데, 이는 학습에 있어서 과잉적합의 전형적인 예라고 보여진다.

<표 5> 예비분석의 결과 (예측율, %)
(DT =Decision Tree)

분석 방법	훈련 집합			검증 집합		
	MDA	C4.5		MDA	C4.5	
		DT	Rule		DT	Rule
'92	70.3	94.7	83.0	46.6	16.1	25.9
'93	47.3	93.3	72.2	42.1	25.9	29.6
'94	85.0	96.4	78.1	58.1	51.7	42.1
평균	67.5	94.8	77.7	49.0	31.2	32.5

이와 같은 과잉적합 현상의 원인을 찾기 위해 학습자료의 내용을 면밀히 검토한 결과 다음과 같은 세 가지 원인이 추정되었다. 첫 번째는 학습자료 내부에 이상치(Outliers)가 많이 존재하여 추정된 분류함수의 일반화 능력을 크게 떨어뜨리는 것이다. 두 번째는 학습자료내에 상당히

많은 Missing Value들이 존재한다는 사실로 실제 Missing Value가 발생한 자료 수는 92년 26개, 93년 27개, 94년 25개였다. 마지막으로 선정된 입력변수들이 가질 수 있는 값의 크기 및 범위의 차이가 매우 심하다는 것이다. 즉, 변수들간 스케일(Scale)의 차이가 심하여 변수들의 판별력을 추정하는데 어려움이 있을 것으로 예상되었다.

따라서, 학습자료가 갖는 문제점을 해결하기 위해 수집된 자료들을 분류함수의 학습에 사용하기 전에 전처리 과정을 수행하였다. <그림 5>은 학습자료의 전처리 과정에서 통계분석 프로그램인 SAS의 단일변수 Box-Plot을 이용하여 각 재무변수들이 갖는 이상치들을 제거하는 과정을 나타낸 것이다. 전처리 작업 대상이었던 95개의 재무변수들 중에서 이상치가 발생하지 않았던 변수는 92년 9개, 93년 13개, 94년 11개에 불과하여 <표 4>에서와 같이 예비분석의 결과가 나쁠 수밖에 없음을 알 수 있었다. 이상치 제거 과정은 최초자료에서 5개미만의 관찰값이 해당 재무변수의 분포의 편차에 심한 영향을 미칠 경우에는 이들을 제외한 상한과 하한 값을 구하여 이상치를 보인 기업의 재무변수들을 상하한 값을 가지도록 조정하였다. 이와 같은 조정 과정은 경우에 따라 5번까지 반복 수행이 필요하였다. 또, 수집된 학습자료의 수가 많지 않음을 감안하여 Missing Value가 있는 경우에는 이상치가 제거된 자료들에 대해 동종업종, 동일 신용등급의 평균값으로 설정하여 가능한 학습자료의 손실을 방지하였다.

각 재무변수들이 갖는 값들의 크기 및 범위의 심한 차이는 분류함수의 추정에 문제를 발생시킬 수 있다. 따라서, 타변수들에 비해 변수 값들의 크기와 범위가 상대적으로 매우 큰 11개의 규모지표와 4개의 생산성지표들을 범주형(Categorical)

변수로 변환하였다. 이 때는 업종을 제외한 나머지 변수들에 대해서는 십분위수를 적용하여 10개의 범주로 구분하여 1에서 10사이의 한 값을 갖도록 하였다.

Histogram	Number	Boxplot
1250+*	1	*
.		
.*		
. **	3	*
*****	9	0
-50+*****	194	+---+---
-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----	107	+---0---+---
* may represent up to 5 counts		
Histogram	Number	Boxplot
350+*	1	*
.*	2	*
.		
.**	3	*
.*	1	*
* 130+*	2	*
.*	1	0
.*	2	0
.**	3	0
*****	9	
*****	27	
*****	61	+-----+
*****	94	+-+--+
*****	78	+-----+
*****	22	
*** . .	6	
-90+*	1	0
-----+-----+-----+-----+-----+-----+-----+-----+-----+-----		
* may represent up to 2 counts		

(그림 5) Box-Plot에 의한 학습자료의 전처리 (1992년 재고자산증가율의 이상치 제거과정 예)

3.4. 신경망을 위한 입력변수의 선정

전처리에 의해 준비된 학습자료들에 대해 네 가지 귀납적 학습방법들에 의한 신용등급 분류 함수를 추정하기 위하여 각 학습알고리즘들에 대해 입력변수를 선정하여야 한다. 이를 위해 MDA와 C4.5를 먼저 사용하여 분석한 후 그 결과를 이용하여 신경망의 입력변수들을 결정하여 MLP와 CCN의 분류성능을 분석하는 순서로 진행하였다. 이는 단계적 절차를 사용한 MDA나 C4.5는 입력 가능한 모든 변수들을 검토하여 판별력이 높은 변수들만으로 분류함수를 구성하기 때문에 사전에 입력변수의 수를 확정할 필요가 없지만, 신경망의 경우는 사전에 입력으로 사용될 변수들을 확정하여야 하기 때문이다.

<표 5>는 5개의 훈련집합들에 대해 각각 추정된 MDA과 C4.5의 분류함수에 선정된 입력변수들의 개수를 지표별로 분류하여 평균값을 연도별로 구한 것이다. 입력변수로서 가장 많이 선택된 변수들은 수익성 지표에 관련된 재무변수들이며 그 다음이 규모에 관련된 지표들이다. 현재 국내 사정과 신용평가 실무자들의 의견을 종합해 볼 때 규모에 관한 지표보다는 현금흐름에 관한 재무변수들을 더 중요시하고 있는 것과는 상이한 결과가 나왔다. 이는 본 연구의 대상이 기업어음의 신용등급 즉 단기채권에 대한 원리금 상환능력을 평가한 것임을 감안할 때 의외의 결과이지만, 국내 금융관행을 고려할 때 대기업이 단기차입에 있어 유리한 점이 반영된 것으로 볼 수도 있다.

<표 5> 선정된 입력변수 수의 지표별 평균

	92년			93년			94년		
	MDA	C4.5	신경망	MDA	C4.5	신경망	MDA	C4.5	신경망
성장성	1.8	2.6	1	3.2	2.4	3	1.4	1.8	1
규모	2.6	4.8	3	2.4	5.0	3	2.6	4.6	4
수익성	5.4	4.8	5	6.2	6.4	6	5.6	5.4	6
안전성	2.6	0.6	1	1.8	0.8	1	2.4	1.8	1
활동성	2.2	1.0	1	1.8	0.6	1	2.0	0.8	1
생산성	2.4	2.0	5	3.0	2.4	4	2.6	2.4	0
현금흐름	1.6	0.4	1	1.2	0.6	0	0.4	0.2	0
합계	18.6	16.2	17	19.6	18.2	18	17.0	17.0	15

<표 5>의 신경망에 해당하는 열은 MDA와 C4.5의 결과를 이용하여 신경망에의 입력변수로 결정된 변수들의 개수를 나타낸 것이다. 신경망의 입력변수를 결정하기 위해서는 MDA나 C4.5가 적어도 해당 년도의 3개 훈련집합에 대해 입

력변수로 선정된 경우에 한정하였다. 이러한 신경망의 입력변수 선정과정은 <표 6>에 정리하였다. <표 6>에서 검은 점들은 하나의 훈련집합에 대해 해당 재무비율이 입력변수로 선정되었음을 나타낸 것으로, 검은 칸으로 표시한 것은 3개

<표 6> 신경망의 입력변수로 선택된 변수들

지표명	변수명	빈 도 수					
		92년		93년		94년	
		MDA	C4.5	MDA	C4.5	MDA	C4.5
성장성	유형고정자산증가율				●●●	●●●●●●	●●●
	자기자본증가율	●●●●●		●●●●	●●●		
	순이익증가율			●●●●			
규모	총자산				●●●●		●●●
	자기자본	●●●		●●●●	●●●●●●	●●●●	●●●●●●
	총차입금					●●●	
	당기순이익	●●●●●	●●●●	●●●●	●●●●		●●●●
수익성	업종		●●●				
	총자본순이익율			●●●			
	총자본영업이익율		●●●				
	자본금경상이익율	●●●					
	배당율				●●●		●●●●
	유보액/총자산	●●●		●●●●	●●●●	●●●	●●●
	유보액/납입자본	●●●	●●●●●	●●●	●●●		●●●●●
	사내유보율			●●●●●	●●●	●●●	
	매출액영업이익율	●●●●●					
	금융비용대매출액비율					●●●	
안정성	감가상각율					●●●	
	감가상각비대총비용비율				●●●		
	자기자본구성율	●●●					
	매입채무대채고자산비율						●●●
활동성	재고자산대유동자산비율			●●●●			
	순운전자본회전율						●●●
	매출채권회전율	●●●●●	●●●	●●●●			
생산성	1인당부가가치증가율	●●●		●●●			
	1인당인건비증가율			●●●			
	기계장비율					●●●●●	
	총자본투자효율				●●●		
	설비투자효율	●●●					
	기계투자효율	●●●				●●●	
	1인당부가가치		●●●		●●●		
1인당매출액		●●●					
현금흐름	현금흐름/총자본	●●●●					
방법별 합계		13개	7개	12개	12개	9개	9개
합 계		17개		18개		15개	

이상의 훈련집합에서 MDA와 C4.5가 동시에 입력변수로 선정한 재무비율들이다. 이와 같은 입력변수의 선정방법은 신경망의 입력변수로 '92, '93년의 경우는 생산성 관련지표가 너무 많이 선정되었고, '93, '94년의 경우에는 현금흐름에 관한 지표가 하나도 선정되지 못하는 결과를 가져왔다. 하지만, 신경망의 입력변수들을 기계적으로 선정하여 사용한 이유는 본 연구의 주안점이 네 가지 귀납적 학습방법들의 분류성능을 비교 분석하기 위한 것이므로 특성추출기, 즉 입력변수의 선정에 따른 영향을 가능한 배제시키기 위함이었다.

4. 분류성능의 분석

4.1. 분류성능의 연도별 평가

귀납적 학습방법들의 신용평가 자료에 대한 분류성능 평가는 연도별 평가와 시계열 평가의 두 가지 방식으로 이루어 졌다. 연도별 평가는 <표 2>에서와 같이 분리된 학습집합에 대해 분류함수를 추정한 후, 검증집합에 대해 신용등급에 대한 설명에 앞서 신경망의 훈련에 관련된 예측의 정확성을 측정하는 방식이다. 실험 결과 사항들을 먼저 정리하면 다음과 같다.

MLP를 학습시키기 위해서는 은닉층의 노드 수를 결정하여야 하는데, 본 연구에서는 입력노드와 은닉층의 노드 수를 같게 놓고 시작하여 점차 줄여가면서 분류성능을 테스트하였다. MLP의 분류성능은 매 100 Epoch마다 검증집합에 대해 테스트하였는데 '94년의 경우는 500 Epoch에서 가장 좋은 결과가 나왔고 나머지 경우에는 100 Epoch에서 가장 좋은 예측결과를 보였다.

CCN의 경우에도 아래 식과 같이 정의되는 ErrorIndex를 기준으로 CCN의 분류성능을 학습진행에 따라 추적하였다[Fahlman & Lebiere, 1990]. 즉, ErrorIndex가 1일 때부터 시작하여 0.1씩 줄어들 때마다 학습회수(Epoch)와 생성된 은닉노드의 수를 기록한 후 학습정도를 측정하였다. ErrorIndex가 0.1 이하일 경우에는 0.01씩 감소시켰다.

실험결과 5개의 훈련집합들에 대해 가장 좋은 적응률 보인 경우를 <표 7>에 정리하였다. <표 7>의 결과를 살펴 볼 때 CCN의 학습과정이 매우 불안정하다는 것을 알 수 있다. 즉, 훈련집합에 따라 ErrorIndex, Epoch 및 생성된 은닉층 노드 수의 심한 변화를 볼 수 있다. 이는 CCN이 학습자료에 대해 매우 민감하게 작용한다는 측면도 있지만 학습자료 자체의 변화도 매우 심하다는 것을 반증하는 것이다.

$$ErrorIndex = \sqrt{\frac{TrueError}{NOutputValue \times StdDev}}$$

$$where, \quad TrueError = \sum_p \sum_i (\text{예측값} - \text{목표출력값})^2$$

$$NOutputValue = \text{출력노드 수} \times \text{학습패턴 수}$$

$$StdDev = \sqrt{\text{출력노드 수} \times \sum Output^2 - (\sum Output)^2}$$

<표 7> CCN 실험에서의 Error Index, Epoch 및 생성된 은닉노드 수

	연 도	학습 집합 1	학습 집합 2	학습 집합 3	학습 집합 4	학습 집합 5	평 균
ErrorIndex	92년	0.5	0.7	0.8	0.5	0.3	0.56
	93년	0.7	0.6	0.3	0.6	0.08	0.45
	94년	0.5	0.05	0.4	0.5	0.4	0.37
Epoch	92년	331	49	17	321	686	280.80
	93년	105	199	724	190	2274	698.40
	94년	319	2451	441	270	468	789.80
은닉노드의 수	92년	3	0	0	3	6	2.40
	93년	1	2	7	2	26	7.60
	94년	3	26	4	3	4	8.00

<표 8>은 네 가지 귀납적 학습방법들을 신용 평가 자료에 적용한 실험결과를 정리한 것이다. 훈련집합에 대해서는 MDA에 비해 C4.5, 다계층 퍼셉트론, CCN이 높은 적응률을 보인 반면 검증집합에 대한 적응률에서는 우월한 결과를 보이지 못했다. 비록 CCN의 결과가 가장 좋은 것으로 나타났지만 통계적으로 유의한 수준은 아니었다. 또 모든 학습 알고리즘들이 검증집합에 대한 적응률이 훈련집합에 비해 30~40% 정도 씩 하락하는 현상을 볼 수 있으며, 하락률은 신경망의 경우가 더 크다는 점이다. 이는 학습자료의 전처리에 의해 검증집합에 대한 예측력이 상당히 개선되었음에도 불구하고 여전히 과잉적합의 여지가 있음을 나타내는 것이다.

<표 8>에서 또 지적할 사실들은 C4.5의 경우 가지치기를 한 의사결정수가 가지치기를 하지 않은 경우에 비해 검증집합에 대한 적응률이 더 좋았다는 점이다. 한편 생성규칙(Production Rule)의 경우에는 검증집합에 대한 적응률의 하락이 상대적으로 적어 일반화 능력이 좋다고 평가할 수도 있으나 전체적인 적응률에서 MDA보다 나을 것이 없어 규칙의 생성방법론을 보완될 필요가 있는 것으로 생각된다. 본 연구에서 사용된 신경망 모형들인 MLP나 CCN의 경우에도 주어진 훈련집합에의 학습능력이 매우 뛰어나 과잉적합의 문제를 적절히 제어하여 예측율을 높이는 방안의 모색이 필요함을 보여주고 있다.

〈표 8〉 실험결과 I : 연도별 분석

연 도	귀납적 학습방법들		평균적중률	
			훈련집합	검증집합
92년	MDA		78.8%	56.8%
	C4.5	Unpruning Decision Tree	87.2%	57.8%
		Pruning Decision Tree	82.2%	59.6%
		Production Rule	64.6%	49.6%
	신경망	MLP	90.6%	53.6%
		Cascade-correlation	90.5%	58.0%
93년	MDA		79.8%	57.4%
	C4.5	Unpruning Decision Tree	92.2%	55.0%
		Pruning Decision Tree	87.6%	56.4%
		Production Rule	73.2%	55.6%
	신경망	MLP	92.2%	56.4%
		Cascade-correlation	83.6%	57.6%
94년	MDA		85.2%	58.8%
	C4.5	Unpruning Decision Tree	93.8%	54.2%
		Pruning Decision Tree	89.8%	55.4%
		Production Rule	75.8%	55.0%
	신경망	MLP	92.2%	55.8%
		Cascade-correlation	95.6%	60.6%

4.2. 시계열 분석에 의한 성능평가

귀납적 학습방법들의 신용평가 자료에 대한 시계열적 분류성능 평가는 주어진 연도의 신용평가 자료 전체를 훈련집합으로 사용하여 분류함수를 추정한 후 다음 연도 자료 전체를 검증집합으로 사용하여 각 학습알고리즘 별로 신용등급 예측의 정확성을 측정하는 방식이다. 따라서, 훈련집합이나 검증집합 내의 자료 수는 <표 2>

의 연도별 합계란에 있는 숫자이며, <표 9>는 실험 결과를 정리한 것이다. 시계열 평가의 결과는 연도별 평가에 비해 전체적으로 예측성능이 향상되었으며 신경망의 경우 과잉적합 현상도 많이 줄어들었다. 이는 기본적으로 훈련집합 내의 학습자료의 수가 증가했기 때문으로 생각된다. 연도별 평가의 경우와 마찬가지로 CCN의 성능이 가장 좋은 것으로 나왔으나 예측성능의 차이는 역시 통계적으로 유의하지는 않았다.

〈표 9〉 실험결과 II : 시계열 분석

연 도	실험방법		평균적중률	
			훈련집합	검증집합
92년 ↓ 93년	MDA		80%	67%
	C4.5	Unpruning Decision Tree	67%	61%
		Pruning Decision Tree	67%	61%
		Production Rule	65%	58%
	신경망	MLP	82%	64%
		Cascade-correlation	88%	67%
93년 ↓ 94년	MDA		76%	59%
	C4.5	Unpruning Decision Tree	80%	59%
		Pruning Decision Tree	79%	62%
		Production Rule	71%	57%
	신경망	MLP	91%	60%
		Cascade-correlation	93%	62%

4.3. 실험결과에 대한 토의

신용등급 예측율이 60%를 약간 상회하는 정도는 실제 상황에서 예측함수로 사용하기에는 부족해 보인다. 연도별 평가와 시계열 평가를 비교해 볼 때 시계열 평가의 경우 전체적인 예측성능이 향상되고 특히 신경망의 과잉적합 현상이 축소됨을 감안할 때 학습자료의 수를 증가시키는 것이 예측성능을 향상시키는데 도움이 될 것으로 예상되지만 본 연구에서는 주어진 자료 내에서 최선의 분석이 이루어지도록 노력하였다. 그럼에도 불구하고 <표 6>에서 볼 수 있듯이 분류함수에 포함되는 입력변수들이 연도별로 상이하다는 사실은 학습자료내에 상당한 변

화요인들이 내재되어 있어 예측능력의 향상을 저해하는 것으로 해석할 수 있다.

학습자료내 변화요인의 하나로 연도별 피평가 기업의 신용평가 등급의 일관성이 유지가 되지 못했다는 점이 지적될 수 있는데, 동일 기업에 대한 동일 신용평가기관의 신용평가 등급을 3개년에 걸쳐서 확보할 수 있었던 기업의 수가 매우 적었다. 이는 본 연구의 학습자료 수집과정에서 발생한 한계로 생각할 수 있다. 하지만, 연도별 평가의 경우 동일 연도 동일한 학습자료를 임의추출에 의해 훈련집합과 검증집합으로 구분하였음에도 훈련집합별로 학습결과에 많은 차이를 보이는 것은 학습자료 자체의 내부적 일관성

에 문제가 있는 것으로 생각되며 이러한 문제는 학습자료의 전처리과정 즉 입력변수들 내의 이상치 제거 또는 범주형 변수로의 변환 등으로는 해결할 수 없음을 의미하는 것이다.

이러한 현상에 대해서는 다음과 같은 해석이 가능하다. 첫 번째는 본 연구에서 사용된 자료들이 신용평가 기관들이 등급을 발표했던 시점에서의 해당기업의 재무상태를 반영하지 못했다는 사실이다. 이는 본 연구의 근본적인 한계로서 자료수집에 있어 FAS를 사용함으로써 등급 발표 년도 말의 재무제표를 사용할 수밖에 없었기 때문이다. 두 번째는 본 연구에서 사용된 입력변수들이 재무변수에 치우쳐 있다는 점이다. 본 연구에서 사용된 입력변수들이 재무변수에만 치우쳐 있다는 점은 국내 기업들의 재무제표가 해당 기업의 재무상태를 정확히 반영하고 있지 못하다는 것과 제 2절 신용평가 절차에서 설명한바 같이 신용평가는 단순히 해당기업의 재무변수만으로 평가되는 것은 아니라는 두 가지의 해석을 모두 가능하게 한다. 특히 국내의 금융관계 현실을 감안할 때 재무변수보다도 오히려 거시경제변수의 영향이나 계열관계와 같은 비재무적 변수가 더 중요한지도 모른다[이재식과 한재홍, 1995; 김광용외 2인, 1998]. 따라서, 본 연구에서 재무적 변수에 치우친 분석을 한 것은 신용평가에 있어 좋은 예측력을 기대하기 어렵게 하는 요인이다.

마지막으로 실험분석 결과 중 몇 가지 지적한다면 다음과 같다. C4.5의 경우 예상한대로 가지치기를 한 의사결정수의 경우가 일반화 능력이 좋았으나, 생성규칙의 경우는 일반화 능력이 많이 떨어지는 현상을 보였다. 이는 학습자료의

성격에 의해서도 많은 영향을 받겠지만 근본적으로 프로덕션 규칙의 생성방법론을 보완될 필요가 있는 것으로 생각된다. CCN의 경우에는 주어진 훈련집합에의 학습능력이 매우 뛰어나므로 과잉적합의 문제를 적절히 제어하는 것이 쉽지 않다는 것이다. 하지만 C4.5나 CCN이 MDA에 비해 좋은 결과를 보인 것은 앞으로 신용평가 예측함수의 추정에 유력한 방법론으로 사용될 수 있음을 입증한 것으로 볼 수 있다.

5. 결론

본 연구에서는 분류작업에 있어서 귀납적 학습방법들의 분류성능을 비교 분석하였다. 사용된 귀납적 학습방법들은 MDA, C4.5, MLP 및 CCN이 사용되었으며, 학습자료로는 국내 기업어음에 대한 신용평가자료를 사용하였다. 분류작업에 있어서 특성추출기와 분류기의 상호보완작용을 감안하여 귀납적 학습방법들에 대한 입력변수의 선정에 있어 가능하면 공정한 특성추출기로서의 역할을 할 수 있도록 본 연구에서 MDA과 C4.5의 결과를 신경망(MLP와 CCN)의 입력변수를 선정하는데 이용하였으며, 학습자료에 대한 전처리 작업을 수행하여 학습자료내의 이상치들을 제거하였다.

'92, '93, '94년도 국내 신용평가자료에 대해 CCN이 가장 좋은 예측력을 보였지만 통계적으로 유의하지는 않았다. 하지만 아직 국내 신용평가자료에 대해 C4.5와 CCN을 적용한 연구가 없었던 점을 감안하면 본 연구의 결과 C4.5와 CCN의 분류함수로서의 유용성은 입증되었다고 볼 수 있다. 특히 사용상의 어려움은 있지만

CCN의 활용가능성은 앞으로 계속 연구되어야 할 과제이다. 또 입력변수의 선정에 있어 재무변수들에 한정된 한계가 있기는 하지만, 본 연구에서도 귀납적 학습방법은 사용된 자료가 갖는 한계를 넘어설 수 있는 없다는 사실은 확인하였다.

마지막으로 신용평가 예측문제와 관련하여 언급할 사항은 국내 신용평가자료를 분석함에 있어서는 거시경제 변수나 비재무적변수의 포함을 적극 고려해야한다는 점과 학습자료의 구성에 있어 보다 신중한 접근이 필요하다는 것이다. 특히 현실성 있는 신용평가예측모형의 수립을 위해서는 보다 많은 학습자료의 수집과 함께 학습자료의 전처리 과정이 반드시 필요하다는 것이다. 학습자료의 전처리 과정에서도 본 연구에서 수행하였던 이상치 제거나 변수의 변환만이 아니라 학습자료내에 내재되어있는 자료들간의 불일치를 제거하는 것이 예측함수의 예측력을 높이는 지름길로 생각한다. 이를 위해서는 신용평가에 적절한 Data Screening 방법[Versaggi, 1995]들에 대한 연구가 필요하다. 또, Data Screening을 수행할 경우에는 포기하여야 할 학습자료들이 많이 발생하게 되므로 충분한 학습자료의 수집이 필수적이다.

참 고 문 헌

김광용, 손광기, 홍온선, "Data Mining 기법들과 전문가들로부터 추출된 지식에 관한 실증적 비교 연구", *한국전문가시스템학회지*, 제4권 1호, (1998), 41-58.

이재식, 한재홍, "인공신경망을 이용한 중소기업 도산예측에 있어서의 비재무적 정보의 유용성 검증", *한국전문가시스템학회지*, 제1

권 1호, (1995).

한국기업평가, *기업어음 신용등급가이드*, 한국기업평가주식회사, (1992-1994).

한국신용평가, *기업어음 신용등급가이드*, 한국신용평가주식회사, (1992-1994).

한국상장회사위원회, *상장회사총람*, 한국상장회사위원회, (1996).

한국은행 여신관리국, *판별분석에 의한 기업평가방법*, (1982).

Altman, E., & S. Katz, "Statistical Bond Rating Classification Using Financial and Accounting Data", *Proc. of the Conf. on Topical Research in Accounting*, New York University, School of Business, N.Y., (1976).

Blayo, F., Y. Cheneval, A. Guerin-Dugue, R. Chentouf, C. Aviles-Cruz, J. Madrenas, M. Moreno, & J.L. Voz, "Deliverable R3-B4-P - Task B4: Benchmarks", *Technical Report, Elena-Nerves II*, ESPRIT-Basic Research Project Number 6891, June, (1995).

Dutta, S. & S. Shekhar, "Bond Rating: A Non-Conversative Application of Neural Networks", *Proc. of the IEEE Conf. on Neural Networks*, San Diego, CA., (1988), II443-450.

Falman S.E., "Faster-learning Variations on Backpropagation: An Empirical Study", *Proc. of Connectionist Models Summer School*, (ed) D. Touretzky, G. Hinton, and T. Sejnowski, San Mateo, CA:Morgan Kaufmann, (1988).

Falman S.E. & C. Lebiere, "The Cascade Correlation Learning Architecture", *Technical Report*, CMU-CS-90-100, (1990).

Geman, S. & E. Bienenstock, "Neural networks and the Bias/Variance Dilemma", *Neural*

- Computation*, Vol. 4, (1992), 1-58.
- Garavaglia, S., "An Application of a Counter-propagation Neural Network: Simulating the S&P Corporate Bond Rating System", *Proc. of the 1st int'l Conf. on AI Applications on Wall Street*, IEEE Computer Society Press, Los Alamitos, CA, (1991).
- Hair, J.F., R.E. Anderson, R.L. Tatham, & W.C. Black, *Multivariate Data Analysis*, 4th ed, Prentice Hall, Englewood Cliffs, New Jersey, (1995).
- Han, I. & W.C. Jhee, "Intelligent Credit Rating System", *Proceedings of 93 Pan Pacific Conference on Information Systems*, May 30 - June 1, (1993), pp267-274.
- Jhee, W.C., "Learning Agency Judgement for CP Rating: A Comparative Study Between Statistical Method and Connectionist Network", *Hong Ik Review*, (1989), 601-613.
- Kaplan, K. S. & G. Urwitz, "Statistical Models of Bond Ratings: A Methodological Inquiry". *Journal of Business*, Vol.52 No.2, (1979), 231-261.
- Klecka, W., *Discriminant Analysis*, SAGE Publications, Beverly Hills, London, (1981).
- Kwon, Y., I. Han & K. Lee, "Ordinal Pairwise Partitioning(OPP) Approach to Neural Networks Training: Bond Rating Case", *Intelligent Systems in Accounting, Finance and Management*, (1996).
- Lee, K., I. Han & Y. Kwon, "Neural Networks Applications for Business Classification: Structured Approach to Neural Networks Simulations(SANNS)", *한국경영정보학회 춘계 학술대회*, (1994), 129-148.
- Lippmann, R.P., "An Introduction to Computing with Neural Nets", *IEEE ASSP Magazine, April*, (1987), 4-22.
- Michie, D., D.J. Spiegelhalter, & C.C. Taylor, (Eds), *Machine Learning, Neural and Statistical Classification*, Ellis Horwood Series in AI, England, (1994).
- Moody, J. & J. Utans, "Architecture Selection Strategies for Neural Networks: Application to Corporate Bond Rating Prediction", in Refenes A. N. (eds), *Neural Networks in the Capital Markets*, John Wiley & Sons, (1994).
- Murphy, P.M. & D.W. Aha, *UCI Repository of Machine Learning DataBases*, Irvine, U. of California, Dept. of Information and Computer Science, (1991).
- Pao, Y.H., *Adaptive Pattern Recognition and Neural Networks.*, Addison-Wesley, (1988).
- Pinches, G. & K. Mingo, "A Multivariate Analysis of Industrial Bond Ratings", *The Journal of Finance*, Vol. 28, (1975), 1-18.
- Prechelt, L., "Investigation of the CasCor Family of Learning Algorithms", *Neural networks*, Vol. 10, No.5, (1997), 885-896.
- Quinlan, J. R., *C4.5 : Programs for Machine Learning*, Morgan Kaufmann Publishers, San Mateo, California, (1992).
- Russel, S. & P. Norvig, *Artificial intelligence: A Modern Approach*, Prentice-Hall, (1995).
- Rumelhart, D.E. & J.L. McClelland, *Parallel Distributed Processing: Explorations in Microstructure of Cognition*, MIT Press, (1986).

Surkan, A. & J. Singleton, "Neural Networks for Bond Rating Improved by Multiple Hidden Layers", *Proc. of IEEE Int'l Conf. on Neural*

Networks, San Diego, CA, (1990), II157-162.
Versaggi, M.R., "Understanding Conflicting Data", *AI Expert*, Vol. 10, No. 4, (1995), 21-25.