

효과적인 의사결정을 위한 2단계 하이브리드 인공신경망 접근방법에 관한 연구

이 건 창¹⁾

A Study on the Two-Phased Hybrid Neural Network Approach to an Effective Decision-Making

본 논문에서는 비구조적인 의사결정문제를 효과적으로 해결하기 위하여 감독학습 인공신경망 모형과 비감독학습 인공신경망 모형을 결합한 하이브리드 인공신경망 모형인 HYNEN(HYbrid NEural Network) 모형을 제안한다. HYNEN모형은 주어진 자료를 클러스터화 하는 CNN(Clustering Neural Network)과 최종적인 출력을 제공하는 ONN(Output Neural Network)의 2단계로 구성되어 있다. 먼저 CNN에서는 주어진 자료로부터 적절한 퍼지규칙을 찾기 위하여 클러스터를 구성한다. 그리고 이러한 클러스터를 지식베이스로 하여 ONN에서 최종적인 의사결정을 한다. CNN에서는 SOFM(Self Organizing Feature Map)과 LVQ (Learning Vector Quantization)를 사용해 클러스터를 만든 후 역전파학습 인공신경망 모형으로 이를 학습한다. ONN에서는 역전파학습 인공신경망 모형을 이용하여 각 클러스터의 내용을 학습한다. 제안된 HYNEN 모형을 우리나라 기업의 도산자료에 적용하여 그 결과를 다변량 판별분석법(MDA:Multivariate Discriminant Analysis)과 ACLS (Analog Concept Learning System), 퍼지 ARTMAP 그리고 기존의 역전파학습 인공신경망에 의한 실험결과와 비교하였다.

1) 한동대학교 경영정보학과

I. 서론

본 연구에서는 인공신경망을 이용한 새로운 분류기(classifier)로서 비감독학습모형과 감독학습모형(Rumelhart et al 1986; Freeman & Skapura 1991)을 결합한 인공신경망 모형인 HYNEN모형을 제안한다. 일반적으로 인공신경망에 기초한 모형은 인공신경망의 기본구조인 뉴런 (neuron) 내의 전이함수 (transfer function), 인공신경망의 구조, 뉴런 또는 층(layer)간의 연결형태, 뉴런간의 연결강도를 적절하게 조정하는 학습규칙 등에 따라 여러 가지 형태의 모형으로 구분할 수 있다. 그러나, 가장 일반적인 분류는 기대출력치가 주어지지 않은 상태에서 스스로 주어진 입력자료를 학습하는 '비감독학습 인공신경망 모형' (unsupervised neural network model)과 해당입력에 대해 기대출력치가 주어진 상태에서 주어진 학습자료를 학습하는 '감독학습 인공신경망 모형' (supervised neural network model)으로 분류하는 것이다. 감독학습 인공신경망 모형으로는 역전파학습 인공신경망 모형 (Rumelhart et al. 1986)이 가장 대표적이다. 비감독학습 인공신경망 모형으로는 '자기조직화 특성지도'(이하 SOFM이라 약함) (Kohonen 1982, 1988)와 ART 모형 (Carpenter & Grossberg 1987ab, 1990)등이 있다. 한편, 최근에는 비감독학습 인공신경망 모형과 감독학습 인공신경망 모형을 결합한 연구가 많이 시도되고 있다. S rheim (1991)은 비감독학습 인공신경망 모형인 ART2(Carpen-

ter & Grossberg 1987b)와 역전파학습 인공신경망을 결합한 새로운 인공신경망 모형을 제안하고 이를 시계열 예측문제에 적용하였다(S rheim 1991).

본 연구에서는 인공신경망 모형을 이용한 새로운 의사결정 모형으로서 비감독학습 인공신경망 모형과 감독학습 인공신경망 모형을 결합한 새로운 추론메카니즘으로서 HYNEN모형을 제안한다. 본 연구에서 제안하는 HYNEN 모형은 주어진 비구조적 의사결정 문제를 비감독학습 모형으로 처리할 수 있는 부분과 감독학습 모형으로 처리할 수 있는 부분으로 나누어, 최종적으로 이를 결합하여 의사결정을 하는 모형이다. 첫째 주어진 입력자료를 비감독학습 인공신경망 모형을 이용하여 클러스터로 분류한다. 비감독학습 인공신경망은 기대출력치가 없이 단지 입력값만으로 학습을 할 수 있는 인공신경망 모형이다. 본 연구에서 사용하는 비감독학습 인공신경망 모형은 SOFM (Kohonen 1982, 1988)이다. SOFM은 고차원의 복잡한 입력자료를 내부자료의 지식을 손상시키지 않고 1차원으로 표현할 수 있는 장점이 있다. 더욱이 비감독학습 모형이므로 입력자료의 특성에 따라 클러스터를 구성할 수 있다는 장점이 있다. 그러나 입력자료가 자료의 특성에 따라 적절한 클러스터로 분류될지라도 해당 클러스터들이 서로 겹쳐질 수 있다. 이 문제를 해결하기 위해 LVQ (Kohonen 1988)를 사용한다. LVQ는 SOFM과는 달리 감독학습법을 사용하며 클러스터간의 최적의 경계를 보다 정확하게 분류할 수 있다 (Hung 1993). 둘

째 이렇게 분류된 클러스터를 역전파학습 인공 신경망 모형(Rumelhart et al. 1986)을 사용하여 학습한다.

본 연구에서 제안한 HYNEN모형의 성과를 검증하기 위해 우리나라 기업의 과거 4년간의 도산자료를 사용해서 기존의 MDA와 ACLS, 역전파학습 인공신경망, 퍼지 ARTMAP (Carpenter et al 1992, Kasuba 1993)등의 방법과 비교하고자 한다. 본 논문은 모두 4장으로 구성되어 있다. 2장에서는 제안한 HYNEN모형의 구조와 의사결정과정에 대해 자세히 설명하고 3장에서는 HYNEN 모형의 성과를 검증하기 위해 도산자료를 이용한 실험 결과를 제시한다. 끝으로 4장에서는 결론 및 향후 연구방향을 제시한다.

II. HYNEN의 구조와 의사결정 과정

2.1. CNN(Clustering Neural Network) 단계

CNN 단계에서는 비감독학습모형인 SOFM, 그리고 감독학습모형인 LVQ, 역전파 학습 인공신경망 모형을 이용하여 입력자료에 대한 클러스터를 생성하고, 해당 클러스터를 인식한다. 먼저 SOFM과 LVQ의 특징에 대해 살펴보고, 이를 기초로 하여 CNN의 전체적인 과정을 설명하기로 한다.

2.1.1. SOFM

Kohonen(1982)에 의해 개발된 SOFM은

역전파학습 모형과는 달리 학습시 기대출력값이 필요없는 비감독학습방법을 사용한다. SOFM은 '입력층'과 '경쟁층'의 2차원 격자(two-dimensional grid)로 구성되어있다. 모든 입력은 가변 연결강도를 통하여 모든 출력 뉴런에 연결되고 출력뉴런은 많은 국부적 접속으로 상호 연결되어 있으며, 입력으로는 연속값을 갖는 입력자료가 기대출력값이 표기되지 않은 상태로 순차적으로 주어진다. SOFM의 학습시 연결강도 벡터와 입력자료가 얼마나 가까운가를 계산하여 가장 가까운 경쟁층내의 출력뉴런이 활성화된다. 이 활성화된 출력뉴런이 출력신호를 보낼 수 있는 유일한 출력뉴런으로서 선택된다. 한편 이 선택된 출력뉴런과 그의 이웃반경안의 뉴런들은 Kohonen의 학습규칙에 따라 연결강도를 조정한다. 다음은 SOFM의 학습알고리즘을 순차적으로 정리한 것이다 (김대수 1992).

단계 1 연결강도를 초기화한다.

그림 1과 같이 N개의 입력과 출력뉴런 사이의 연결강도를 임의의 작은수로 초기화한다. 경쟁 층내에서 초기의 이웃 반경은 모든 출력 뉴런들이 포함될 수 있도록 충분히 크게 잡았다가 점 차로 줄어나간다.

단계 2 새로운 입력자료를 제시한다.

단계 3 입력자료와 모든 출력뉴런들간의 거리를 계산한다. 입력과 출력뉴런 j사이의 거리 d_j 는 다음과 같이 계산한다.

$$d_j = \sum_{i=1}^N (x_i(t) - w_{ij}(t))^2$$

여기서 t 는 반복횟수를 의미한다. $x_i(t)$ 는 t 시점에서 i 번째 입력자료이고 $w_{ij}(t)$ 는 t 시점에서 i 번째 입력자료와 j 번째 출력뉴런 사이의 연결강도이다.

단계 4. 해당 입력자료와 최소거리에 있는 출력뉴런을 선택한다. 즉, 최소거리 d_j 인 출력뉴런 j^* 를 선택한다.

단계 5. 출력뉴런 j^* 와 그 이웃들의 연결강도를 재조정한다. 출력뉴런 j^* 와 그 이웃반경내의 뉴런들의 연결강도를 다음식에 의해 재조정한다.

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(x_i(t) - w_{ij}(t))$$

여기서 j 는 출력뉴런 j^* 의 이웃반경내의 출력뉴런을 의미하고, α 는 0과 1사이의 값으로서 시간이 경과함에 따라 점차 작아진다.

단계 6. 단계 2로 가서 반복한다.

SOFM 학습의 처음 단계에서는 경쟁층내의 모든 출력뉴런들이 포함될 수 있으나, 학습이 진행됨에 따라 점점 적은 수의 출력뉴런들이 학습을 하고 최종적으로는 단지 '승자뉴런'만이 연결강도를 조절하게 된다. 이러한 과정이 끝나면 또 다른 입력자료가 들어오고 이 과정을 되풀이한다. 이렇게 해서 입력자료중 서로 유사한 자료들끼리 클러스터로 분류된다. 그러나 이러한 클러스터는 그 경계선이 서로 겹치는 경우가 많아 의사결정문제에 적용될때 많은 문제점을 야기시키는 경우가 많다. 그러므로 SOFM에 의해서 정확하게 클러스터를 결정하기가 어렵고, 이에 Kohonen(1988)은 LVQ를 사용할 것을 제안하였다. 한편, Hung(1993)




그림 1. SOFM의 기본구조

도 SOFM과 LVQ를 적용하여 제어문제에 효과적으로 이용될 수 있는 퍼지 인공신경망 모형을 제안하였다.

2.1.2. LVQ

Kohonen(1988)에 의해 제안된 LVQ는 입력자료를 몇 개의 클러스터중 하나에 할당하는 방법을 사용하고 있다. 학습시 각각의 학습자료에 대한 거리값을 계산하고 가장 가까운 뉴런이 선택된다. 승자뉴런이 학습자료의 클러스터속에 속하면 승자뉴런은 학습자료쪽으로 가깝게 이동한다. 만약 승자뉴런이 학습자료의 클러스터에 속하지 않는다면 이때는 학습자료에서 멀어지는 쪽으로 승자뉴런이 이동한다. 이와같은 LVQ의 학습알고리즘은 기본적으로 SOFM 학습알고리즘과 같지만, LVQ는 연결강도 벡터를 각 클러스터에 할당하는 감독학습 방법의 원리에 기초하고 있다. 그림 2는 SOFM에 의한 클러스터의 형성과 LVQ에 의한 클러스터 형성과의 차이를 보여주고 있다. 즉, LVQ에 의한 클러스터는 SOFM의 그것과

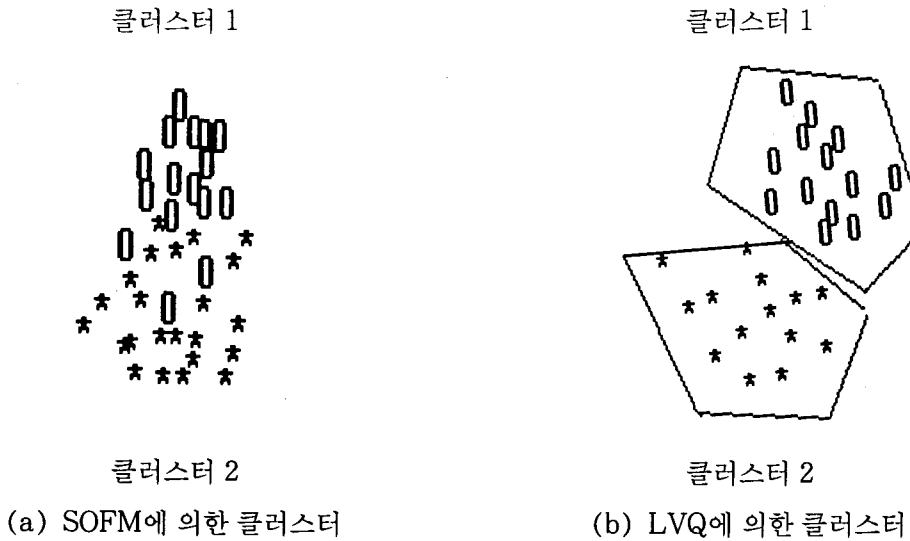


그림 2. SOFM과 LVQ에 의한 클러스터




그림 3. CNN단계의 과정

비교하여 경계선이 분명한 것을 알 수 있다.

이와같이 SOFM과 LVQ의 상호보완적인 성질을 이용하여 주어진 입력자료로부터 유용한 클러스터를 확보하는 것은, SOFM 또는 LVQ 중 어느 하나만을 이용하여 클러스터를 구성하는 것보다 클러스터 간의 경계선이 보다 분명한 클러스터를 확보할 수 있다는 측면에서 바람직하다 (Hung 1993). 한편, LVQ가 초기자료값에 민감한 영향을 받기 때문에 이를 개선하기 위하여 일반화된 GLVQ를 사용하나, 본 연구의 경우에는 SOFM과 LVQ를 순차적으로 적용하는 하이브리드 방식의 방법론을 적용하

고자 하는 연구의도를 살리기 위하여 GLVQ의 사용을 고려하지 않았다. 한편, 본 연구를 통한 필자의 경험으로는 SOFM과 LVQ를 순차적으로 적용하는 것은 그렇지 않은 경우보다 판별력이 강한 클러스터를 얻을 수가 있었다.

2.1.3. 정리

CNN단계는 입력자료를 특성별로 클러스터로 구분하는 과정이다. 먼저 입력자료를 SOFM으로 분류하여 클러스터를 생성한다. 이렇게 생성된 클러스터간의 경계를 보다 명확히 하기 위해서 감독학습모형인 LVQ를 적용한

다. 본 논문에서는 이렇게 생성된 클러스터를 인식하는 인공신경망을 CNN이라고 칭한다. CNN의 형성과정은 그림 3과 같이 세단계로 구성되어 있다. 1단계는 비감독학습모형인 SOFM을 사용하여 입력자료에 대한 클러스터를 생성하는 과정이고, 2단계는 보다 명확한 클러스터를 생성하기 위한 LVQ의 학습과정, 그리고 3단계는 CNN을 만들기 위한 역전파학습 인공신경망 모형 적용과정이다.

이상에서 본바와 같이 CNN단계는 SOFM과 LVQ를 사용해서 주어진 입력자료를 몇개의 클러스터로 분류한 뒤, 생성된 클러스터를 기대출력값으로 하여 다시 역전파학습 인공신경망으로 학습하는 하이브리드 방식을 적용했다. 이렇게 만들어진 CNN을 이용하여 주어진 입력자료에 대한 적절한 클러스터를 확인할 수 있다. 또한 CNN단계에서 형성된 클러스터는 주어진 자료에서 추출된 퍼지규칙(Fuzzy Rule)으로 인식할 수 있기 때문에(Takagi & Hayashi 1991), CNN단계를 주어진 입력자료로부터 인공신경망을 이용한 퍼지규칙 생성과정으로 이해할 수 있다.

2.2. ONN(Output Neural Network) 단계

ONN단계는 CNN단계에서 나온 각각의 클러스터에 대해 실제 추론결과를 유도하는 과정이다. 즉, ONN단계는 CNN단계에서 형성된 각각의 클러스터를 역전파학습 인공신경망으로 학습하는 단계이다. 이때 기대출력값으로서 실제 결과값을 사용한다. 따라서 ONN은 각 클러스터에 대해 역전파학습을 적용한 인공신

경망이라고 정의할 수 있다.

2.1에서 언급한 바와 같이 CNN단계는 ONN단계에서 서로 유사성을 갖는 입력자료에 대해서 추론을 할 수 있도록 입력자료를 클러스터로 구분하는 역할을 한다. CNN단계에서 유도된 클러스터는 하나의 퍼지규칙으로 볼 수 있으므로(Takagi & Hayashi 1991), ONN은 IF-THEN규칙에서 THEN부분을 추론하는 인공신경망이라고 간주할 수 있다. 그러므로 CNN단계는 IF부분을 결정하는 전처리과정 단계(Preprocessing stage)라고 보고, ONN단계는 그에 대한 결론부분, 즉 THEN부분을 결정하는 단계로 정의할 수 있다. 그림 4는 주어진 입력자료에 대해 CNN과 ONN이 결정되는 과정을 간략히 도시하고 있다.

그림 4에서 보는 것처럼 CNN단계를 거쳐서 클러스터가 생성되면, 이들 클러스터에 대해 역전파학습 인공신경망을 적용해서 ONN이 생성되므로 ONN은 CNN단계에서 생성된 클러스터 갯수만큼 만들어진다. 이상에서 언급한 ONN단계는 의사결정을 할 수 있는 단계이다. 주어진 실험자료가 CNN단계에서 적절한 클러스터로 분류되면, 이는 IF-THEN 규칙에서 IF부분, 즉 조건부가 확인된 것이다. 그 다음 해당 클러스터에 해당하는 ONN을 이용하여 주어진 자료에 대한 최종적인 출력값이 산출되는데 이는 곧, THEN부분이 추론되는 과정이다. 이러한 과정을 통해 ONN단계에서 주어진 의사결정문제에 대한 최종적인 결론이 추론된다.

2.3. HYNEN 모형에 의한 의사결정과정

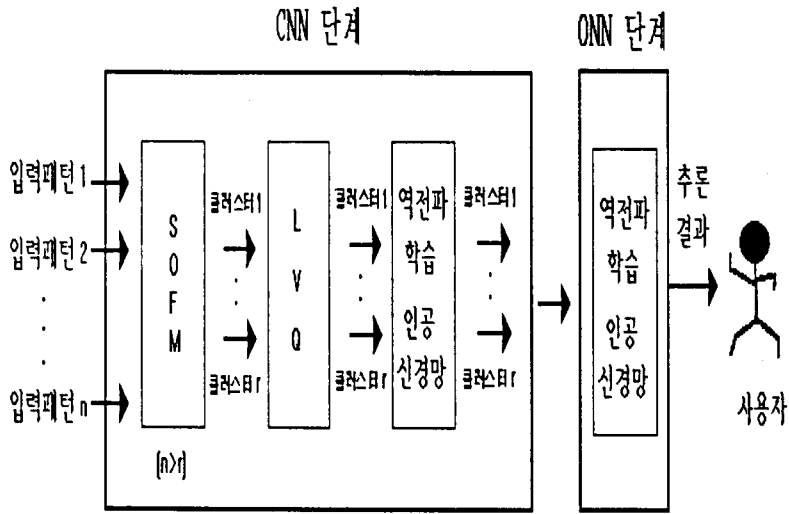


그림 4. CNN단계와 ONN단계의 연결과정

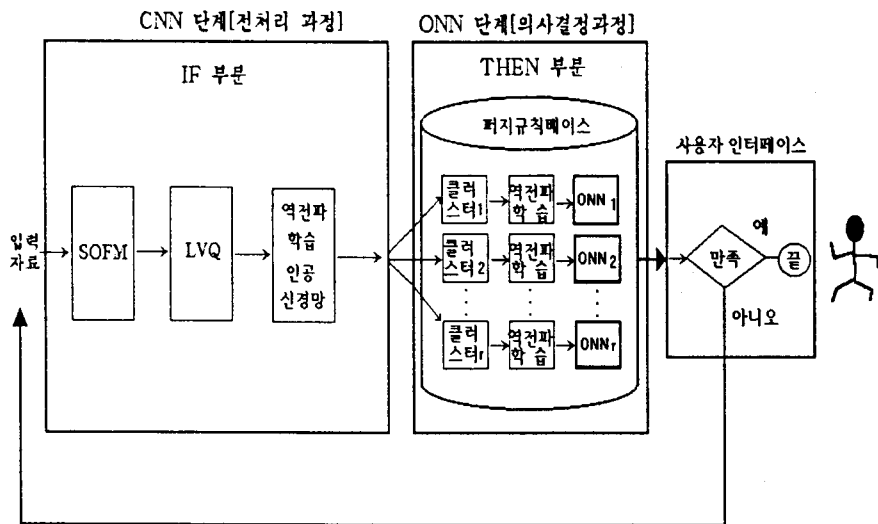


그림 5. HYNEN 모형에 의한 의사결정과정

그림 5는 HYNEN 모형의 의사결정과정을 도시한 것이다. HYNEN 모형에 의한 의사결정과정은 다음과 같은 5단계로 구성되어 있다.

1단계: 주어진 학습자료는 비감독학습방법인 SOFM을 통해서 몇 개의 클러스터로 분류된다.

2단계: LVQ를 사용하여 1단계에서 나온 클러스터를 더욱 세련화시킨다

3단계: 2단계에서 유도된 클러스터를 기대 출력값으로 하여 학습자료를 역전파학습 인공신경망으로 학습하여 CNN을 만든다.

4단계: 각 클러스터에 실제 출력값을 입력

하여 역전과 학습 인공지능경망으로 학습한 후 이를 ONN으로 한다.

5단계: ONN을 이용하여 주어진 실험자료에 대한 최종적인 의사결정을 한다.

이상에서 살펴본 것처럼 HYNEN 모형은 구조적으로 비감독학습 인공지능경망과 감독학습 인공지능경망을 사용하는 하이브리드 방식의 의사결정모형이다. 결국 HYNEN모형에 의하여 의사결정자는 주어진 자료에 대한 추론을 2단계로 수행할 수 있다. 즉, IF부분에 대한 CNN 단계와 THEN부분에 대한 ONN단계이다. 기존의 IF-THEN방식에 의한 규칙베이스와 비교하여 볼 때, 본 연구에서 제안하는 HYNEN 모형은 학습효과와 일반화효과가 가능한 추론 기관과 같은 역할을 수행한다.

Ⅲ. 실험 및 결과

본 장에서는 실험에서 사용된 자료분석과 MDA방법, ACLS방법, 인공지능경망, 그리고 퍼지 ARTMAP에 대해 간략히 설명하고 HYNEN에 의한 실험결과와 서로 비교한다.

3.1. 자료

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

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

이상과 같은 도산의 개념적 정의를 이용하여 도산자료를 추출하고 이를 표 1과 같이 3그룹으로 나누었다. 특히 표1의 검증용 표본에 대하여 설명하면, 85년도에서 90년도까지의 전체 검증용 표본수는 30개, 91년도 검증용 표본수는 30개, 마지막 92년도 검증용 표본수는 40개이다. 따라서 그룹1의 경우 검증연도가 85년에서 92년도이므로 검증용 표본수가 100개가 되며, 같은 방법으로 그룹2의 경우는 91년,

〈표 1〉 년도별로 구분한 표본기업

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

92년이 검증년도이므로 검증용 표본수는 70개, 그룹3의 경우는 92년만 검증년도에 해당되므로 검증용 표본수는 40개가 된다.

3.2. 변수선정

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.

이들 재무비율자료를 본 연구에서 수행하는 실험의 변수로 사용하였다. 즉, 본 연구에 이용되는 변수는 기업도산을 잘 나타내주는 지표로서 자료의 입수가 용이하고 객관적이며 통계처리가 가능한 재무비율을 선정하였다. 재무비율은 재무제표상의 여러항목중에서 두 항목이상을 비교하여 계산되기 때문에 수없이 많이 구할 수 있지만, 본 연구에서는 다음과 같은 선정 기준에 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. 이 중 하나의 재무비율이 공식의 형태에 따라 여러개로 표현되는 고정자산증가율, 총부채증가율, 차입금의존도에 대해서는 다음과 같이 그 공식을 소개한다.

고정자산증가율 1 = $\frac{\text{금년도 고정자산}}{\text{전년도 고정자산}}$

고정자산증가율 2 = $\frac{\text{금년도 고정자산}}{\text{전년도 고정자산}} \times \frac{\text{전년도 부채}}{\text{금년도 부채}}$

고정자산증가율 3 = $\frac{\text{금년도 고정자산}}{\text{전년도 고정자산}} \times \frac{\text{금년도 부채}}{\text{전년도 부채}}$

총부채증가율 1 = $\frac{\text{금년도 부채}}{\text{전년도 부채}}$
 총부채증가율 2 = $\frac{\text{금년도 부채}}{\text{전년도 부채}} \times \frac{\text{전년도 매출}}{\text{금년도 매출}}$

총부채증가율 3 = $\frac{\text{금년도 부채}}{\text{전년도 부채}} \times \frac{\text{전년도 경상이익}}{\text{금년도 경상이익}}$

총부채증가율 4 = $\frac{\text{금년도 부채}}{\text{전년도 부채}} \times \frac{\text{전년도 이자비용}}{\text{금년도 이자비용}}$

차입금의존도 1 = $\frac{\text{차입금}}{\text{총자산}}$

차입금의존도 2 = $\frac{\text{차입금}}{\text{매출}}$

차입금의존도 3 = $\frac{\text{차입금}}{\text{총부채}}$

〈표 2〉 선정된 재무비율(57개)

구 분	번 호	재 무 비 율
성 장 성	1	총자산증가율
	2	매출액증가율
	3	경상이익증가율
	4	순이익증가율
	5	고정자산증가율 1
	6	고정자산증가율 2
	7	고정자산증가율 3
	8	총부채증가율 1
	9	총부채증가율 2
	10	총부채증가율 3
	11	총부채증가율 4
수 익 성	12	총자본경상이익율
	13	총자본순이익율
	14	기업경상이익율
	15	자기자본경상이익율
	16	자기자본순이익율
	17	자본금순이익율
	18	매출액경상이익율
	19	매출액순이익율
	20	매출액총이익율
	21	매출액영업이익율
	22	금융비용대 매출액
	23	배당율
	안 전 성	24
25		유동비율
26		당좌비율
27		고정비율
28		고정장기적합율
29		부채비율
30		유동부채비율
31		고정부채비율
32		차입금의존도 1
33		차입금의존도 2
34		차입금의존도 3
35		총부채구성율
36		고정자산구성율
37		재고자산대 유동자산
38		재고자산대 유동자산변화율
39		순운전자본대 총자본
40		이자보상배율
41		이자배율

구 분	번 호	재 무 비 율
현 금 흐 름	42	현금흐름대 자기자본비율
	43	현금흐름대 차입금비율
	44	현금흐름대 총산비율
	45	현금흐름대 매출액비율
	46	자본회전율
활 동 성	47	자기자본회전율
	48	순운전자본회전율
	49	고정자산회전율
	50	재고자산회전율
	51	재고자산회전율의 변화
기 업 신 용 율	52	매입채무대 매출채권변화율
	53	매입채무대 유동부채
	54	매입채무대 유동부채변화율
	55	매출채권대 유동자산변화율
	56	매입채무대 매출채권(신용율)
	57	매입채무대 재고자산

이와같은 57개의 재무비율은 특성에 따라 11개의 성장성 비율, 12개의 수익성 비율, 18개의 안전성 비율, 4개의 현금흐름 및 6개의 기업 신용율, 6개의 활동성 비율로 분류된다.

3.3. 기존의 방법

3.3.1. MDA

MDA는 주어진 관측치를 두개 이상의 그룹으로 분류하는데 사용되는 통계적 기법이다. 도산예측을 위해서는 미리 '도산' 및 '비도산'이라는 두개의 그룹을 설정하고, 여러 독립변수의 선형결합(linear combination)으로 표현되는 판별함수를 유도한다. 이때 판별함수는 판별오류(misclassification) 확률을 최소화하는 방식으로 유도되며, 이는 일반적으로 최소자승법의 한 형태로 표현된다. 그러나, MDA분석이 유효하려면 몇가지 가정이 전제

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

3.3.2. ACLS

ACLS는 기존의 사례로부터 일정한 의사결정기준 (decision rule), 즉 지식을 도출하는 방법이다(Quinlan 1986). 이 방법은 특정분야에 대한 기존의 사례에서 지식을 학습하여 의사결정트리 형태로 구성된 지식을 유도하고, 이를 이용하여 해당 의사결정 분야의 의사결정 문제에 이용하는 방법이다. ACLS방법의 메카니즘을 설명하기 위하여 $n(t)$ 를 노드 t 에 할당된 사례의 수라 하고, $n_i(t)$ 를 노드 t 에서 계층 i 에 속하는 사례의 수를 나타낸다고 하자. 이때 해당 노드 t 에서의 엔트로피(entropy)는 곧 노드 t 에서의 '기대정보내용'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 t 에서 하나의 사례가 계층 i 에 속할 조건부 확률은 $P(i|t) = n_i(t)/n(t)$ 가 되고 하나의 사례가 특정 분할기준에 의하여 노드 t 의 하위노드인 t_i 로 할당될 조건부 확률은 $P(t_i|t, sr) = n(t_i)/n(t)$ 가 된다. 따라서 분류기준 sr 에 대한 노드 t 에서의 기대정보내용을 $ICT(t|sr)$ 이라고 정의하면 이는

$$ICT(t|sr) = \sum_{i,j} ICT(t_i) \cdot P(t_i|t, sr)$$

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

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

로 계산된다. 결과적으로 ACLS는 노드 t 에서 $\Delta Inf(t|sr)$ 를 최대로 하는 분할기준을 선정하여 하위노드를 구성하며 이러한 과정은 최종 노드에 이르러 모든 사례를 정확히 구분할 때까지 반복적으로 수행된다.

3.3.3. 퍼지 ARTMAP

퍼지 ARTMAP(Carpenter et al 1992)은 기존에 잘 알려진 ART(Carpenter & Grossberg 1987ab, 1990)의 퍼지화된 모형이다. 이는 감독학습방법을 사용하며, 대규모의 비안정적인 데이터베이스(nonstationary data base)에 온라인적으로 학습규칙을 적용할 수 있는 특징이 있다. 퍼지 ARTMAP은 퍼지화된 두개의 ART모듈과 이들 두개의 ART모듈을 연결시켜주는 'Map Field'라 불리는 Inter-ART모듈로 구성되어 있다. 퍼지 ARTMAP에 대한 간략한 요약은 Kasuba (1993)에 소개되어 있다.

3.4. 실험결과

실험을 위하여 본 연구에서 사용한 소프트웨어는 MDA의 경우 SPSS-PC+, ACLS는 Pascal로 coding한 프로그램으로, 그리고 SOFM, LVQ, 퍼지 ARTMAP, 역전파학습 인공신경망등은 Neural Works Professional V5.0(NeuralWare社, 1994)을 사용하였다.

표 3은 각 방법의 실험결과를 보여주고 있다. NN(MDA)와 NN(ACLS)는 각각 MDA와 ACLS에 의하여 선정된 변수를 입력으로 하여 일반적인 역전파학습 인공신경망으로 실

〈표 3〉 실험결과

그룹	MDA	ACLS	NN (MDA)	NN (ACLS)	HYNEN (MDA)	HYNEN (ACLS)	퍼지 ARTMAP (MDA)	퍼지 ARTMAP (ACLS)
1	68.0%	74.0%	70%	73.0%	84.0%	74.0%	73.0%	72.0%
2	68.5%	72.8%	80%	81.4%	74.0%	79.0%	75.7%	77.1%
3	70.0%	77.5%	80%	82.5%	82.5%	77.5%	80.5%	85.5%
평균	68.83	74.77	76.67	78.97	80.17	76.83	76.4	78.2

험한 것을 의미한다. 마찬가지로 HYNEN(MDA)와 HYNEN(ACLS)도 각각 MDA와 ACLS에 의하여 선정된 변수를 입력으로 하여 HYNEN으로 실험한 것을 의미한다. 또한 퍼지 ARTMAP(MDA)와 퍼지 ARTMAP(ACLS)도 각각 MDA와 ACLS에 의하여 선정된 변수를 입력으로 하여 퍼지 ARTMAP으로 실험한 것을 의미한다. 그룹별 성과를 보면 각 방법간에 약간의 차이가 있지만, 평균적인 성과를 토대로 각 방법을 비교하면 다음과 같다.

MDA < ACLS < 퍼지 ARTMAP(MDA)
< NN(MDA) < HYNEN(ACLS) < 퍼지
ARTMAP(ACLS) < NN(ACLS) <
HYNEN(MDA)

결국 본 논문에서 제안하는 HYNEN(MDA)가 가장 좋은 성과를 보여주고 있다. 한편, 각 방법간의 차이를 보면 일단 본 논문에서 제안하는 HYNEN모형에 의한 결과가 MDA, ACLS, 퍼지 ARTMAP(MDA), NN(MDA)방법에 의한 결과보다 우수하다는 것

을 알 수 있다. 이는 기존문헌에서 많이 사용된 MDA방법과 ACLS방법, 그리고 역전파학습 인공신경망보다는 HYNEN모형의 성과가 더 우수하다는 것을 보여주는 결과라고 할 수 있다.

IV. 결론 및 향후 연구방향

본 논문에서는 효과적인 의사결정을 위하여 HYNEN이라는 새로운 하이브리드 인공신경망 접근방법을 제안했다. HYNEN은 비감독학습 인공신경망 모형인 SOFM과 감독학습 인공신경망 모형인 LVQ, 그리고 역전파학습 인공신경망을 결합하여 모형을 구축한다. 이러한 과정을 통하여 HYNEN모형은 클러스터 선택을 위한 CNN과 결과값을 추론하기 위한 ONN을 주어진 의사결정문제에 적용하여 문제를 해결한다. 이렇게 구성된 HYNEN모형은 기존의 단순한 인공신경망과는 달리 주어진 자료의 특성을 찾아 학습함으로 보다 향상된 추론을 할 수 있다는 장점이 있다. 또한 새로운 실험자료에 대해서 미리 적절한 클러스터별로 구분해

주기 때문에 자료가 지닌 불확실성을 어느정도 감소시켜 보다 정확한 의사결정을 가능하게 하는 적응성이 우수하다. 앞으로의 연구방향은 보다 정교한 비감독학습 인공신경망 모형과 감독학습 인공신경망 모형을 결합하여 비구조적인 의사결정문제를 보다 효과적으로 해결하는 또 다른 형태의 HYNEN 모형을 개발하는 것이다. 또한 본 연구에서 몇가지 해결해야 할 사항이 있는데 이를 정리하면 다음과 같다.

- 1) 실제 자료값들에는 애매한 정보가 많기 때문에 퍼지개념을 사용한 퍼지

HYNEN모형인공신경망에 대한 연구가 필요하다.

- 2) HYNEN 모형과 다른 AI 방법을 결합한 합동추론이 보다 좋은 결과를 낼 수 있다. 왜냐하면 두개의 보완적인 방법으로 상승작용을 일으켜 보다 정확한 예측이 가능하기 때문이다.
- 3) 본 실험에 사용된 도산 자료는 재무비율만을 이용하였지만, 앞으로의 연구에 있어서 질적인 정보가 고려되어야 한다.

참 고 문 헌

강철승, “부가가치 회계정보의 기업부실예측력에 관한 실증적 연구”, 회계학 연구, 제 12호, 79-100, 1991년.

김대수, “신경망 이론과 응용 II”, 하이테크정보, 1992.

김선기, 황석하, 김건우, “기업부실화의 원인, 징후 및 예측”, 한국신용평가(주), 1986.

박창길, “우리나라 재무재표의 기업실패 예측능력의 실증적 연구”, 박사학위논문, 서울대, 1984.

정준수, “기업도산 예측 모델에 관한 연구”, 박사학위논문, 경북대, 1985.

한국기업재무총람, 1985-1991, 한국신용평가주식회사.

황석하, “기업부실 예측에 관한 연구”, 회계학 연구, 제 12호, 57-78, 1991년.

회계연감, 1979-1991, 매일경제신문

Altman, E.I., “Financial Ratios, Discriminant Analysis and Prediction of Corporate Bankruptcy”, *The Journal of Finance*, vol.23, 589-609, Sep 1968.

Carpenter, G.A., and S. Grossberg, “A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine”, *Computer*

Vision, Graphics, and Image Processing, vol. 37, 54–115, 1987a.

_____, “ART2: Self-Organization of Stable Category Recognition Codes for Analog Input Patterns”, *Applied Optics*, vol. 1, 4919–4930, 1987b.

_____, “ART3: Hierarchical Searching Using Chemical Transmitters in Self-Organizing Pattern Recognition Architectures”, *Neural Networks*, vol. 3, 129–152, 1990.

Carpenter, G.A., S. Grossberg, N. Markuzon, J.H. Reynolds, and D.B. Rosen, “Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps”, *IEEE Transactions on Neural Networks*, vol. 3, 698–713, 1992.

Hung, C.C., “Building a Neuro-Fuzzy Learning Control System”, *AI Expert*, 40–49, Nov 1993.

Freeman, J.A. and D.M. Skapura, *Neural Networks: Algorithms, Applications, and Programming Techniques*. Addison-Wesley Publishing Company, 1991.

Kasuba, T. “Simplified Fuzzy ARTMAP”, *AI Ex-*

pert, 18–25, Nov 1993.

Kohonen, T., “Self-Organized Formation of Topologically Correct Feature Maps”, *Biological Cybernetics*, vol. 43, 59–69, 1982.

_____, “Self-Organization and Association Memory.” Second edition. Springer-Verlag, Berlin, 1988.


Quinlan, J.R., “Induction of Decision Trees”, *Machine Learning*, vol.1, 81–106, 1986.

Rumelhart, D.E., G.E. Hinton, and R.J. Williams, “Learning Internal Representations by Error Propagation”, in D.E. Rumelhart and J.L. McClelland (Eds). *Parallel Distributed Processing: Exploration in the Microstructure of Cognition*. Cambridge, MA:MIT Press, 1986.

Sorheim, E., “A combined network architecture using ART2 and back propagation for adaptive estimation of dynamical processes”, *Proceedings of the 24th Annual Hawaii Conference on Systems Science*, vol 2. 468–475, 1991.

Takagi, H. and I. Hayashi, “NN-Driven Fuzzy Reasoning”, *International Journal of Approximate Reasoning*, Vol. 5, 191–212, 1991.

◇ 저자소개 ◇



저자 이건창은 성균관대학교에서 경영학사(1982), 한국과학기술원(KAIST) 경영과학과에서 MIS로 석사(1984), 박사(1988)를 취득하였다. 저자는 1990년도부터 1994년도까지 경기대학교 경영정보학과에서 부교수로 재직하였고, 1995년 3월부터 한동대학교 경영정보학과 학과장으로 재직중이다. 주요연구분야는 인공지능망을 이용한 전문가시스템 개발이며, 특히 전략계획분야 또는 예측분야에서 사용될 수 있는 퍼지 인공지능망 전문가시스템 개발에 관심을 갖고 있다.

그의 논문은 경영학연구, 경영과학지, 정보과학회지, 경영정보학연구, 시뮬레이션학회지 등 국내학술지 이외에도 Decision Support Systems, Decision Sciences, Fuzzy Sets and Systems, Expert Systems, Computer Science in Economics and Management, Intelligent Systems in Accounting Finance & Management 등의 국제 학술지에 출간되었거나 또는 출간예정이다. 그는 현재 IEEE Computer Society와 IEEE Systems, Man & Cybernetics Society, Society of Computer Simulation의 Member로 활동중이며, 퍼지전문 국제학술지인 Fuzzy Sets and Systems 지의 Reviewer로 봉사하고 있다.