

보건행정학회지 : 제 10 권 제 2 호
Korean J. of Health Policy & Administration
Vol. 10, No. 2, 1-21, June 2000

병원도산의 예측모형 개발연구

정기택[†], 이훈영

경희대학교 의료경영학과

<Abstract>

Developing a Combined Forecasting Model on Hospital Closure

Ki-Taig Jung, Hoon-Young Lee

Dept. of Health Services Management Kyung Hee University

This study reviewed various parametric and nonparametric methods for forecasting hospital closures in Korea. We compared multivariate discriminant analysis, multivariate logistic regression, classification and regression tree, and neural network methods based on hit ratio of each model for forecasting hospital closure. Like other studies in the literature, neural network analysis showed highest average hit ratio. For policy and business purposes, we combined the four analytical methods and constructed a forecasting model that can be easily used to predict the probability of hospital closure given financial information of a hospital.

Key Words : Hospital closure, forecasting model, logistic regression, neural network, CART

본 연구는 1998년도 학술진흥재단 인문·사회과학분야 중점영역 연구비 지원에 의해 수행되었음

† 교신저자 : 정기택(02-961-0489, ktjung@nms.kyunghee.ac.kr)

I. 서 론

기업부실 예측과 관련된 연구는 특정 산업이 재편되거나 한 국가가 경제위기를 경험하면서 그 중요성이 부각되어 왔다. 기업도산에 관한 연구는 다양한 통계적인 방법론과 인공지능 등의 기법을 도입하는 등 실증분석 기법의 발전측면에서도 많은 기여를 했으며, 기업여신 여부를 결정하거나 기업의 인수합병 등 협업에서도 광범위하게 활용되고 있다. 기업부실예측에 대한 연구와는 대조적으로 병원도산 및 부실예측에 관한 연구는 그 역사와 범주면에서 상당히 일천한 실정이다. 우리나라에서 기업도산에 관한 연구는 80년대후반 시작되어 90년대 중반까지 본격적으로 진행되어 왔으나, 병원도산에 관한 연구는 외환 및 경제위기를 경험하면서 많은 병원들이 도산하게 되자 1990년대 후반부터 시작되었다. 미국의 경우에도 기업도산에 관한 연구가 60년대부터 시작되었던 것과는 대조적으로 병원도산에 대한 연구는 병원산업이 대개편되었던 80년대부터 시작되었다. 병원도산 예측에 관한 연구들은 기업도산 예측에 관한 연구에 비해 다변량 판별분석이나 로짓분석 등만을 사용하는 등 분석방법론 측면에서 상당히 제한적이라고 볼 수 있다. 국내에서 발표된 병원도산 예측에 관한 연구에서도(이무식 외 1999) 다변량 판별분석, 로짓분석 및 프로빗 분석 등 전통적인 통계기법만을 활용하여 병원의 도산가능성을 예측하고 있다. 이와는 대조적으로 기업도산 예측에 관한 연구에서는 1960년 말 Beaver(1966)와 Altman(1968)등에 의해 통계적 방법으로부터 시작되어 최근에는 인공지능기법과 의사결정나무의 개념을 활용한 Classification and Regression Tree (CART)까지 활용하는 등 상당히 광범위한 범주의 분석기법들을 활용하고 있다.

병원의 부실예측과 관련된 연구는 실증기법상의 제한점 뿐 아니라 현장에서의 활용측면에서도 기업분야에 비해 상당히 낙후된 실정이다. 외국은 물론이고 우리나라에서도 중소기업에 대한 여신여부를 판단하기 위해 수만개의 재무 및 비재무자료에 기초해서 부실예측모형이 개발되고 패키지화되기도 했다. 부실병원 예측과 관련된 연구나 패키지가 개발된다면 병원산업이나 정책적인 용도로도 많은 곳에서 활용될 수 있을 것으로 판단된다. 특히 우리나라에서는 병원이 비영리법인으로서 자본시장에 의해서 그 가치를 평가받을 수 없기 때문에 중소병원에 대한 합리적인 지원기준의 개발과 같은 정책적인 측면 뿐 아니라, 부실 병원의 인수시에 가치평가 및 인수여부 결정 등 산업발전의 측면 등에 부실병원에 관한 예측모형이 활용될 수 있을 것으로 보인다.

따라서 본 논문에서는 실무적으로 활용되기 쉬운 병원의 도산예측 모형을 개발하는 것을 목표로 한다. 이를 위하여 지금까지 기업분야에서 적용되었던 전통적인 통계기법인 다변량 판별분석, 로짓분석기법 뿐만 아니라, 인공신경망분석, Classification and Regression Tree (CART)를 이용하여 병원의 도산가능성을 예측해 보았다. 도산예측율에 기초하여 이들 네가지 기법을

비교하였고 네가지 기법들을 종합한 하나의 예측모형을 구축하고자 시도하였다.

본 논문은 다음과 같이 전개될 것이다. 2장에서는 본 논문의 실증분석에 사용될 다변량 판별분석, 로짓분석과 인공신경망분석, 그리고 CART(Classification and Regression Tree)에 대한 개념적 고찰과 선행연구를 요약했다. 3장에서는 300여개 병원에 대한 경영분석자료에 대해서 네가지 분석방법을 적용시켜 각 실증분석기법별로 도산예측율을 검증하였으며, 4장에서는 이들 네가지 모형을 통합한 종합예측모형을 제시하고 본 연구의 한계점을 지적하였다. 마지막으로 5장에서는 결론을 도출하는 순으로 논지를 전개하였다.

II. 도산예측에 사용되는 제 분석기법의 고찰

1. 기존 연구에 대한 고찰

1) 기업도산에 대한 연구

기업도산 예측에 관한 연구는 1960년대 후반 Beaver(1966)와 Altman(1968)등에 의해 전통적인 통계기법을 적용하는데서 시작되었고, Deakin(1972), 박창길(1984), 정준수(1985), 황석하(1987, 1991) 등에 의해 지속되어 왔다. 이들의 기업도산 예측연구는 주로 재무비율과 같은 회계정보자료에 통계적기법을 적용한 것으로, 다변량 판별분석(MDA, Multivariate Discriminant Analysis)이 많이 이용되었다. 그러나 MDA는 독립변수들의 정규분포를 가정하고 있는 점, 검증용표본과 예측용표본을 같은 기간에 걸쳐 추출함으로써 미래에 대한 예측력검증이 아니라 과거자료에 대한 판별의 타당성 검증에 그치는 경우가 많은 점 등 통계학적 한계를 가진다. 이런 MDA의 문제점을 해결하기 위하여 로짓분석(logit analysis), 프로빗분석(Probit analysis) 등과 같은 통계적 모형들이 개발되었으며, 통계기법을 의사결정나무와 결합시킨 Classification and Regression Tree(CART)기법이 개발되기도 했다. 최근에는 인공지능을 이용한 인공신경망 분석, 사례추론법(Case Based Reasoning), 귀납적 학습방법 등에 의한 모형의 개발로 도산 예측과 기업신용평가 연구가 이루어지고 있다.

특히 최근의 연구를 보면 인공신경망을 이용한 모형이 기존의 통계적 모형보다 예측력이 뛰어남을 보여주고 있다. 인공신경망이 도산예측 연구에서 많이 이용되고 있는 것은 인공신경망의 특성중의 하나인 자기조정 능력 때문이다. 자기조정능력은 인간의 추론하는 능력과 유사하여 학습, 자기구성, 일반화, 훈련이라는 과정으로 이루어져 있으며, 이런 과정을 통하여 학습된 인공신경망은 새로운 문제 또는 새로운 자료에 대하여 예측을 할 수 있는 능력을 의미한다 (Nelson과 Illingworth, 1992).

Odom과 Sharda(1990)는 MDA와 인공신경망 모형을 기업도산예측에 적용하여 그 성과를 비교하였다. 인공신경망 모형으로 하나의 은닉층을 갖는 모형을 사용하였으며, 실험 결과 인공신경망 모형이 81.48%, 판별분석이 59.26%로서 인공신경망 모형이 보다 우수한 예측력을 보였다. 이건창(1993)은 MDA의 방법론적, 통계학적 단점을 극복하고자 인공지능 기법에 기초한 귀납적 학습방법 및 인공신경망 모형을 제시하였다. 이러한 모형의 실증분석 결과 인공신경망 모형이 다른 모형에 비하여 높은 예측정확성을 가지고 있고 귀납적 학습방법은 인공신경망 모형보다 낮은 예측정확성을 보이지만 MDA보다는 높은 예측정확성을 가지고 있음을 제시하고 있다.

1990년대에 들어서면서 재무나 회계분야에 있어서 기존의 통계적방법이나 인공신경망의 방법과는 다른 사례기반추론방법(Case-Based Reasoning : CBR)이 등장하여 좋은 성과를 보이고 있다. CBR은 사례의 데이터베이스화를 통해 가장 유사한 사례의 추출로 새로운 문제의 해결을 유추하는 방법이다. 조홍규 등의 연구(1994)에서는 1991년부터 1993년 사이에 도산한 기업 142개 비도산기업 142개업체를 대상으로 MDA와 인공신경망, 그리고 CBR 을 도산예측에 적용하여 각각의 예측능력을 비교하였다. MDA는 전통적인 통계적 방법으로 기존의 연구에서 가장 많이 사용되었던 것이고, CBR은 예측을 위한 주요변수를 결정하고, 유사성을 계산하여 유사성을 가진 사례들의 결합하는 세가지 하부과정을 통하여 예측결과를 제시하는 것이다. 인공신경망모형은 역전파학습모형을 사용하여 검증한 결과 MDA와 CBR사이에는 예측력의 차이가 유의하지 않았으나, 신경회로망의 결과는 다른 두가지 모형보다 우수하였다.

2) 병원도산에 관한 연구

미국의 보건행정학계에서는 도산병원이나 재정상 문제가 있는 병원들에 관해서 1980년대부터 많은 관심을 보였다. 1980년대 초반의 미국 병원업계에서는 도시소재 병원들의 도산회수가 시골병원에 비해서 월등히 높았기 때문에 도산과 병원소재지간의 관계에 대해서는 별다른 관심을 보이지 않았다 (Mullner et al 1982, Kenney and Dumas 1983). 몇몇 학자들은 (Hadley et al. 1982, Sager 1983) 도시소재 병원의 도산에 대해서만 연구를 했고 도·농간의 구분에 대해 분석한 연구는 Longo와 Chase(1984)와 Kelly와 O'Brien(1983) 등이 있다. 80년대 후반에 들면서 도산하는 시골소재 병원의 수가 증가하면서 시골병원들의 도산원인에 대한 심층적인 분석이 수행되었다. 실증분석을 통해 발견된 도산병원들의 특성으로는 단기치료중심병원(short-term acute care hospital), 병상수가 적은 병원, 영리법인여부, 미국병원신임협회(JCAHO)의 신임여부, 장기요양시설의 보유여부 및 내원환자의 감소 등을 들 수 있다. 도산과 관련된 병원경영 환경요인으로는 높은 경쟁의 강도, 진료권역내에 높은 소수민족 비중 및 이민 및 이동으로 인한 인구구성의 변화 (Mayer et al. 1987)을 들 수 있었고 소재지별 차이로는 미국의 남부나 북동부 지역에서 다른 지역보다 높은 도산비율을 보였다. Mullner 등의 연구

(1989)에 따르면 시골소재병원들의 도산가능성이 도시소재 병원들보다 높은 이유는 단순히 시골에 소재한 것 때문이 아니라 위에서 지적된 도산 위험요인이 시골병원들에게서 더 일반적이라는 데 있다.

우리나라에서 병원도산예측과 관련된 연구는 90년대 후반 경제위기를 경험하면서 관심을 모으기 시작했다. 김영호는 1992년 병원의 생존분석을 시행하였으나 연구의 초점은 재무변수 보다는 병원내부의 구조적 변수와 외부 환경변수에 있었다. 양동현과 정두채(1998)는 경제위기 이후에 병원도산의 심각성을 발표하였다. 그 후 이무식외(1998, 1999)는 일련의 연구를 통해서 한국보건의료관리연구원에서 수집한 경영분석자료를 활용하여 판별분석, 로짓 및 프로빗 분석의 예측력에 관해 비교하였다. 본 연구에서는 아직까지 병원도산 예측에 적용된 적이 없는 인공신경망과 CART 기법을 적용한 점에서 기존 연구를 보완하는 성격을 가지며, 다양한 분석모형을 통합한 종합 예측모형을 제시한 점에서 차별화된다고 볼 수 있다.

다음에서는 본 연구의 실증분석에서 사용될 다변량 판별분석, 로짓분석, CART, 인공신경망 분석 등의 기법에 관해 설명하고자 한다.

2. 다변량 판별분석(Multivariate Discriminant Analysis : MDA)

다변량 판별분석이란 관찰치들의 특성을 나타내는 변수에 기초하여 관찰집단을 몇 가지 대조적 집단 또는 범위로 분류하는 방법이다. 환언하면 판별분석은 관찰집단을 두 개 이상의 대조적 집단으로 분류해 주는 독립변수들의 결합을 찾는 통계적 기법이다. 예를 들면, 부실기업군과 정상기업군으로 분류해 주는 여러 가지 재무비율의 결합중에 부실기업과 정상기업 두 집단을 가장 잘 판별해 주는 재무비율들의 선형결합을 찾는 것이다.

다변량 판별분석의 가정 중 가장 중요한 것은 변수들이 다변량정규분포를 따른다는 것이다. 즉 이들 변수들의 분산 공분산 행렬은 각 집단이 서로 같고, 이들 변수들의 평균은 집단간에 유의적인 차이가 있다는 가정하에서 선형판별함수 $Z_i = aX_i + bY_i$ 를 추정하는 것이다. 이 선형판별함수는 분류오차를 최소화시킬 수 있도록 추정되어진다. 이를 다음과 같은 수식으로 표현할 때 최대화하는 재무변수의 판별계수를 구하는 것이다.

$$Z_{\max} = \frac{(\overline{Z}_N - \overline{Z}_F)^2}{\sum_{i=1}^2 \sum_{j=1}^n (Z_{ij} - \overline{Z}_i)^2}$$

여기서 i ; 정상기업과 부실기업집단의 분류

j ; 집단내의 기업

\overline{Z}_N ; 정상기업집단의 판별점수 평균

\bar{Z}_F ; 부실기업집단의 판별점수 평균

Z_{ij} ; i 집단내의 j 기업의 판별점수

Z_i ; i 집단의 판별점수 평균

이를 만족하는 판별계수 a , b 의 값을 구함으로써 판별함수가 결정되고 결정된 판별함수의 예측능력을 보기 위하여 다음과 같은 분류행렬을 만들어 분석한다.

〈표 1〉

판별분석분류행

예측분류	실제분류		
	정상	부부	실
정상	a_{11}	a_{12}	
부부	a_{21}	a_{22}	

여기서 a_{11} 은 정상으로 예측하였는데 실제로 정상으로 나타난 경우, a_{22} 는 부실로 예측하였는데 실제로 부실기업으로 나타난 경우이므로 판별모형에 의한 예측이 적중한 경우이다. 그러므로 예측능력은 다음과 같이 계산되어진다.

$$\text{예측능력} = \frac{a_{11} + a_{22}}{a_{11} + a_{12} + a_{21} + a_{22}}$$

3. 로지스틱 회귀분석(Logistic Regression Analysis)

여러 개의 설명변수로 종속변수를 예측하는데 일반적으로 다변량 회귀분석을 이용한다. 하지만 종속변수가 범주형일 경우 또는 이산화를 변수일 경우 회귀분석의 가정 중 하나인 오차가 정규분포를 따른다는 기대를 할 수 없기 때문에 일반화된 정규선형모형을 사용하는 데는 무리가 있다. 이러한 경우에 사용하는 통계적 방법론이 로지스틱회귀분석(Logistic Regression Analysis)이다.

p 를 성공할 확률이라고 가정하자. logitp는 다음과 같이 정의한다.

$$\text{logit}p = \ln \frac{p}{1-p}$$

로짓은 승산비(odd ratio), 즉 성공할 확률과 실패할 확률의 비에 로그를 취한 값이다.

로지스틱 회귀분석모형은 다음과 같이 반응변수를 로짓으로 변환한 선형모형 형태로 표현

한다.

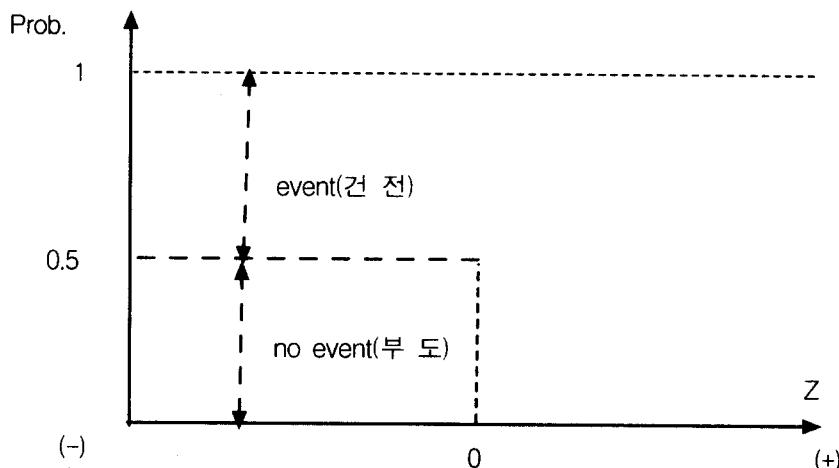
$$\text{logit } p = \beta_0 + \beta_1 X$$

이 식을 p 에 대하여 정리하면 다음의 식을 얻는다.

$$p = \frac{\exp(\beta_0 + \beta_1 X)}{1 + \exp(\beta_0 + \beta_1 X)}$$

위 식에서 얻어진 p 값은 성공할 확률을 의미하는 것이다.

이와 같이 범주형인 종속변수에 대한 직접적인 예측을, 즉 관심이 되는 사건이 발생할 확률을 통해 예측하고자하는 통계적인 방법이 로지스틱 회귀분석이다. <그림 1>은 X 값의 변화에 따른 logit p 값의 변화를 보여주고 있다.



(그림 1) logit 확률값의 변화

4. CART(Classification And Regression Trees)

CART는 의사결정규칙을 나무구조로 도표화하여 분류와 예측을 수행하는 분석방법이다. 이 방법은 분류 또는 예측의 과정이 나무구조에 의한 추론규칙에 의해서 표현되기 때문에 다른 통계적인 방법론에 비해 분석과정이나 결과해석이 쉽다는 장점이 있다. 일반적으로 의사결정나무는 탐색과 모형화라는 두 가지 특성을 가진다. 즉 판별분석 또는 회귀분석등과 같은 분석에 있

어서 사전에 이상치를 검색하거나 분석에 필요한 변수를 찾아내고 분석모형에 포함되어야 할 교호효과를 찾아내는 데 사용 될 수 있고, 그 자체가 분류 또는 예측모형으로 사용될 수 있다.

CART는 트리를 확장하는 하는 것과 유사하게, 관찰치를 한개 또는 k개의 그룹에 배분할 수 있는 이진 분류 트리를 만들어 내는 분류 기법이다. 이진분류트리는 모든 관련 관측 벡터값을 포함한 측정치 공간의 반복되는 스플리트(split)에 의해 구축된다. 이진분류트리를 구축하기 위해서는 다음의 세가지 요소를 해결해야 한다.

첫째, 분할 규칙(splitting rules)의 선택

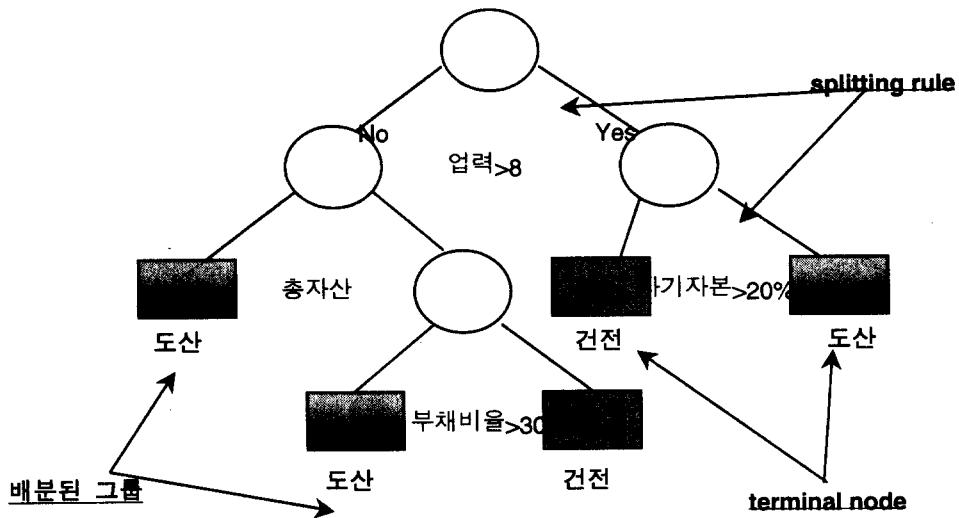
둘째, 언제 노드를 터노드(terminal node)로 선언할 것인가의 결정

셋째, 각 터미널 노드에 한 그룹을 배분하는 문제

그러므로 문제의 핵심은 분할규칙, 터미널 노드, 그리고 각 그룹의 배분을 결정하기 위해서 자료를 사용하는 방법을 아는 것이다. 위에서 언급한 세번째 문제는 간단하지만, 첫째와 둘째의 문제, 즉 좋은 분할 규칙을 찾아내는 것과 언제 분할을 멈출것인가의 문제는 그렇게 간단하지 않다. CART의 알고리즘은 최적의 분할 규칙을 선택하는 것과 터미널 노드를 선언하는 것에 초점이 맞추어져 있다.

최적의 분할 규칙을 결정하기 위한 기본 개념은 자손 노드(descendant nodes)가 부모 노드(parent node) 보다 더 순수해야 한다는 것이다. 여기서 더 순수하다는 의미는 부모 노드의 불순도(im purity)가 2개의 자손 노드의 불순도의 합보다 더 클때, 자손 노드가 더 순수하다라고 일컫는다. 그러므로 불순도의 감소를 최대화 시키는 분할 규칙을 결정하는 것이 중요하다. 그 후 터미널 노드의 선언은 스플리팅과 스탑-스플리팅 규칙(splitting and stop-splitting rule)에 의해 이루어진다. 즉, 데이터를 분할 규칙에 의해 이분하면서 트리를 확장해 나갈 때, 비터미널 노드(non-terminal node)에서 일정 수준의 불순도 감소에서 트리의 확장을 멈추고 그 노드를 터미널 노드로 선언하는 기준을 말한다. 그후 터미널 노드에 어떤 한 그룹을 배분하는 규칙은 오분류 확률의 대용치를 최소화 시키는 그룹을 그 터미널 노드에 배분하는 것이다. 대용치(resubstitution estimates)란 터미널 노드에는 실제로 여러 종류의 그룹을 가진 관찰치가 있는데, 그룹 배분 규칙에 의하여 터미널 노드에 하나의 그룹만을 배분하기 때문에, 이로 인해서 실제 관찰치 중에서 배분된 그룹과는 다른 그룹을 가진 비율이다. CART는 nonparametric 한 방법으로서, Recursive Partitioning Algorithm(RPA)의 한 형태로서 위의 세가지 문제가 해결되어질 때, 어떠한 데이터도 이진분류트리로 분석되어질 수 있다. 또한 다른 모형에 비해, 그 결과의 해석도 매우 용이하다.

CART는 주로 의료 분야 즉 심장 마비 후 생존 여부 분류 문제, mass spectra 분류 문제 등 자연과학에서 많이 사용되어져 왔다. <그림 2>는 CART를 병원도산 예측에 적용했을 때 판단 과정을 도식화하고 있다.

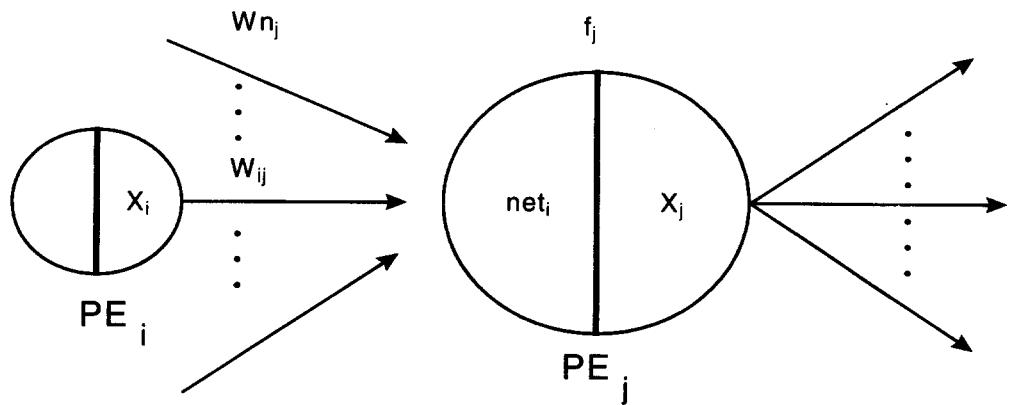


(그림 2) CART에 의한 도산예측 분석과정

5. 인공신경망 모형

인공신경망(Neural Network)은 생물학적인 뇌의 작동원리를 그대로 모방하는 방법으로 1957년에 Rosenblatt에 의해 개발된 퍼셉트론(Perceptron)이 최초의 모형이다. 인공 신경망 모형은 응용분야에 적합하도록 다양하게 개발되어 현재 그 종류가 수십가지에 이른다. 이러한 분류 방법은 입력의 형태에 따라 이진수와 연속적인 값으로 나누어지며, 이들은 훈련 방법에 따라 각각 감독학습모형과 자율학습모형으로 나눠진다(김대수, 1992). 여기서 감독학습은 인공신경망 이용자가 각 입력 자료에 대해 원하는 목표 출력값을 대응시켜 학습 자료를 구성하는 것으로 인공신경망은 학습자료내에 각 입력 자료들에 대응되는 목표 출력값을 생성할 수 있을 때 까지 연결 가중치를 조정하게 된다. 이에 반해 자율학습은 목표 출력값이 학습 자료에 주어지지 않는 것으로 주어진 입력 패턴 자체를 기억시키거나, 유사한 패턴들을 군집화시키는 데 많아 이를 이용된다(이재규 외, 1996).

인공신경망은 생물학적인 뇌에 있어서 뉴런(Neuron)에 해당하는 처리요소(Processing Element)로 구성된다. 처리 요소는 입력, 순 입력, 출력, 가중치, 전이함수 등 5개의 기본요소로 이루어진다. 다음의 <그림 3>은 처리요소의 기본 구조를 나타낸다.



(그림 3) 인공 신경망 처리 요소의 기본 구조

<그림 3>에서, PE는 처리 요소, X_i 는 PE_j 의 입력값이 되며, X_j 는 PE_j 의 출력값이 된다. 그리고 W_{ij} 는 PE_i 와 PE_j 간의 연결강도를 나타내는 가중치이며, net_j 는 순 입력값, f_j 는 net_j 값을 X_j 값으로 바꾸어 주는 전이함수이다. 순 입력값과 출력값을 계산해주는 식은 다음과 같다.

$$net_j = \sum_i W_{ij} X_i \quad X_j = f_j(net_j)$$

이들 전이함수에는 계단함수, 임계논리함수, 그리고 S자 형태의 시그모이드 함수 등이 있으며, 그 중에서 가장 많이 쓰이는 것은 시그모이드 함수이다.

동시에 또는 병렬적으로 동작하는 처리 요소들이 모여서 하나의 총을 이루게 되는데 입력총, 은닉총, 출력총이 있다. 은닉총은 인공신경망 모형에 따라서 없을 수도 있고, 하나 또는 그 이상의 은닉총이 있을 수 있다.

도산예측 연구에서 주로 사용되는 인공 신경망 모형은 다층 퍼셉트론(Multi-layer perceptron)과 역전파(Back-propagation Network:BPN)모형이다(조홍규, 1994). 단층 퍼셉트론은 선형분리 가능한 문제에만 적용가능하므로 Exclusive-OR문제를 해결할 수 없다는 한계가 있었다. 그러나, Werbos 등에 의해 다층 퍼셉트론을 역전파 알고리즘에 의해 학습시킬 수 있음이 알려지면서 다층 퍼셉트론은 가장 널리 사용되는 인공신경망 모형이 되었다.

III. 실증분석

1. 표본의 선정과 자료수집

본 연구에서는 한국보건의료관리연구원에서 수집한 병원경영분석자료를 활용하였다. 병원경영분석자료는 보건복지부와 한국보건의료관리연구원이 의료기관경영개선의 일환으로 1993부터 우리나라의 의료기관 경영실적자료를 수집분석한 것이다. 본 연구의 표본은 95년 당시 재무적으로 건전한 병원 228개와 92년에서 95년까지 도산한 병원 39개로 구성되어 있다. 도산병원의 정의와 선정기준은 기존 연구(이무식 외 1999)와 동일하다. 보다 구체적인 표본의 특성은 <표 2>에 정리되어 있다. 본 연구에서는 92~95년 4년간 수집된 자료를 사용하였는데, 이 중에 부도 병원의 개수는 92년 5개, 93년 11개, 94년 14개, 95년 9개로 총 39개이고 건전 병원의 개수는 95년 당시 228개 이었다. 부도 병원의 수가 상대적으로 작기 때문에 본 연구에는 부도 병원의 자료는 4년간의 관찰치 모두를 사용하도록 하였고, 건전 병원은 95년 관찰치만을 사용하였다. 따라서 분석을 위한 최종 관찰치 수는 부도 병원에 대한 관찰치 75개 건전 병원에 대한 관찰치 228개로 도합 303개로 구성된다.

<표 2> 표본의 특성

변수명	구분	건전	도산
응급진료	응급센터	59 (25.88%)	0 (0.00%)
	응급병원	101 (44.30%)	10 (25.64%)
	비지정	68 (29.82%)	29 (74.36%)
병원규모	3차	24 (10.53%)	1 (2.56%)
	300병상 이상	55 (24.12%)	2 (5.13%)
	160병상 이상	44 (19.30%)	2 (5.13%)
	160미만(종합병원)	12 (5.26%)	5 (12.82%)
전공의 수련	병원	93 (40.79%)	29 (74.36%)
	인턴/레지던트 수련	89 (39.04%)	1 (2.56%)
	인턴수련	28 (12.28%)	5 (12.82%)
대학병원	비수련	111 (48.68%)	33 (84.62%)
	대학병원	32 (14.04%)	1 (2.56%)
	비대학병원	196 (85.96%)	38 (97.44%)
소재지	대도시	107 (46.93%)	20 (51.28%)
	중소도시	94 (41.23%)	12 (30.77%)
	읍면	27 (11.84%)	7 (17.95%)

본 연구에서 사용된 재무비율의 변수명과 산식은 <표 3>과 같다. 유동비율(V8)과 당좌비율(V9)은 1000-1500%의 높은 값을 보였기 때문에 상용로그값을 취해 분석에 사용했다.

<표 3>

재무비율 변수 및 계산식

비율5	공 식	계 산 식
V1	총자산경상이익율	(경상이익/자산총계)*100
V2	총자산순이익율	(당기순이익/자산총계)*100
V3	의료수익경상이익율	(경상이익/의료수익)*100
V4	의료수익순이익율	(당기순이익/의료수익)*100
V5	의료사업비비율	(의료사업비용/의료수익)*100
V6	금융비용대 의료수익비율	(금융비용/의료수익)*100
V7	자기자본비율	(자기자본/총자본)*100
V8	유동비율	(유동자산/유동부채)*100
V9	당좌비율	(당좌자산/유동부채)*100
V10	차입금의존도	(총차입금/총자산)*100
V11	의료수익	의료수익
V12	총자산	총자산
V13	당좌자산대 총자산	(당좌자산/총자산)*100
V14	유동부채대 총자산	(유동부채/총자산)*100
V15	총차입금대 의료수익	(총차입금/의료수익)*100
V16	자기자본	자기자본
V17	총자본투자효율	(부가가치/총자본)*100
V18	금융비용대 부채비율	(금융비용/총차입금)*100
V19	고정장기적합률의 역	(고정부채+자기자본)/(투자와 기타자산+고정자산)*100
V20	단기부채 의존도	(단기부채/총자산)*100
V21	기업경상이익률	(경상이익+금융비용)/총자산*100
V22	이자보상배율	(법인세차감전순이익 + 금융비용)/금융비용
V23	총자산 회전율	의료수익/총자산
V24	제조간접비비율	관리비/의료수익*100

2. 판별 분석을 이용한 모형

판별분석에 의하여 다음과 같은 Fisher의 판별분석식을 얻었다. 다양한 재무변수 중에서 Stepwise 분석을 통해서 다음 표에 제시된 9개의 재무변수를 선정하였다. 이 변수들은 판별분석 뿐만 아니라 로짓모형, 인공신경망 모형 및 CART를 사용한 도산예측에 공통적으로 사용되었다. 즉 303개 병원의 9개 재무변수에 기초하여 해당병원의 도산 가능성을 예측하고 그 진위를 hit ratio로 계산하여 네가지 모형을 비교하고자 한다.

〈표 4〉 Fisher 판별식의 계수값

	정상병원의 판별계수	도산병원의 판별계수
상 수 항	-13.57896	-16.20902
단기부채 의존도	-0.05318	-0.01190
총차입금대 의료수익	0.11196	0.14051
금융비용대 의료수익비율	0.13151	-0.01708
총자산순이익률	-0.12088	-0.04770
금융비용대 부채비율	0.00497	-0.00202
유동부채대 총자산	0.26279	0.31478
자기자본비율	0.24455	0.27205
의료수익	0.000002728	0.000001376
관리비계	-0.000006877	-0.000003091

모형의 활용은 병원의 재무자료를 〈표 4〉에서 제시된 두 개의 판별식에 넣어 값이 높은 쪽으로 판별하면 된다. 예를 들어 어느 병원의 자료를 넣어 계산한 결과 정상병원의 식에 의한 값이 4.5이고 도산 병원의 식 값이 6.4이면 이 병원은 도산한 병원으로 판별하면 된다. 위의 모형을 이용한 판별식의 예측률은 다음과 같다.

〈표 5〉 판별분석 모형에 의한 예측률

	실제값	예 측 값			
		전 전	도 산	개 수	예 측 률
전전	건전	198	30	228	86.84%
	도산	16	59	75	78.67%
예 측 률				303	84.82%

판별분석 모형은 건전병원의 예측률이 86.84%로 도산병원의 예측률 78.67%보다 상대적으로 높게 나왔으며, 전반적으로는 84.82%의 예측률을 보였다.

3. 로지스틱 회귀분석(Logistic Regression Analysis)모형

<표 6>은 Logistic regression 방법을 이용하여 개발 된 모형의 계수값을 제시하고 있다. 한 병원의 재무자료를 위의 식에 입력하여 값을 구하고, 이에 기초하여 $\exp(z)/(1+\exp(z))$ 의 값을 구하면 이것이 도산 확률 값이다. 만일 이 확률 값이 0.5보다 크면 도산이고 작으면 건전이라고 판별하면 된다. Logistic Regression 모형의 예측 결과는 다음과 같다.

〈표 6〉 Logistic Regression 계수값

변 수 명	계 수 값
상 수 항	4.7836
단기부채 의존도	-0.0709
총차입금대 의료수익	-0.0357
금융비용대 의료수익비율	0.1714
총자산순이익율	-0.1347
유동부채대 총자산	-0.0889
자기자본비율	-0.0521
금융비용대 부채비율	0.0136
의료수익	0.00000275
관리비계	-0.00000744

〈표 7〉 Logistic Regression 에 의한 예측률

실제값	건전	예 측 값		예 측 률
		건 전	도 산	
건전	198	30	228	86.84%
도산	14	61	75	81.33%
예 측 률				85.48%

Logistic Regression 모형의 예측 결과, 건전 병원의 경우는 판별식 모형과 차이가 없으나 도산 병원의 경우는 예측력이 향상되었음을 알 수 있다.

4. 인공신경망(Neural Networks) 모형

본 연구에서는 NeuroShell 2.0 package를 사용하여 인공신경망 분석을 수행했는데 이는 가장 일반적인 세 개의 계층을 가진 역전파 알고리즘에 기초하고 있다. 사용된 노드의 수는 초기 입력노드의 경우 아래 표의 각 산업군 별 변수의 수와 같으며 은닉층의 노드 수는 입력노드의 2 배를 사용하였다. 출력층의 노드 수는 1개로 설계하여 산출된 결과값을 Cut-off Point를 이용하여 판별하는 방법을 이용하였다. Momentum은 Default로 잡혀있는 0.1을 사용했으며 Learning Rate는 0.1을 사용했다. 그리고 Initial Weight는 0.3을 사용하여 모형을 구축하였다. 또한 데이터 셋을 학습을 위한 데이터 셋과 완성된 모형을 적용하여 모형의 예측 능력을 측정하기 위한 Validation 셋으로 나누었다.

인공신경망을 이용한 최종 모형은 C프로그래밍 코드로 뽑아 내었으나 그 세부적인 내용은 의미 있게 해석하기가 어렵기 때문에 본 논문에서는 결과만을 제시하였다. 학습용 데이터 셋과 검증용 데이터 셋은 인공신경망 모형의 테스트 결과는 다음과 같다.

〈표 8〉 학습용 자료를 사용한 인공신경망분석에 의한 예측률

	실제값	예 측 값			
		건 전	도 산	개 수	예 측 률
	건 전	132	21	153	82.64%
	도 산	7	68	75	90.67%
	예 측 률				88.45%

〈표 9〉 검증용 자료를 사용한 인공신경망분석에 의한 예측률

	실제값	예 측 값			
		건 전	도 산	개 수	예 측 률
	건 전	68	7	75	90.67%
	도 산	7	68	76	90.67%
	예 측 률				90.67%

인공신경망 모형은 다변량 판별분석이나 로지스틱 회귀모형보다 예측능력이 뛰어남을 알 수 있다. 그러나 이를 모형화하기가 어렵고, 더욱이 데이터 수의 부족으로 인하여 항상 Over Fitting의 위험이 존재할 수 있다는 한계를 가지고 있음을 인식할 필요가 있다.

5. CART를 이용한 모형

CART 모형은 분리기준(splitting criterion), 정지규칙(Stoping rule), 그리고 가지치기(Pruning)에 의해 결정되어지는데 본 모형에서는 분리기준을 지니계수(Gini Index)를 사용하였으며 정지규칙과 가지치기는 디폴트 값을 이용하였다. 분리기준인 지니계수는 각 마디에서의 불순도 또는 다양도를 재는 측도중의 하나로써

$$G = \sum_{j=1}^c P(j)(1 - P(j)) = 1 - \sum_{j=1}^c P(j)^2 = 1 - \sum_{j=1}^c (n_j/n)^2$$

와 같이 표현될 수 있다. 여기서 n_j 는 그 마디에 포함되어 있는 관찰치 수를 말하고, n 는 목표변수의 j 번째 범주에 속하는 관찰치 수를 말한다.

의사결정나무의 결점은 데이터의 특성상 비연속적인 자료에 분석이므로 경계점 근방에서의 예측오류가 클 가능성이 있고, 선형성 또는 주효과에 대한 분석이 어려울 뿐만 아니라 새로운 자료에 대한 예측이 불안정하다는 것이다. 이와 같은 현상은 특히 자료의 크기가 너무 작은 경우와 가지의 수가 너무 많은 경우 빈번히 발생한다. 본 연구의 경우에도 표본의 크기가 소규모이기 때문에 예측이 불안정할 가능성을 가지고 있다.

본 모형의 활용을 위해서 예측에 사용할 변수를 선정하고 그 변수에서 구한 판별 임계치에 대한 규칙이 생성하였다. 따라서 생성된 규칙에 따라 자료를 대입해 보면 각각의 병원이 어디에 속하게 되는 가를 알 수 있다. CART를 이용한 모형의 예측 결과는 다음과 같다.

〈표 10〉 CART를 이용한 모형의 예측률

	예 측 값				예 측 률
	건 전	도 산	개 수		
실제값	건 전	221	7	228	96.93%
	도 산	14	61	75	81.33%
	예 측 률			303	93.07%

CART에 의한 모형이 인공신경망 모형 보다 예측률이 높은 것으로 나타났다. 그러나 CART 모형은 주로 건전에 치중되어 높게 나타나고 도산 병원의 예측률은 상대적으로 낮음을 알 수 있다.

IV. 종합모형

3장에서는 네가지 분석기법을 활용하여 건전병원군과 도산병원군에 대한 예측율을 비교하였다. 평균예측율은 CART기법이 93.07%로 가장 높지만 도산병원에 대한 예측율이 인공신경망 기법과 9%나 차이가 나기 때문에 인공신경망기법이 본 연구에 사용된 표본에 대해서는 가장 우수한 예측율을 가졌다고 평가할 수 있다.

〈표 11〉 네가지 분석기법별 예측율 비교

분석기법	MDA	로짓분석	인공신경망	CART
건전병원에 대한 예측율	86.84%	86.84%	90.67%	96.93%
도산병원에 대한 예측율	78.67%	81.33%	90.67%	81.33%
평균예측율	84.82%	85.48%	90.67%	93.07%

일반적으로 예측 오차(Error)는 편의(Bias)와 분산(Variance)로 구성된다고 할 수 있다. 편의를 줄이기 위해서는 정교한 모형의 개발이 필요하고 분산을 줄이기 위해서는 가능한 다양한 모형의 결과치를 결합하여 사용하는 것이 효과적이다. 3장에서 논의한 바와 같이 다양한 분석기법을 적용하여 예측율을 비교하는 것은 학술적으로는 가능할 것이지만 협업에서는 상당히 어려운 작업일 것이다. 따라서 본 연구에서는 통계적인 분석방법론인 다변량판별분석, 로지스틱분석과 인공신경망 그리고 CART를 결합한 종합모형을 구축하였다.

분산에 의한 오차를 줄이고 예측 모형의 신뢰도를 높이기 위한 한 방법으로 네 가지 방법에 의하여 도출된 어느 하나의 모형을 선택하여 사용하기보다는 네 가지 방법론을 모두 사용하여 이들에게 적당한 가중치를 부여하여 결합된 모형이 더 바람직하다고 판단했다. 종합모형의 장점은 매번 네가지 모형을 실행하여 최상의 모형을 선정하는 절차를 거치지 않고도 최상의 예측율을 기대할 수 있다는데 있다.

본 연구에서는 네 가지 분석모형을 통합하기 위해 몇 가지 방법을 시도하여 보았으나 단순 최적화 모형이 바람직하다고 판단되어 최적의 가중치를 구하는 수리모형을 사용하기로 하였다. 이 수리모형의 해를 구하기 위하여 미국의 The World Bank에서 개발한 GAMS(General Algebraic Modeling System)를 사용하였다.

GAMS는 일반 최적화 수리 프로그램 작성시 필요한 목적함수와 제약식의 미분한 조건식을 자동적으로 작성해 주기 때문에 사용자들은 필요한 식을 대수형태로 표현한 방식을 사용함으로써, 미분을 통한 최적화를 쉽게 수행할 수 있도록 되어 있다. 즉 GAMS를 사용하면, 크고 복

잡한 모형들을 높은 수준의 언어로 함축되게 표현할 수 있기 때문에 모형의 제원변경을 쉽게 조작하면서 시뮬레이션 할 수 있다.

GAMS는 여러 가지 모형의 조합을 통해 가장 좋은 예측능력을 찾아내기 위한 방법이고, 위의 표에 나타난 가중치 또한 가장 좋은 예측능력을 찾아낼 수 있도록 하는 가중치이다. GAMS를 이용하여 구한 각각 방법론에 대한 가중치는 다음과 같다.

〈표 12〉 결합모형개발을 위한 각각의 예측 모형의 가중치

예 측 모 형	MDA	Logit	NN	CART
가 중 치	0.240	0.255	0.312	0.193

단순 최적화 모형을 이용하여 최적의 가중치를 구하는 문제에서는 인공신경망의 예측결과가 가장 큰 비중을 차지하고 있음을 알 수 있다. CART는 단일 모형으로 예측률이 가장 높은 것으로 나타났으나 결합모형에서는 가중치가 가장 낮게 나왔다. 그 이유는 CART는 전전 병원에 예측률은 높으나 도산 병원의 예측률은 인공신경망 분석방법을 이용한 모형보다 크게 떨어지는 것을 알 수 있다. 이러한 이유로 인하여 CART에 의한 방법이 결합모형에서 가중치가 상대적으로 낮게 나온 것으로 해석된다. 결합모형에 의한 예측률은 다음과 같다.

〈표 13〉 결합모형의 예측률

실제값		예 측 값			예 측 률
		전 전	도 산	개 수	
건 전		222	6	228	97.37%
도 산		9	66	75	88.00%
예 측 률				303	95.05%

GAMS의 가중치에 의해 구해진 최종 결합모형에 의한 예측률은 현격하게 증가함을 알 수 있다. 병원부실에 대해 예측하기 위해서 어느 하나의 모형을 사용하기보다는 여러 개의 모형을 최적의 가중치를 주어 결합한 종합모형을 사용함으로써 모형의 특성에서 비롯되는 여러 한계점을 최소화하면서도 적용의 용이성을 최대화할 수 있음을 이상의 연구결과에서 제시하고 있다.

V. 요약 및 결론

본 연구에서는 267개의 병원(303개의 관찰치)의 재무분석 자료에 기초하여 병원의 부실여부를 예측하기 위해 다변량판별분석(MDA), 로짓분석(Logistic Regression), 인공신경망분석(Neural Network), CART(Classification and Regression Tree) 기법을 적용하였다. 도산병원군과 건전병원군에 해당 병원의 소속여부를 예측하기 위해 24개의 재무변수 중에 단기부채의 존도, 총차입금대 의료수익, 금융비용대 의료수익비율, 총자산순이익율, 금융비용대 부채비율, 유동부채대 총자산, 자기자본비율, 의료수익, 관리비계의 9개 변수를 stepwise 기법에 의해 선정하고 네가지 모형에 공통적으로 적용하였다. 분석결과 다변량판별분석에 비해서는 로짓분석이 예측율이 높았으며, 로짓에 비해서는 CART와 인공신경망이 높은 예측력을 보였다. 이 결과는 기업도산에 대한 기존 연구결과와 일치하는 것이다. 그러나 CART와 인공신경망 간의 모형상 우위에 대해서는 용도와 자료에 따라 이견이 있을 수 있다. 이같이 병원도산 예측에 있어서 모형상 우열에 대한 평가는 학술적으로는 가치가 있을 수 있겠으나 실무적인 관점에서는 상당한 혼선을 빚을 수 있을 것이다.

따라서 본 연구에서는 GAMS를 사용하여 이상의 네가지 분석기법을 통합한 최적화 모형을 개발하였다. 예측율에 기초해서 종합모형과 네가지 분석모형을 비교해 보아도 평균적으로는 종합모형이 우위에 있음을 확인하였다¹⁾. 병원도산에 대한 종합 예측모형은 중소병원지원을 위해 부실병원과 건전병원을 구분하는 기준을 마련하는 등의 정책적 목적 뿐 아니라 병원계에서 많은 관심을 모으고 있는 병원간 인수 합병 등의 경영적 목적을 위해서도 활용될 수 있을 것이다.

본 연구가 가지는 한계는 복잡한 예측모형을 적용하기 위해 필요한 크기의 도산병원 표본을 확보하기 위해 도산병원에 대해서는 92-95년간 수집된 모든 자료를 충복해서 사용한 점과 제한된 재무변수만을 사용하여 다섯가지 모형을 비교한 점이다. 병원도산의 예측에서 재무변수뿐 아니라 비재무변수의 유용성에 대해서는 과거의 연구(이무식외 1999, 정기택외 1999)에서 분석된 바 있기 때문에 본 연구에서는 이 문제에 관해 다시 검토하지 않았다. 본 연구의 목적이 네가지 분석모형의 예측력을 평가하기 위한 것보다는 궁극적으로 종합모형을 개발하기 위함데 있음을 상기할 때, IMF경제위기 이후에 증가한 도산병원에 대한 자료를 확보하여 보다 다양한 조합의 예측변수에 기초하여 예측모형을 검증하는 것은 향후 연구과제로 남기고자 한다.

1) 인공신경망모형의 도산병원예측율이 90.67%로 결합모형에 비해서 2% 높은 것은 인공신경망모형이 결합모형에 비해서 제한된 표본크기하에서 overfitting정도가 높기 때문인 것으로 해석된다. 따라서 결합모형을 사용하는 것이 예측의 신뢰도측면에서 안정적이라고 평가할 수 있다.

참 고 문 헌

- 김대수. 신경망이론과 응용(1), 하이테크정보, 1992
- 김영호. 한국병원 생존에 관한 연구, 대한병원협회지, 제 9권, 1992; pp 22~55.
- 박창길. 우리나라 재무제표의 기업실패 예측능력의 실증적 연구, 박사학위논문, 서울대, 1985
- 양동현, 정두채. 도산병원 실태와 대책. 한국병원경영학회 추계학술대회 연제집, 1998
- 이건창. 기업도산을 위한 통계적 모형과 인공지능모형간의 예측력비교에 관한 연구: 귀납적학습방법, 인공신경망. 한국경영과학지, 1993; 18(2), pp57~81
- 이건창, 한인구, 김명종. 통계적 모형과 인공지능모형을 결합한 기업신용평가모형에 관한 연구. 한국경영과학회지, 1996; 21(1), pp 81~100
- 이무식, 서영준. 병원도산 예측에 관한 연구, 예방의학회지, 1998; 31(3), pp490~502
- 이무식, 서영준, 양동현. 병원도산 예측모형의 실증적 비교연구, 한국보건행정학회지, 1999; 9(2), pp1~20.
- 이병원. 통계기법을 이용한 대출의사결정모형의 개발. 경희대학교 박사학위논문, 1994; pp 117~128
- 이재규 외. 전문가시스템 원리와 개발. 법영사, 1996; p.432
- 이재식, 한재홍. 인공신경망을 이용한 중소기업도산예측에 있어서의 비재무정보의 유용성 검증. 한국전문가시스템학회지, 1995; 창간호, pp 123~134
- 정기택, 이훈영. 병원도산분석에 기초한 효율적인 병원지원방안에 관한 연구. 병원경영학회지 1999; 4(2)
- 정준수. 기업도산예측모델에 관한 연구. 박사학위논문, 경북대, 1985
- 조홍규. 판별분석, 유사추론, 신경회로망을 이용한 도산예측. 석사학위논문, KAIST, 1994
- 한국은행 은행감독원 여신관리국. 판별분석에 의한 기업평가방법, 1981
- 조홍규, 한인구, 이훈영. Comparative analysis of bankruptcy prediction accuracy. 전문가시스템학회, 1994; pp 385~399
- 한인구, 박철수, 김철홍. Bankruptcy predictions for Korea Medium-sized firms using neural networks and case based reasoning, 한국경영과학회, 1996; pp 203~206
- 황석하. 기업부실예측에 관한 연구. 회계학연구 1991; 12(7), pp57~77
- 황석하. 기업부실원인에 관한 연구. 경영학연구, 1987; 2
- Altman, E.I.. Financial Ratios, Discriminant Analysis and the prediction of corporate bankruptcy. Journal of Finance, 1968; 23(4), pp589~609
- Beaver, W.H.. Financial Ratios as predictors of failure. Empirical Research in

- Accounting, 1966; pp.71~111
- Deakin, E.B.(1972). A Discriminant Analysis of Predictors of Business Failure, Journal of Accounting Research(Spring) pp.167~179
- Hadley, J., R.Mullner, and J.Feder(1982). The Financially Distressed Hospital. The New England Journal of Medicine 307(20). pp.1283~1287.
- Kelly, J.V. and J.J. O'Brien(1983). Characteristics of Financially Distressed Hospitals. (Hospital Cost and Utilization Project), Research Note 3, DHHS Publication No. (PHS) pp.83~3352. Washington, D.C. : National Center for Health Services Research.
- Kenedy, L. and B.M. Dumas(1983). Hospital Closures and Survivals : An Analysis of Operating Characteristics and Regulatory Mechanisms in Three States. Health Services Research 18(4) pp.489~512.
- Longo, D.R. and G.A. Chase(1984). Structural Determinants of Hospital Closure. Medical Care 22(5) pp.388~402.
- Mayer, J.D., E.R. Kohlenberg, E.G. Sieberman, and R.A.Rosenblatt(1987). Patterns of Rural Hospital Closure in the United States. Social Science and Medicine 24(4) : pp.327~334.
- Mullner, RM., Rydman, RJ., Whiteis, DG., Rich, RF.. Rural community hospitals and factors correlated with their risk of closing, Public Health Rep. 1989 Jul-Aug. 104(4). pp.315~25.
- Nelson, M.M and W.T. Illingworth. A Practical Guide to Neural Nets, Addison Wesley, 1992
- Udom, M. and R.Sharda (1990). A Neural Network Model for Bankruptcy Prediction, Proceedings of the IEEE International conference on Neural Networks, San Diego, CA., pp.163~168
- Ohlson, J. Financial Ratios and the Probabilistic Prediction of Bankruptcy. Journal of Accounting Research, Spring, 1980, pp.109~131.
- Sager, A. Why Urban Voluntary Hospitals Close. Health Services Research 1983; 18(3) pp.451~475.