

인공신경망 모델을 이용한 주식시장에서의 투자전략에 대한 연구*

서영호** · 이정호***

A Study on the Investment Strategy Using Neural Network Models in the Korean Stock Market*

Yung-Ho Suh** · Jhong-Ho Lee***

■ Abstract ■

Since the late 1980s, an increasing number of neural network models have been studied in the areas of financial prediction and analysis. The purpose of this study is to investigate the possibility of building a neural network model that is able to construct a profitable trading strategy in the Korean Stock Market. This study classifies stocks into the future market winners and losers from the publicly available accounting information and builds portfolios based on this information. The performances of the winner portfolios and the loser portfolios are compared with each other and against the market index. The empirical result of this research is consistent with the traditional fundamental analysis where it is claimed that the financial statements contain firm values that may not be fully reflected in stock prices without delay. Despite the supporting empirical evidence, it is somewhat inconclusive as to whether or not the abnormal return in excess of market return is the result of the extra knowledge obtained in the neural network models derived from the historical accounting data. This research attempts to open another avenue using neural network models for searching for evidence against market efficiency where statistics and intuition have played a major role.

* 본 논문은 97년도 경희대학교 연구비지원으로 이루어 졌습니다.

** 경희대학교 경영학부

*** 서울대학교 경영대학

1. 서 론

주식시장을 분석하고 예측하는데 있어 전통적으로 다양한 통계 모델들이 광범위하게 사용되어져 왔다. 지금까지 소개된 통계기법들 가운데 잘 알려진 몇 가지를 예로 들어 보면 다변량 판별분석(MDA: multivariate discriminant analysis), 회귀분석(regression), 로짓(logit)분석 등이 있다. 그러나 1980년대 후반 이래로 인공 지능 기법을 응용한 재무분석 모델들이 매우 많이 소개되어져 왔으며, 전문가 시스템(expert systems)과 기계적 학습(machine learning)은 재무 또는 회계 분야에서 문제 해결에 사용되는 두 가지 대표적인 인공 지능 분야라고 할 수 있다. 지금까지 재무 분야에서 전문가 시스템이 문제해결에 사용된 분야들을 예로 들면 기업신용평가[2][4][8], 자본예산[22], 재무투자자문[17], 재무 헤징[10], 대출 포트폴리오 분석[15] 등을 들 수 있다. 그러나 최근 몇 년 간에 걸쳐 기업 도산 예측 문제에 있어서 인공신경망이라는 또 다른 기계적 학습 기법의 사용이 여러 학자들에 의해 논의되어져 왔다.[25] 도산 예측 문제를 예로 들면, 국내의 경우 기업 도산 예측 분야에서 [1], 미국의 경우 은행의 도산 예측[28]에 있어서 인공신경망 모델은 기존의 통계적 모델들에 비해 보다 낮은 오분류율(誤分類率)을 나타내었다. 이들 기업 도산예측 모델들이 인공신경망 모델에서 사용한 대부분의 데이터는 재무 데이터들이었으나 비재무 데이터를 추가적으로 사용할 경우 예측력이 증가한다는 등 비재무 정보의 유용성에 대한 연구결과도 나타나 있다.[3][4] 그러나 기존의 인공지능 기법들을 이용한 대부분의 도산예측 모델들이 일반적으로 건전한 기업들과 도산기업들을 사후적(ex post)으로 분류하는 모델로 재무분석가들에게 실무적인 효익이 적으며, 재무분석가들의 주된 관심인 재무적으로 어려운 기업들로부터 도산기업들을 분류하는 사전적(ex ante) 예측의 경우 예측력이 기존의 연구결과에 비해 떨어진다는 연구결과[27]는 실용적인 관점에서 시사하는 바가 크다고

할 수 있다.

인공신경망 모델이 학자들 사이에 관심을 끌고 있는 이론적 배경에는 인공신경망 모델이 비선형적 관계를 표현할 수 있는 적응 능력을 갖고 있기 때문이다. 많은 통계적 기법들이 독립변수들의 선형적 결합을 통해 예측 모델을 표현하고 있음에 반해, 인공신경망 모델은 어떠한 확률분포나 변수들 간의 선형적 관계도 가정하고 있지 않다. 따라서 인공신경망 모델은 전통적인 통계기법들보다 적응력이 크다고 할 수 있다.

회계 전문가들은 회계 보고서의 유용성을 입증하기 위해 주식투자 수익률과 회계적 수치들 간의 관련성을 검증해 왔다. 이러한 일련의 연구는 기발행된 회계 보고서와 관련하여 자본 시장이 효율적이며, 현재 주식의 가격은 재무제표에 있는 가격변동을 유발할 수 있는 기업가치를 포함한 정보를 즉각적으로 반영한다고 가정하였다. 그러나 Bernard와 Thomas는 재무제표가 공시된 후에 발생하는 사후 주가의 이상흐름(post-announcement drifts)을 발견하고 이를 대립되는 두 가지 이론으로 해석하여 이를 밝혀내려 하였다[11]. 즉, 첫째로 이러한 사후 주가의 이상흐름은 주식수익률을 결정하는 또 다른 위험을 전문가들이 알아내지 못했음에 기인할 수 있다는 것이며, 둘째는 사후 주가의 이상흐름이 기업가치를 포함한 재무제표의 정보를 즉각적으로 반영하지 못하는 주식시장의 비효율성이 기인한다는 것이다. 그들의 연구결과는 첫번째 이론보다는 두번째 이론, 즉, 재무제표에 포함된 기업가치 관련 정보가 주식시장에 늦게 반영된 것에서 비롯된다는 주장들과 일치하고 있다고 할 수 있다.

또한 Ou와 Penman은 주식시장이 순이익 및 주가수익을 예측하는데 유용한 현재 재무제표 정보들을 제대로 활용하지 못하고 있다는 연구결과를 발표하였다.[23] 즉, 기업의 미래 순이익의 변동 방향을 예측하기 위하여 Ou와 Penman은 로짓 모델을 이용하여 일년 뒤 순이익의 증가 확률을 추정할 수 있도록 기본적 회계 변수들을 조합하였다.[24]

이러한 모델을 통해 포트폴리오를 구성한 결과 12.5%의 누적 비정상 수익률을 달성할 수 있었다.

본 연구의 목적은 이러한 연구결과에 근거해 일반적으로 이용 가능한 회계정보로부터 주식시장을 ‘승자’와 ‘패자’로 분류하여 주식시장에서 이익을 산출할 수 있는 거래전략을 수립해 주는 인공신경망 모델을 구축하는 것이 가능한지 여부를 검증해보는 것이다. 또한 이 연구결과가 검증된다면 즉, 재무제표가 주가에 즉각적으로 반영되지 않는 회사의 가치를 포함하고 있다고 한다면 위의 연구결과도 어느 정도 일맥상통성을 가지고 있다고 할 수 있다. 일시적인 비정상적 가격은 궁극적으로 회사의 진정한 가치에 이끌려 조정되게끔 되어있다. 다시말해 이론적으로 재무제표에 있는 가격변동 유발정보들이 주식시장에 반영되기까지, 재무제표 분석을 통해서 고평가된 주식(미래 패자)과 저평가된 주식(미래 승자)을 판별해낼 수 있을 것이다.

이 연구의 진행 및 결과는 다음과 같은 순서로 기술되었다. 첫째 절에서는 인공신경망 모델의 재무회계적 응용에 대하여 간략히 기술하고, 회계정보를 기반으로 한 투자전략에 있어서 인공신경망 모델 활용 방안 및 이론적 근거에 대하여 서술하였다. 둘째 절에서는 인공신경망 모델의 구성과 인공신경망 모델의 응용에 있어서의 장점과 단점에 대하여 기술하였다. 셋째 절에서는 자료의 수집 및 분석에 사용될 인공신경망의 구조에 대하여 서술하였다. 넷째 절에서는 자료분석 결과 인공신경망 모델의 성과와 시장 성과를 상호 비교하였다. 마지막으로 다섯째 절에서는 연구의 결론을 기술하고 미래 연구 방향을 제시하였다.

2. 인공신경망 모델과 재무적 응용

인공신경망 모델은 처리 마디(nodes), 층(layers), 연결 링크(links), 활동 함수(activation function), 학습 알고리즘(training algorithm) 등과 같은 요소로 구성된 정보처리 시스템이라고 정의할 수 있다. 대부분의 인공신경망 모형에는 입력 마디(input

nodes), 은닉 마디(hidden nodes), 출력 마디(output nodes)의 3가지 처리 마디가 존재한다. 입력 층은 시스템 외부로부터 입력 자료를 받아들여 시스템으로 이들을 전송한다. 시스템 안쪽에 자리잡고 있는 은닉층은 입력 값을 넘겨받아 그것들을 처리한 뒤, 즉각적인 결과를 산출해 낸다. 출력층은 입력 값과 현재 시스템 상태에 기준하여 시스템 출력 값을 산출해 낸다.

최근 수 년간 수많은 연구자들에 의해 재무회계 분야에서 인공신경망 모형이 활용되어져 왔다. 그러나 인공신경망의 내부 배열(은닉층과 은닉 마디의 수)은 확실한 이론적 배경에 의해서라기 보다는 경우에 따라 시행착오 또는 어렵짐작의 방법으로 결정되어져 온 것이 사실이다. 은닉층의 최적 수를 확고하게 결정지어 주는 이론적 토대가 없음이 인공신경망 모형의 용용 연구에 있어서 항상 걸림돌이 되어져 왔다. 또한 인공신경망 모형은 그 자체의 블랙박스적 특성 때문에 입력 변수와 출력 변수와의 상호 관계를 이해하기가 쉽지 않다. 통계 모델에서 계수와 변수들의 확률 값은 관계의 강도와 유의도를 나타내 주는데 반해, 인공신경망 모델에서 내부 가중치들은 입력층, 은닉층, 출력층 내에서 모두 함께 얹혀있어 변수들간의 상관관계를 뚜렷이 표출하지는 않는다.

이러한 몇 가지 결점들에도 불구하고 인공신경망 모델은 기업도산 예측 문제[1][3][12][13][26][28], 주식투자시점 결정[9], 전환사채의 가격결정[5], 재무제표의 오류판단[6], 회계감사 응용[21], 주가지수 선물거래 응용[7], 조세관련 응용[14], 기업 공개시의 IPO가격 결정[18] 같은 재무회계 응용 분야에서 매우 인기 있는 도구로 활용되어지고 있다. 투자분석 문제에서 데이터와 정보의 대부분은 계량적 데이터이며 종종 많은 이상 값들(outliers) 때문에 분석이 곤란할 때도 있다. 따라서 선형성과 정규성을 분포와 같은 가정에 바탕을 둔 통계분석[19] 들의 대부분은 투자분석 문제에 있어서 제한적으로 사용될 수 밖에 없었다. 또한 인공신경망은 같은 인공지능의 분야로 전문가의 도움없이 데이

터를 통해 지식을 도출해내는 기계적 학습의 장점을 갖고 있기도 하다[20]. 위와 같은 몇 가지 이유로 인해 인공신경망 모델은 재무용용 분야에서 많은 주목을 받고 있다.

3. 데이터와 모델

이 연구에서는 인공신경망을 활용하여 재무제표 변수들을 통해 미래 비정상 수익률을 예측하는 것이 가능한지를 분석해 보기로 한다. 이미 회계분야에서는 공개된 재무제표 정보에 기초하여 ‘이익을 창출할 수 있는’ 전략을 수립하는 것이 가능한지 여부를 검증함으로써 재무제표 분석이 유용한가를 평가해 왔다. 공개된 재무제표 정보의 예측능력을 평가하기 위해 Ou와 Penman은 로짓모델을 이용하여 일년 후 수익률의 증감확률에 기초한 포트폴리오를 구성하였다. 이에 반해 본 연구에서는 각종 재무제표 변수들과 순이익 간의 관계를 인공신경망을 통해 분석함으로써 미래 ‘승자’와 ‘패자’로 회사들을 구분하는 거래 전략을 통해 포트폴리오를 구축해 보기로 한 것이다. 왜냐하면 인공신경망 모델은 재무분야에 있어 분류, 균집화와 같은 작업에 효과적으로 적용될 수 있기 때문이다.[16]

3.1 데이터 수집

이 연구는 한국신용평가(주)에서 발행한 KIS-FAS(Korea Investors Service - Financial Analysis System)의 1993년부터 1995년까지의 재무제표 정보를 활용하고 있다. 자료들의 동질성을 확보하기 위해 다음과 같은 기준에 따라 대상 기업들을 선택하였다.

1. 1993년부터 1995년까지 상장기업 중 제조업에 속한 기업들을 선택한다.
2. 기업 회계연도가 12월 31일에 끝나는 업체들을 선택한다.
3. ‘규모의 효과’ 가능성을 고려하여 매출액 상위 5%, 하위 5%의 기업들은 제외한다.

KIS-FAS에서 수집한 총 776개 기업 가운데 위의 기준들에 따라 411개 만이 선택되었다. 월별 주가수익 정보는 한국신용평가(주)의 KIS-SMAT (Korea Investors Service Stock Market Analysis Tool)에서 수집한 1995년 4월부터 1996년 3월까지의 데이터 파일을 참고하였다. 주식들은 재무제표가 공개된 후인 1995년 4월 1일부터 12개월 동안 보유 되었다. 기업 회계연도가 매년 12월 31일에 끝나는 기업들의 재무제표는 대부분 다음해 3월 말까지 공개된다. 각 단계별로 선택된 기업들의 수가 다음 <표 1>에 나타나 있다.

<표 1> 각 단계에서 선택된 회사의 수

각 단계에서 선택된 회사의 수	회사수
총 상장기업 수	776개
제조업에 속한 기업들을 선택	545개
결산월이 12월인 기업들을 선택	470개
매출액 상위 5%, 하위 5%의 기업들을 제외	411개
분석 기간 중 한 해라도 결측치가 포함된 기업들을 제외	397개

411개 회사 중 1993년부터 1995년 까지의 기간 동안 한 해라도 데이터가 빠진 회사는 분석 샘플에서 제외되었으며, 결과적으로 397개의 회사가 최종적으로 선택되었다.

3.1.1 변수들의 선택

주가수익률 예측을 위한 인공신경망 모델을 구축하기 위해서는 먼저 모델에 포함될 재무제표 관련 변수들을 정의해야 한다. 본 연구는 변수의 선정을 위해 Ou and Penman의 연구[24]에서 미래 주가수익률의 변동을 예측하는데 관계이 크다고 판단되어진 28개의 재무변수 중 한국 증권시장에서의 데이터 획득 가능성 및 인공신경망의 크기 등을 고려하여 8개의 재무비율들을 분석에 포함시키기로 하였다. 한국신용평가(주)의 KIS-FAS에서 얻은 재무비율 정보들을 기초로 하여 데이터를 수집하였으며 몇 개의 중복된 자료들을 제거한 뒤,

다음과 같은 8개의 재무 변수들을 인공신경망 모델의 입력자료로서 선택하였다.

$$X1 : \frac{\text{재고자산}}{\text{총자산}} \text{의 변화량} (\%)$$

$$X2 : \text{주당 배당금 } \left(\frac{\text{배당금}}{\text{총주식수}} \right) \text{의 변화량}$$

$$X3 : \text{총자산이익률 } \left(\frac{\text{순이익}}{\text{총자산}} \right)$$

$$X4 : \text{유동비율 } \left(\frac{\text{유동자산}}{\text{유동부채}} \right) \text{의 변화량} (\%)$$

$$X5 : \text{유동부채 } \rightarrow \text{자기자본 비율 } \left(\frac{\text{유동부채}}{\text{자기자본}} \right)$$

$$X6 : \text{자기자본이익률 } \left(\frac{\text{순이익}}{\text{자기자본}} \right)$$

$$X7 : \text{현금회전율 } \left(\frac{\text{매출액}}{\text{현금 + 시장성유가증권}} \right)$$

$$X8 : \text{당좌비율 } \left(\frac{\text{유동자산} - \text{재고자산}}{\text{유동부채}} \right) \text{의 변화량}$$

선택된 변수들은 인공신경망 모델의 입력층에서 처리마디(node)에 포함되었다. 이러한 변수선택 과정은 어떠한 특정 이론에 기초하고 있지 않은 것으로 이 연구에서만 유효할 수도 있다. 즉 여러 가지 대안들 가운데 한 가지 방법으로서 간주되어야 할 것이다. 따라서 본 연구에서 사용한 변수선택 과정이 최적 재무비율 변수들의 집합을 도출하게 해 준다고는 말할 수 없다. 그러나 만약 선택된 재무비율 자체가 미래 주가수익률을 예측하는데 아무런 도움이 되지 못한다고 한다면, '미래 주가수익률을 예측하는데 인공신경망 모델이 유용하지 않다'라는 귀무가설을 채택하게 될 것이다. 본 연구의 의의는 미래 주가수익률을 예측하는데 필요한 최적 변수들을 찾아내는 데 있는 것이 아니라 기존의 유용한 변수들을 통해 인공신경망 모형의 예측가능성을 입증해 보이는 데 그 의의가 있다. 따라서 변수의 선택과정이 다소 임의적이며 기존의 회계학적 연구 결과를 적극적으로 활용하였다. 397개 회사에 대한 1993년도 9개 재무비율이 다음 <표 2>에 나타나 있다.

<표 2> 8개 재무비율 변수들의 통계치(1993)

	Average	Maximum	Minimum	Standard Deviation
X1	0.0251	11.5318	-0.6396	0.6742
X2	-0.0183	1.0000	-1.7676	0.2092
X3	-0.0071	0.3339	-6.2729	0.3190
X4	0.0355	1.3523	-0.7883	0.2686
X5	1.3605	33.9838	-115.6079	6.5022
X6	0.0065	1.5432	-4.8223	0.3628
X7	17.4031	417.9881	1.0096	26.8448
X8	0.0340	2.6138	-3.9756	0.4152
EPS(94-93)	85.7286	53292.0000	-48875.0000	5301.9174

3.1.2 인공신경망 모델의 구축

본 연구에서 인공신경망을 통한 주가수익률 예측모형의 훈련(training) 기간은 1993년부터 1994년까지이며, 1993 회계년도 재무제표 변수들이 1994년 주가수익률을 예측하는 인공신경망을 훈련시키기 위해 사용되었다. 훈련 데이터에서 주가수익률의 승자와 패자를 구분하기 위해 1994년과 1993년의 EPS의 증감분이 사용되었다. 이 연구에서는 2년이라는 비교적 짧은 겸중 기간 탓에 특정 회사의 개별적인 영향은 고려되지 않았다. 만약 어떤 회사의 주당이익률 변동치가 평균 이상이라면 (이하라면) 그 회사는 승자(패자)로 분류될 수 있다. 관찰기간(1993~1994) 동안 EPS의 평균 변동치는 85.73으로 다소 증가되는 경향이 있었다. 인공신경망 모델에서는 만약 어떤 특정 그룹의 샘플 크기가 충분히 크지 않으면 그 그룹의 속성을 정확히 판별해 내는데 어려움을 겪는 경우가 종종 있다.[12][13] 따라서 본 연구에서는 승자와 패자를 특정 (Cutoff) 값을 설정하여 결정하지 않고, 순서대로 상위 40개 기업 하위 40개 기업 총 80개 기업을 훈련세트(training set)로 선택하였다. EPS 증감분의 상위 커트라인은 1,800이었으며, 하위 커트라인은 -1,600이었다.

4. 실증분석 결과

이미 앞에서 언급한 바와 같이 은닉층 내에 총

분히 많은 처리 마디(node)를 가지고 있다면 단일 은닉층 신경망(single hidden layer networks)도 입력 변수와 출력 변수 사이의 관계를 설명해 줄 수 있는 것으로 판명되었다. 따라서 본 연구에서는 단일 은닉층을 가지는 인공신경망 모델을 이용하여 분석하였다. 그러나 은닉층 내의 적정 처리단위 수에 대한 문제는 이 분야에 대한 연구가 충분히 이루어지지 않아 항상 논란의 대상이 되어 오고 있다. 본 연구에서는 인공신경망 시스템 패키지로 Brain Maker for Professional V3.11을 사용하였으며, 패키지에서 기본값으로 제공한 10개의 노드를 은닉층에서의 처리마디로 사용하였다.

4.1 인공신경망 모델의 훈련 및 검증

인공신경망 모델의 성과는 오분류율(誤分類率, misclassification rate)과 평균절대오차(mean absolute error)와 RMS오차(root mean squared error, 이하 RMS라 함)로 측정할 수 있다. 오분류율은 샘플에서 승자 또는 패자로 잘못 분류된 회사들의 수를 총 회사 수로 나눈 것이다. 평균절대오차는 패턴의 실제 값과 인공신경망의 출력 값 사이의 차이를 평균한 것이다. MSE는 다음과 같이 정의할 수 있다.

$$MSE = \frac{\sum_{i=1}^N (O_i - V_i)^2}{N}$$

O : 인공신경망 출력 값

V : 패턴의 실제 값

N : 샘플의 수

RMS는 평균을 구하기 위해 두 값의 차이를 제곱한 값들의 합에 제곱근을 사용한 것으로, RMS는 큰 오차에 더 높은 가중치를 부여하는 경향이 있다. RMS는 다음과 같이 정의할 수 있다.

$$RMS = \sqrt{\frac{\sum_{i=1}^N (O_i - V_i)^2}{N}}$$

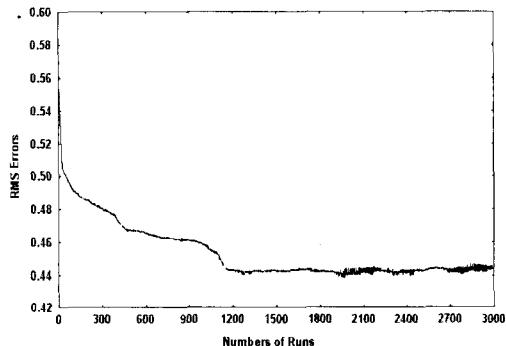
훈련용 세트(training set)의 오분류율은 훈련 허용치(training tolerance)에 따라서 상이하게 나타난다. 본 모델에서 인공신경망의 출력 값은 시그모이드 함수(sigmoid function)를 사용하여 0에서부터 1까지로 정의한다. 0은 미래 주당수익률(EPS) 관점에서 패자(loser)를 의미하며 1은 승자(winner)를 의미한다. 훈련 허용치 0.1이 의미하는 바는 훈련 패턴 값이 1이라고 했을 때 0.9보다 작은 값이 출력되었을 때는 이는 예측이 틀린 것으로 간주 된다는 것이다. 마찬가지로 훈련 패턴 값이 0이라고 가정했을 때는 0.1보다 큰 출력값들은 잘못된 예측으로 간주될 것이다. 만약 인공신경망 출력 값이 틀린 것으로 간주된다면 후방학습알고리즘(backpropagation algorithm)에 의해 가중치가 조정된다. 훈련 허용치 0이 의미하는 바는 처리단위의 출력 값이 훈련 패턴 값과 정확히 일치해야 올바른 분류로 간주 된다는 것이다. 하지만 이 같은 경우는 너무나 엄격하게 허용치를 적용한 경우이다. 훈련 허용치가 0.5인 경우를 보면 0.5보다 클 때는 승자로 판별되고 0.5보다 작을 때는 패자로 분류되게 된다. 이 경우는 너무 느슨하게 허용치가 적용된 것이라고 할 수 있다. 허용치를 너무 엄격하게 적용하면 데이터를 일반화하는 능력이 떨어지게 되고, 허용치를 너무 느슨하게 적용하면 신경망의 학습능력이 떨어지게 된다. 본 연구에서는 훈련 단계에서 허용치를 비교적 엄격하게 적용하였고, 검증 단계에서 허용치를 느슨하게 적용하였다. 학습률(learning rate)은 신경망 학습 단계에서의 수렴(convergence) 속도를 뜻한다. 본 연구에서는 기본적으로 학습률을 1.0으로 가정하였다. 본 연구에서 사용된 인공신경망에서의 학습 매개변수는 다음과 같다.

훈련 허용치 : 0.1

학습률 : 1.0

앞에서 선정된 80개 업체의 샘플을 통한 훈련 결과 [그림 1]에서 보는 바와 같이 1200회 반복훈련

이후부터 인공신경망은 안정화되고 RMS 수준이 더 이상 감소하지 않고 있다. 2000회 이상 훈련 후에는 RMS 오차 수준은 더 이상 감소하지 않았으며 오히려 편차가 증가하는 현상이 발생하였다. 본 연구에서는 검증(test)-용 데이터를 이용하여 인공신경망 모형의 예측력을 판단하기 위해 2000회 반복훈련이 실시된 인공신경망 모델을 사용하였다.



[그림 1] 훈련 허용치가 0.1일 때 8-10-1 신경망에서 RMS 오차

1993년도 재무비율과 1994년 성과로 구성된 훈련 세트로부터 인공신경망 모델이 만들어 졌고, 훈련된 인공신경망 모델에 1994년도 재무비율 변수들을 입력하여 인공신경망 모형의 예측력을 검증해 보기로 하였다. 인공신경망에서 얻어진 결과들을 활용하기 위해 고안된 투자전략은 다음과 같다.

- A. 인공신경망 출력 값에 따라 2개 그룹의 포트폴리오가 형성되었다. '승자' 포트폴리오는 인공신경망 출력 값의 상위 30개 회사들로 구성되어져 있다. 우리는 이것을 '30-승자' 포트폴리오라고 부르기로 한다.
- B. 인공신경망 출력 값의 하위 30개 회사들은 패자로 구분된다. 우리는 이것을 '30-패자' 포트폴리오라고 부르도록 한다.
- C. 주가수익률에 대한 포트폴리오 효과를 비교하기 위해 본 연구에서는 추가적으로 두 가지 포트폴리오 세트(상위 50개; 승자-50, 하위

50개; 패자-50, 상위 100개; 승자 100, 하위 100개; 패자-100)를 고려하였고, 각각의 포트폴리오 수익률의 성과가 다른 세트들과 상호 비교되었다.

- D. 각 포트폴리오에서 선택된 주식들은 일단 매입한 후 12개월 동안(95년 4월부터 96년 3월 까지) 보유하는 것으로 가정하였고, 주가수익률은 같은 기간의 제조업 평균 수익률, 종합주가지수 수익률과 비교하였다.

각 포트폴리오의 성과는 앞서 결정된 보유기간 동안 각 포트폴리오의 보유 수익률을 관찰함으로써 측정되었다. 보유기간은 95년 4월부터 96년 3월 까지이다. 12월 31일에 회계년도가 끝나는 기업들은 대부분 이듬해 3월말에 재무제표를 공시한다. 따라서 시간적 지체 없이 즉각적으로 거래전략을 수행할 수 있도록 포트폴리오의 보유 기간은 4월 초에 시작하는 것으로 가정하였다. 12개월이라는 보유 기간은 거래 전략의 성과를 측정하기에는 다소 짧은 기간인 것처럼 느껴진다. 하지만 12개월이 지난 후 이듬해 재무제표가 공시되고 나면 최신 정보로부터 새로운 전략이 다시 수립되어져야 한다는 사실을 고려해 볼 때, 12개월의 보유 기간은 본 연구의 목적에 적합한 것이라고 여겨진다.

포트폴리오를 12개월 동안 보유함으로써 얻어지는 수익률은 다음과 같이 계산할 수 있다. 개별 주식들의 복리이자를 계산하여 누적하고, 계산된 개별 주식들의 수익률을 평균하여 전체 포트폴리오의 평균 수익률을 계산하였다. 본 연구에서는 매입-보유(buy-and-hold) 전략을 적용하였는데 그 이유는, 이 전략이 간단하고 거래비용을 최소한으로 줄일 수 있으며 추가적인 계산을 피할 수 있기 때문이다.

각 포트폴리오의 월별 평균 수익률과 제조업 평균 수익률, 종합주가지수 수익률을 상호 비교한 것이 <표 3>에 나타나 있으며, 12개월 동안의 누적평균 수익률을 상호 비교한 것은 <표 4>에 요약되어 있다. 일반적으로 인공신경망 모형의 네트워

크 출력값이 평균적으로 승자(1.0)에 가까운 30개 기업으로 이루어진 '승자' 포트폴리오는 나머지 두 '승자' 포트폴리오(50개, 100개) 보다 더 높은 주가 수익률을 올릴 것으로 기대되며, '패자' 포트폴리오의 경우 30개 포트폴리오가 그렇지 않은 포트폴리오(50개, 100개)에 비해 더 많은 손실을 초래할 것으로 예상된다. 하지만 위험의 관점에서는 회사 수가 적은 포트폴리오 일수록 수익률의 분산이 더 클 것으로 예상된다.

4.2 실증 분석 결과

훈련된 인공신경망 모형을 검증(testing) 데이터

를 통해 포트폴리오를 구성하고 분석한 결과는 <표 4>에서 보는 바와 같이, 12개월의 보유기간 후 승자-30 포트폴리오의 누적 수익률은 제조업 평균 수익률(-21.16%), 종합주가지수 수익률(-13.01%)보다 높은 -11.65%였다. 1995년 4월부터 1996년 3월까지는 우리 증시의 침체기로 종합주가지수를 기준으로 수익이 13% 이상 감소한 것으로 나타났으나, 종합주가지수에 비해 승자-30 포트폴리오의 평균 수익률은 1.5% 이상 높은 것으로 나타났다. 또한 본 연구에서 사용된 주식들은 모두 제조업 주식들로서 제조업의 평균주당수익률이 -21%에 달한 것을 고려한다면, 승자-30 포트폴리오는 제조업 평균에 비해 무려 10% 정도 높은 수

<표 3> 각 포트폴리오와 제조업, 종합주가지수의 월 평균 수익률

	30개 (W)	50개 (W)	100개 (W)	제조업	상장기업	30개 (L)	50개 (L)	100개 (L)
95년 4월	-0.0654	-0.0739	-0.0706	-0.0708	-0.0399	-0.0523	-0.0570	-0.0580
95년 5월	0.0076	-0.0046	-0.0158	-0.0252	-0.0260	-0.0397	-0.0504	-0.0430
95년 6월	-0.0060	-0.0015	0.0003	0.0023	0.0033	-0.0026	-0.0050	-0.0052
95년 7월	0.1102	0.0953	0.0675	0.0428	0.0264	0.0453	0.0372	0.0262
95년 8월	-0.0266	-0.0262	-0.0451	-0.0471	-0.0323	-0.0473	-0.0494	-0.0480
95년 9월	0.0782	0.0718	0.0633	0.0544	0.0782	0.0572	0.0557	0.0548
95년 10월	-0.0016	-0.0063	-0.0002	0.0092	0.0148	0.0006	0.0024	0.0123
95년 11월	-0.0581	-0.0598	-0.0530	-0.0507	-0.0668	-0.0466	-0.0526	-0.0550
95년 12월	-0.0995	-0.0954	-0.1020	-0.0983	-0.0597	-0.0944	-0.0869	-0.0812
96년 1월	0.0954	0.0599	0.0726	0.0413	-0.0113	0.0532	0.0531	0.0265
96년 2월	-0.0691	-0.0665	-0.0718	-0.0705	-0.0365	-0.1098	-0.1039	-0.0755
96년 3월	-0.0456	-0.0360	-0.0111	0.0025	0.0206	-0.0023	0.0004	0.0043

<표 4> 각 포트폴리오와 제조업, 종합주가지수의 월 누적 평균 수익률

	30개 (W)	50개 (W)	100개 (W)	제조업	상장기업	30개 (L)	50개 (L)	100개 (L)
95년 4월	-0.0654	-0.0739	-0.0706	-0.0707	-0.0399	-0.0523	-0.0570	-0.0580
95년 5월	-0.0573	-0.0781	-0.0860	-0.0944	-0.0649	-0.0892	-0.1038	-0.0983
95년 6월	-0.0616	-0.0805	-0.0871	-0.0941	-0.0618	-0.0919	-0.1085	-0.1038
95년 7월	0.0321	0.0016	-0.0292	-0.0569	-0.0370	-0.0486	-0.0749	-0.0805
95년 8월	-0.0047	-0.0295	-0.0745	-0.1025	-0.0681	-0.0950	-0.1207	-0.1239
95년 9월	0.0725	0.0388	-0.0176	-0.0562	0.0048	-0.0435	-0.0724	-0.0776
95년 10월	0.0687	0.0307	-0.0195	-0.0494	0.0196	-0.0474	-0.0736	-0.0685
95년 11월	0.0049	-0.0314	-0.0709	-0.0976	-0.0485	-0.0874	-0.1193	-0.1186
95년 12월	-0.0896	-0.1211	-0.1629	-0.1855	-0.1053	-0.1690	-0.1951	-0.1908
96년 1월	-0.0074	-0.0745	-0.1052	-0.1551	-0.1154	-0.1212	-0.1534	-0.1708
96년 2월	-0.0760	-0.1357	-0.1681	-0.2145	-0.1477	-0.2237	-0.2439	-0.2341
96년 3월	-0.1165	-0.1679	-0.1774	-0.2116	-0.1301	-0.2309	-0.2464	-0.2315

익률을 보여주고 있다. 승자 -50, 승자 -100 포트폴리오 모두 제조업 평균에 비해 높은 수익률을 보여주고 있다. 패자 포트폴리오의 누적 수익률은 각각 -23.09, -24.64, -23.15%로 나타났다. 이 결과 또한 패자 -30, 패자 -50, 패자 -100 포트폴리오의 수익률 모두가 종합주가지수에 비해 현저히 낮으며 제조업 평균수익률에 비해서도 낮다. 또한 승자 포트폴리오의 경우 승자 -30 포트폴리오가 각각 승자 -50, 승자 -100 포트폴리오 들에 비해 수익률이 높다. 이것은 승자 포트폴리오에서 회사수가 적은 포트폴리오가 커트라인이 더 높고 따라서 더 높은 수익률을 가져다 줄 것이라는 예상과 일치하는 것이다.

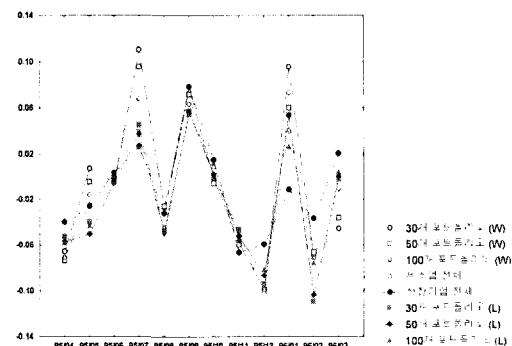
승자 포트폴리오는 패자 포트폴리오 보다 수익률에 있어서 더 넓은 분산을 보이고 있다. 12개월 동안의 월 평균 수익률(누적 평균 수익률이 아님)과 표준편차는 <표 5>에 제시되어 있다. 승자 포트폴리오와 패자 포트폴리오 모두 표준편차는 종합주가지수의 표준편차 보다 큰데, 이는 각 그룹의 크기 때문에 발생되는 당연한 결과라고 여겨진다. 두 그룹 모두에서 회사수가 적을수록 포트폴리오의 분산도 커지는 현상을 보이고 있는바 이 또한 포트폴리오의 다양성과 위험 간의 상관관계에 의해 발생하는 자연스러운 결과라고 할 수 있다.

<표 5> 12개월 동안의 승자, 패자, 제조업, 종합주가지수의 평균수익률과 표준편차

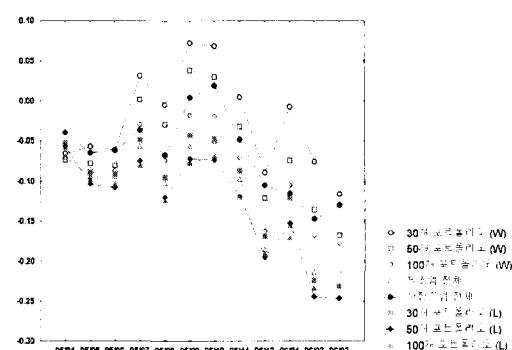
	월 평균	표준편차
30개 포트폴리오 (Winner)	-0.0067	0.0688
50개 포트폴리오 (Winner)	-0.0119	0.0608
100개 포트폴리오 (Winner)	-0.0138	0.0582
30개 포트폴리오 (Loser)	-0.0199	0.0549
50개 포트폴리오 (Loser)	-0.0214	0.0533
100개 포트폴리오 (Loser)	-0.0202	0.0453
제조업 전체	-0.0175	0.0504
상장기업 전체	-0.0108	0.0414

각 포트폴리오의 월별 평균 수익률의 변동을 나타낸 그림이 [그림 2]에 나타나 있다. [그림 2]에서 보면 30개 승자 포트폴리오가 가장 높은 변동을 보이고 있으며, 평균적으로 승자 포트폴리오가 패자

포트폴리오에 비해 더 많은 변동을 보이고 있다. 누적 수익률을 살펴보면, [그림 3]에 나타난 바와 같이 초기 1개월의 보유기간 동안 종합주가지수가 다른 어떤 포트폴리오 보다도 높은 성과를 나타냈으나, 이후 12개월의 보유기간이 지난 후에는 승자 -30의 포트폴리오의 수익률이 종합주가지수 수익률을 앞서고 있다. 반면에 모든 패자 포트폴리오의 수익률은 12개월 내내 종합주가지수 수익률 보다 밀들었으며, 12개월 후에는 제조업 전체 평균 수익률 보다 밀들고 있는 것으로 나타나 있다.



[그림 2] 각 포트폴리오의 월 평균 수익률



[그림 3] 각 포트폴리오의 누적 평균 수익률

5. 결언 및 제언

앞서의 연구결과에서와 같이 인공신경망 모델을 이용하여 시장수익률(market rate of return)보다

높은 승자 포트폴리오와 시장수익률보다 낮은 패자 포트폴리오를 구성할 수 있다고 한다면, 인공신경망 모델 및 재무제표를 통한 주당수익률 예측모형은 유용한 것이라고 간주할 수 있다. 본 연구에서의 실증분석 결과는 이러한 가설을 지지하며 따라서 인공신경망 모델 및 재무제표 정보는 미래주가수익 예측에 유용한 모델이라고 할 수 있다.

그러나 이 연구에는 몇 가지 해결해야 할 점들을 포함하고 있다. 첫째, 이 연구에서 사용된 인공신경망 구조(8-10-1)는 이론적 뒷받침에 의하지 않고 패키지의 기본값을 그대로 활용한 무작위 선택 또는 직관적인 분석에 의해 결정되어졌다. 실제로 몇몇 다른 구조를 가진 인공신경망을 구성하여 비교하여 본 결과 비슷한 실증분석 결과가 나왔으나, 본 연구에서 인공신경망 내부구조의 선택은 임의적이라는 점을 인정하지 않을 수 없으며, 이러한 사실은 수많은 인공신경망 연구에서 문제시 되어온 것이다. 따라서 본 연구는 본 연구에서 사용된 인공신경망의 내부 구조가 최적 또는 심지어 양호한 것이라고도 주장할 수는 없다. 데이터와 인공신경망 내부 구조 간의 관계에 대한 보다 깊이 있는 연구가 행해진다면 인공신경망 성과를 향상시킬 수 있게 될 뿐만 아니라 선택과정에 있어서도 필요한 노력과 시간을 절약할 수 있게 될 것이다.

또한 분석 샘플들의 동질성을 확보하기 위해 제조업이라는 특정 산업 분야만을 선택하고, 업체들의 규모를 고려하여 샘플을 줄여나간 결과 최종적으로 상당히 적은 샘플들이 분석되었다. 따라서 실증분석 결과 발견된 시장수익률을 초과하는 비정상수익률이 역사적 회계자료들에 기초하여 구축된 인공신경망에 의해 포착된 추가적 지식의 결과인지 아닌지는 적은 샘플 숫자에 의한 분석이란 관점에서 명확하게 결론을 주장하기가 어렵다. 따라서 본 연구의 주된 대상인 효율적 자본시장 가설을 반박하는 증거를 찾기 위해서는 모델의 일반화, 샘플 크기의 증가 등이 이루어져야 할 것으로 생각된다. 그러나 본 연구는 효율적 자본시장 가설을 반박하는 증거를 찾는데 있어서 과거의 전통적인 통계기

법이나 직관적인 경험에 의하지 않고 인공신경망이라는 새로운 방법론을 시도했으며, 그 실증분석 결과가 유의하며 추가적인 연구의 필요성을 충분히 제기했다는 점에서 그 의의를 찾을 수 있다고 하겠다.

참 고 문 헌

- [1] 이건창, “기업도산예측을 위한 통계적 모형과 인공지능 모형간의 예측력 비교에 관한 연구: MDA, 귀납적 학습방법, 인공신경망”, 「한국경영과학회지」, 제18권 제2호, 1993년 8월, pp. 57-81.
- [2] 이건창, 한인구, 김명종, “통계적 모형과 인공지능모형을 결합한 기업신용평가 모형에 관한 연구”, 「한국경영과학회지」, 제21권 제1호, 1996년 4월, pp.81-100.
- [3] 이재식, 한재홍, “인공신경망을 이용한 중소기업도산예측에 있어서의 비재무정보의 유용성 검증”, 「한국전문가시스템학회지」, 창간호, 1995년 1월, pp.123-134.
- [4] 이훈영, 조옥래, 이시환, “계량심리학의 방법론을 이용한 체계적인 전문가 지식구조분석 방법: 비재무항목을 활용한 중소기업 신용평가 전문시스템 규칙개발에 적용”, 「한국경영과학회지」, 제23권 제1호, 1998년 3월, pp. 161-181.
- [5] 조희연, 양진설, “파생금융상품의 가격결정을 위한 인공신경망 기법의 이용”, 「한국전문가시스템학회지」, 제3권 제1호, 1997년 6월, pp. 1-12.
- [6] 최재화, 최순재, “신경망 기법을 이용한 경영자사기 위험성 측정에 관한 연구”, 「경영학연구」, 제26권 제1호, 1997년 2월, pp.17-36.
- [7] 최재화, “신경망을 이용한 S & P 500 주가지수 선물거래”, 「한국전문가시스템학회지」, 제2권 2호, 1996년 12월, pp.43-54.
- [8] 한인구, 권영식, 이건창, “지능형 기업신용평

- 가시스템의 개발 : NICE-AI”, 「경영학연구」, 제24권 제4호, 1995년 11월, pp.91-117.
- [9] Barr, D.S. and G. Mani. “Using Neural Nets to Manage Investments.” *AI Expert*, (February, 1994) pp.16-21.
- [10] Benaroch, M. and V. Dhar. “An Intelligent Assistant for Financial Hedging.” *5th International Conference on Artificial Intelligence Applications*, Miami, FL(March, 1990).
- [11] Bernard, V.L. and J.K. Thomas. “Post-Earnings-Announcement Drift: Delayed Price Response or Risk Premium?” *Journal of Accounting Research*, 28, Supplement (1989), pp.1-36.
- [12] Boritz, J.E., D.B. Kennedy, and A. Albuquerque. “Predicting Corporate Failure Using a Neural Network Approach, Institute of Insurance and Pension Research,” *University of Waterloo, Research Report* 93-12(1993).
- [13] Boritz, J.E., and D.B.Kennedy, “Effectiveness of Neural Network Types for Prediction of Business Failure.” *Expert Systems with Applications*, Vol.9, No.4(1995), pp.503-512.
- [14] Denton, J.W., L. Syeed, N.D. Perkins, and A.H. Moorman, “Neural Networks to Classify Employees for Tax Purposes.” *Accounting Management and Information Technology*, Vol.5, No.2(1995), pp.123-138.
- [15] Hartvigsen, G. “Limitations of Knowledge-Based Systems for Financial Analysis in Banking.” *Expert Systems with Applications*, 4(1992), pp.19-32.
- [16] Hawley, D.D., J.D. Johnson, and D. Raina. “Artificial Neural Systems: A New Tool for Financial Decision-Making.” *Financial Analysts Journal*(November-December, 1990), pp.63-72.
- [17] Heuer, S., U. Koch, and C. Cryer. “INVEST: An Expert System for Financial Investments.” *IEEE Expert*(Summer., 1988), pp. 60-68.
- [18] Jain, B.A., and B.N. Nag, “Artificial Neural Network Models for Pricing Initial Public Offerings.” *Decision Sciences*, Vol.26, No.3 (1995), pp.283-302.
- [19] Jones, F.L. “Current Techniques in Bankruptcy Prediction.” *Journal of Accounting Literature*, 6(1987), pp.131-164.
- [20] Kattan, M. “Inductive Expert Systems vs. Human Experts.” *AI Expert*(April., 1994), pp.32-38.
- [21] Lenard, M.J., P. Alam, G.R. Madey, “The Application of Neural Networks and a Qualitative Response Model to the Auditor’s Going Concern Uncertainty Decision.” *Decision Sciences*, Vol.26, No.2(1995), pp.209-225.
- [22] Myers, S.C. “Notes on Expert System for Capital Budgeting.” *Financial Management*, 17:3,(Autumn., 1988), pp.23-31.
- [23] Ou, J.A. and S.H. Penman. “Accounting Measurement, Price-Earnings Ratio and the Information Content of Security Prices.” *Journal of Accounting Research*, 27, Supplement(1989), pp.111-144.
- [24] Ou, J.A. and S.H. Penman. “Financial Statement analysis and the Prediction of Stock Returns.” *Journal of Accounting and Economics*, 11(November, 1989), pp.295-329.
- [25] Reghupathi, W., L.L. Schkade, and B.S. Raju. “A Neural Network Application for Bankruptcy Prediction.” *The 20th Hawaii International Conference on System Sciences*(1991), pp.147-155.
- [26] Salchenberger, L.M., E.M. Cinar, and N.A.

- Lash. "Neural Networks: A New Tool for Predicting Thrift Failure," *Decision Sciences*, 23(1992), pp.899-916.
- [27] Suh, Y. and J. Kim, "Current Neural Network Models for Bankruptcy Prediction," *Journal of Accounting and Business Research*, Vol.4(1996), pp.81-101.
- [28] Tam, K. "Neural Network Models and the Prediction of Bank Bankruptcy." *OMEGA International Journal of Management Science*, 19:5(1991), pp.429-445.