

인공신경망모형을 이용한 주가의 예측가능성에 관한 연구

정용관* · 윤영섭**

<요약>

주가가 과연 예측가능한가의 여부는 이론적으로나 실무적으로 매우 중요한 의미를 가져 이 부분에 대해 많은 연구가 이루어져 왔으나 많은 기존연구들은 주가가 예측 가능하다는 결론을 얻지 못하고 있으며, 예측 가능하다는 연구에서도 예측력이 크지 않게 나타나고 있다.

이러한 실증결과는 실증모형의 선택이 적절하지 못한데서 나타날 수 있다는 가능성을 배제할 수 없다. 기존연구들이 실증분석에서 선형모형을 사용했는데, 선형모형으로는 주가의 예측가능성을 정확히 검증하기 어려운 현실적 요인들이 존재할 수 있다. 증권시장에는 시장실패를 방지하기 위한 규제나 제도 및 시장의 불완전성으로 인해 주가움직임에 선형모형으로 추정하기 어려운 특이패턴이 발생할 수 있기 때문이다.

이 논문에서는 이러한 특이패턴이 존재한다는 가능성을 전제로 비모수적 모형, 그 중에서도 인공신경망모형을 이용하여 주가예측 가능성을 재검증해 보고자 한다. 특히 인공신경망모형을 이용한 예측성과를 동일한 구조를 가지는 선형모형의 성과와 비교함으로써 특이패턴의 고려가 주가예측에 어떤 개선을 제공할 수 있는지를 검증해 보고자 한다.

분석결과를 요약하면, 인공신경망모형이 예측력을 가질 수 있으며, 특히 유사한 구조를 가지는 선형모형보다 우월한 성과를 제공할 수 있다는 가능성을 발견하였다. 이는 선형모형으로 추정하기 어려운 특이패턴이 주가움직임에 존재하며, 따라서 이러한 패턴을 반영할 수 있는 인공신경망모형이 주가예측에 유용하게 사용될 수 있다는 것을 보이는 결과라 볼 수 있다.

I. 서론

주식시장이 존재한 이래 많은 사람들이 과거의 주가패턴을 이용해 주가를 예측하고 이를 투자에 적용해 이익을 얻으려 시도하였다. 그러나 지속적인 이익을 얻을 수 있는 투자전략이나 주가예측기법은 아직 개발되지 못한 것이 사실이다.¹⁾

이와같은 주가예측에 관한 기존연구는 대부분 주가가 예측변수와 선형관계를 가진

* 고려대 경영학과 강사

** 고려대 경영학과 교수

1) Fama와 Miller (1976)는 이러한 결과는 시도해 본 기법에 대해 인정한 것일 뿐, 시도해 보지 않은 방법 중 지속적인 이익을 제공할 수 있는 방법은 존재할 가능성이 있다고 지적하였다.

다는 가정을 전제로 하여 이루어져왔는데, 이러한 선형모형은 주가예측 가능성을 검증하는 데 있어 충분한 모형이 되지 못할 수 있다. 주가의 움직임을 선형관계로 설명·추정하는 것이 이론적으로는 타당하다 하더라도, 현실적으로 존재하는 거래제도나 규제 등 시장의 불완전성으로 인해 선형모형으로 설명할 수 없는 특이패턴이 존재할 수 있기 때문이다.

본 연구에서는 이와 같은 특이패턴에 대한 고려를 통해 주가예측력을 증가시킬 수 있는지를 확인하고자 한다. 이때, 특이패턴을 추정할 수 있는 방법은 여러 가지가 있을 수 있지만 본 연구에서는 인공신경망모형을 사용한다. 인공신경망모형은 예측대상에 대한 학습을 통해 패턴을 인식하는 데 탁월한 능력을 가지고 있는 인공지능모형의 하나로서, 최근에는 계량경제학적 접근 등 많은 연구가 이루어지고 있는 분야이기도 하다.

국내외적으로 이러한 인공신경망모형이 주가를 포함한 금융자산 가격의 변동을 예측하기 위해 학술적 또는 실무적으로 이용되고 있다. 그러나 많은 연구가 금융자산가격의 예측이 아닌 투자기법 구성을 위해 이용하였거나, 또는 주가의 움직임을 예측한 경우에도 주가추세에 관련된 부분을 제대로 통제하지 못하는 등 적절한 예측이 이루어지지 못한 경우도 있었다. 또한 인공신경망모형을 이용한 예측성과만을 측정하였을 뿐 인공신경모형 사용 배경에 대한 충분한 설명을 하지는 못하였다.

본 연구에서는 이러한 단점을 보완하여 인공신경망모형을 이용하여 특이패턴을 고려할 때 과연 주가예측력이 증가하는가를 실증적으로 검증해 보고자 한다. 특히 동일한 예측변수가 주가움직임과 선형관계를 가정하는 모형의 예측력을 구하고, 두 모형의 성과를 비교함으로써 인공신경망모형 등과 같이 비모수적 주가예측이 선형모형에서 제공하는 정보 외에 추가적인 의미를 가질 수 있는지를 확인한다.

본 연구의 구성은 다음과 같다. 제Ⅱ절에서는 주가가 특이패턴을 가질 수 있는 이유에 대해 설명하고, 제Ⅲ절에서는 특이패턴을 추정하기 위한 수단으로서 인공신경망모형의 도입이유를 설명하고, 제Ⅳ절에서 인공신경망모형에 대해 간략히 설명한다. 제Ⅴ절에서는 실제로 인공신경망모형과 선형모형을 구성하고 각 모형에 따른 예측성과를 비교함으로써 인공신경망모형을 이용한 특이패턴의 파악이 주가예측에 도움을 줄 수 있는지를 확인한다. 그리고 제Ⅵ절에서 결론을 맺는다.

II. 선형모형과 인공신경망모형

1. 기존 실증모형으로서의 선형모형

Fama(1970, 1976)에 의해서 잘 알려진 효율적 시장 가설은 아래의 <식 1>과 같이 요약할 수 있다. 이 식에서 효율적 시장은 일정 시점 t 에서 이용가능한 모든 정보는 시장에서 증권의 가격결정에 정확하고 신속하게 반영한다는 것을 의미한다.

$$f_i(P_{t+1} | \Phi_t^i) = f_m(P_{t+1} | \Phi_t^m) \quad <\text{식 } 1>$$

이때, f = 주가의 조건부 확률분포함수

P_{t+1} = $t+1$ 시점에서의 증권가격 벡터 (p_1, p_2, \dots, p_n)

Φ_t = t 시점에서 정보집합

i = 내재가치평가

m = 시장평가

또, 차익거래기회가 존재하지 않는 시장의 균형상태에서 <식 1>은 <식 2>와 같이 수익률(또는 가격)의 형태로 표시할 수 있다.²⁾ 이때, 만일 주가가 주어진 정보를 완전히 그리고 신속하게 반영하지 못한다면 각 예측변수 X 에 대한 회귀계수 β_n 은 유의한 값을 가질 수 있지만, 그렇지 못한 경우에 β_n 은 아무런 유의성을 나타내지 못할 것이다.³⁾

$$E(r_{t+1}) = \beta_0 + \beta_1 X_t^1 + \beta_2 X_t^2 + \dots + \beta_N X_t^N + \varepsilon_t \quad <\text{식 } 2>$$

이때, X^n = 정보집합 Φ 에 포함되는 n 번째 가격결정요소

기존의 주가예측가능성에 관한 대부분의 연구들은 이와 같은 입장에서 선형모형을 이용하여 검증하였다. Fisher(1966), Black(1986), French와 Roll(1988) 등은 과거 주가수익률패턴, Nelson(1976), Fama(1982) 등은 인플레이션율, Fama와 Schwert(1977), Breen, Glosten과 Jagannathan(1989)은 이자율, Shiller(1984), Fama와

2) Fama(1976) p. 179.

3) 물론 이와같이 계수 β 의 유의성으로 시장의 효율성을 검증하는 논의는 주가의 기대수익이 일정하다는(constant expected return) 입장에서의 주장이다. 만일 주가의 기대수익이 변동(time varing expected return)한다면 시장이 효율적인 경우에도 β 들은 유의할 수 있다.

French(1988)는 배당, Campbell과 Shiller(1988)는 주당이익(EPS)을 위 식의 설명변수로 사용하여 주가와의 관계를 확인하였고, 이들 이외에도 무수한 연구들이 지속적으로 이루어져왔다. 그러나 이러한 연구들은 β_{it} 의 유의성을 기각함으로써 주가수익률이 예측가능하지 않다는 대체적인 결과를 얻고있다⁴⁾.

2. 특이패턴의 존재 가능성 및 특이패턴 예측의 의미

그러나 <식 2>와 같은 선형관계가 현실적인 주가행태를 완전히 설명한다고 보기是很 어렵다. 증권시장이 다른 실물시장에 비해 더 경쟁적이고 불완전 요소가 적다고 하더라도, 증권시장에는 시장실패를 방지하기 위한 거래제도, 규제 및 미시구조 등이 존재하여 주가움직임을 선형모형으로 추정하기 어렵게 하는 주가의 특이패턴이 발생할 수 있다. 대표적인 예로, 가격제한폭제도에 의해 주가의 수익률분포가 잘려진(truncated) 형태를 갖게 되고, 또 공매의 제한으로 인해 시장의 비효율성이 쉽게 제거되지 않음으로써 주가에 어떤 특이패턴이 제거되지 않고 지속될 수 있다⁵⁾.

이러한 주가의 특이패턴은 초과수익을 얻기 위한 주가예측 또는 투자전략을 세우는데 있어 두가지 측면에서 중요한 정보가 될 수 있다. 첫째, 완전·경쟁인 시장에서 주가패턴은 자기소멸적 성질에 의해 예측을 위한 노력을 무의미하게 하지만, 거래제도 또는 규제 등에 의해 나타나는 주가의 패턴은 제도나 규제가 존재하는 한 소멸되지 않고 지속적으로 남아 있을 가능성이 크다.

둘째, 특이패턴이 존재한다면 예측변수의 모든 변동구간에서 주가변동의 민감도가 일정하지 않은 비선형 관계를 가질 수 있다. 이때 선형모형은 예측변수와 주가움직임과의 평균적인 관계만을 나타내기 때문에 이와 같은 패턴을 고려함으로써 보다 정교한 예측이 이루어질 수 있을 것이다.

4) 물론 주가의 예측가능성을 제시한 연구들도 많이 있다. 그러나 이러한 예측가능성은 주식의 기대 수익률이 시간변동(time varying)하기 때문에 나타나기 때문에 초과수익을 제공하지 못한다 지적, 또는 Nelson과 Kim(1993) 등과 같이 소표본오류에 의해 발생한 것이라는 지적 등 반론의 여지도 있다. 또 최근 Fama와 French(1992) 등이 지적한 장부-시장가치비율(book to market ratio)이 상당한 예측력을 가진다는 연구도 있으나, Davis(1994) 등은 이러한 현상이 생존편기(survivorship bias)에 기인한다고 지적하는 등 계속적인 논의가 이루어지고 있다.

5) Huang과 Stoll(1994)은 시장의 미시구조에 의해 주가의 예측가능한 부분이 존재할 수 있다고 지적하였다.

3. 인공신경망모형의 도입 배경

앞에서 설명한 것과 같은 주가움직임의 특성을 추정하기 위해서는 모수-비선형모형을 고려할 수 있다. 그러나 이러한 현실적 요인에 의한 주가의 특이패턴 추정에는 모수모형이 적합하지 않다.

모수모형은 이론에 기초한 검증 관계식과 확률분포에 대한 가정을 두고 관계식에서 추정된 값의 통계적 유의성을 검증하는 방법이다. 그러나 본 연구에서 관심을 가지는 특이패턴을 추정하기 위해 다양한 현실적, 제도적 요인을 포함한 이론적 관계식을 유도하기 어렵고 또, 현실에서 제도나 규제 등의 요인들이 동시에 주가 수익률분포에 어떠한 형태로 영향을 미치는지는 규명하기가 쉽지 않다.

이와 같이 주가의 확률분포에 대한 가정을 세우기 어렵고, 예측모형을 구성하기 위한 이론적 지침도 어려운 경우에는 자료로부터 주가패턴에 대한 정보를 직접 얻어 예측모형을 구성하는 비모수적 성격을 가지는 모형이 더 적합할 것이다. 즉, 이론이나 분포에 대한 가정없이 자료로부터 직접 유도된 관계(data driven relation)를 인식하고, 그 인식된 정보를 예측에 이용하는 것이 보다 효과적인 방법이 될 것이다.

이러한 비모수적 모형의 성격을 가진 모형으로 본 연구에서는 인공신경망(Artificial Neural Network; 이하 ANN이라 표시함)모형을 사용한다. ANN모형은 인공지능(AI)모형의 하나로, 학습을 통한 패턴인식이란 측면에서 강점을 가지고 있다. 특히 이 모형은 변수간에 관계가 존재할 것으로 보이지만 그 관계를 수식 또는 통계적으로 명확히 표현하기 어려운 경우 충분히 많은 관찰치를 이용할 수 있을 때 효과적으로 사용될 수 있는 방법이다⁶⁾.

또, 일반적으로 ANN모형에 의한 추정과정은 블랙박스로 비유되기 때문에 이 모형에 의해 추정된 패턴은 논리적 근거를 확보하지 못한다는 문제점을 가진다고 한다.

6) 물론 ANN모형 외에도 비선형과 비모수적 성격을 가지는 통계기법은 다양하게 존재하지만, 최근 계량경제학 접근이 이루어지면서 ANN 모형이 다른 기법보다 비선형패턴의 인식능력이 탁월하다는 평가를 받고 있다. Hornik, Stinchcombe와 White(1989, 1990), Stinchcombe와 White(1989) 등은 ANN모형이 유한개의 입력처리단위를 이용해 거의 모든 형태의 패턴을 형성할 수 있음을 보였고, Lee, White와 Granger(1993)는 ANN모형에 의한 비선형검증이 전통적인 모수모형보다 우월함을 보였다. 또 다른 인공지능의 한가지로 최근 관심을 받고 있는 카오스모형도 비선형-비모수적 성질을 가진 모형이지만, 이 모형은 장기의 패턴을 잡아내는데 적합한 모형이기 때문에 국내에 적용하기에 문제가 있었다. 이러한 점을 고려할 때 ANN모형이 모든 모형중에서 가장 좋은 모형이라고 확신할 수는 없지만 특이패턴의 의미를 확인하는데는 충분하다고 보여진다.

그러나 이러한 문제점은 예측에 있어 현실적으로 더 유리하게 작용할 수 있다. 즉, 앞에서 설명한 것과 같이 주가가 시장의 거래제도나 규제 등의 다양한 요인에 의해 이론적으로 설명하기 어려운 복잡한 패턴을 가질 때, 이 패턴에 대한 논리적 근거를 포기하고 주가가 가지는 자체의 모습을 스스로 나타나게 함으로써 더 적은 비용으로 더 많은 예측정보를 얻을 수 있을 것이다.

4. 인공신경망모형을 이용한 기존의 금융자산 예측연구

ANN모형을 이용한 금융자산가격의 예측시도는 이미 다양하게 이루어져 왔다. 최초로 White(1988)는 IBM사의 주가의 움직임을 예측하였으나 예측결과는 좋지 않았다. 그러나 Grudnitski와 Osburn(1991)은 S&P500 선물지수와 COMEX의 금 선물가격의 상승/하락을 예측하여 S&P 500의 경우에 75%의 적중률을, 금선물의 경우에 61%의 적중률을 얻었다. 또한 Kryzanowski, Wright와 David(1993)는 개별기업의 1년후 주가 움직임을 예측하여 71.7%의 적중률을 얻었고, Walker(1993)는 미국의 재정증권의 현물가격과 선물가격을 예측한 결과 전날가격 대비 80%의 적중률을 보였고, 예측에 기초해 보수적 투자전략을 사용해 S&P 500 평균의 3.8배가 되는 수익률을 얻었다.

ANN모형을 실제투자에 사용하고 있는 대표적인 예는 일본의 TOPIX 예측시스템으로, 이 모형은 니코증권과 후찌즈사가 공동 개발하여 TOPIX의 매매시점을 출력하도록 학습되었다. 또, 일본의 NEC사에서 구축한 ANN모형은 93.8%의 높은 적중률을 보이기도 하였다.

ANN모형을 이용한 국내연구로 김진호, 신성환(1996)이 주식과 채권의 매매시점을 출력하도록 모형을 구축하였으나 기술적 분석의 한가지인 골든크로스 및 데드크로스를 이용한 이동평균법의 성과보다 우수하지 못하였다. 박종엽, 한인구(1996)는 4주 후 KOSPI의 상승/하락을 예측하도록 훈련시켜 다중회귀모형보다 높은 예측성과 및 투자 수익을 얻을 수 있다는 것을 보이기도 하였다. 또, 한재민, 성시중(1996)은 ANN을 이용하여 1개월후의 KOSPI 움직임을 예측해본 결과 다중회귀모형보다 높은 성과를 얻을 수 있다는 것을 보이기는 하였으나, KOSPI의 추세와 관련된 문제(허구적 회귀현상)를 통제하지 못하였기 때문에 적절한 예측이 이루어졌다고 보기는 어렵다.

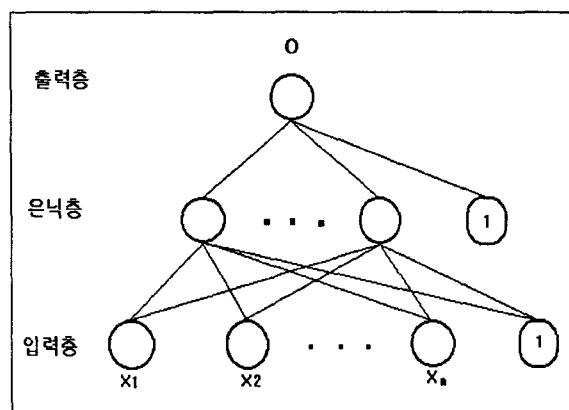
III. 인공신경망모형

ANN모형은 동물 뇌의 학습과정을 기계적으로 구현하기 위한 모형이다. 파블로프의 조건반사 실험에서 처음에 개에게는 음식과 종소리는 전혀 무관한 현상이었지만, 반복적으로 종소리와 음식을 동시에 제공함으로써 개의 뇌에서 음식을 인식하는 뉴런과 종소리를 인식하는 뉴런간의 연관성이 높아지고 결국 개는 종소리를 들으면 자연스럽게 음식을 연상해 침을 흘리게 된다. 이것이 일반적인 동물의 학습과정이고 ANN모형은 이러한 과정을 기계적으로 구현하고자 한다. 이를 위해 뇌에 대한 구조모형과 이 구조에서 뉴런간의 연관성을 조정하는 학습알고리즘이 필요한데, 본 연구에서는 다층퍼셉트론모형과 백프로퍼게이션 학습알고리즘을 사용한다⁷⁾.

1. 다층퍼셉트론

다층퍼셉트론의 일반적인 형태는 <그림 1>과 같이 입력층과 출력층 사이에 하나 이상의 은닉층이 포함하고, 각 층에서는 뇌의 뉴런 역할을 하는 처리단위로 구성되어 있다. 그리고 각 처리단위는 두 처리단위의 관련성을 표시하는 연결강도로 연결되어 있다.

<그림 1> 다층퍼셉트론의 일반적인 구조



7) 물론 ANN모형에서는 이들 이외에 다른 구조모형과 학습알고리즘이 있지만, 주가예측 분야에서 는 다층퍼셉트론과 백프로퍼게이션 알고리즘이 기존의 연구와 실무에서 다양하게 사용되고 있다.

다층퍼셉트론모형에서 처리단위 j 의 역할은 <식 3>으로 표시할 수 있다.

$$o_j = f_j(\text{net}_j) \quad <\text{식 } 3>$$

이때, $O_j = j$ 처리단위의 출력값

$$\text{net}_j = \sum_{i=1}^N w_{ji}x_i + w_{j0}\theta_j$$

$f(\cdot)$ = 비선형전환함수

x_i = 전단계 i 처리단위로부터의 입력값

w_{ij} = 전단계 i 처리단위와 j 처리단위와의 연결강도

N = j 처리단위와 관련을 가지는 전단계 처리단위의 수

즉, 각 처리단위는 전단계 처리단위에서의 출력을 입력(x_i)으로 하여 연결강도에 의한 가중합에 θ ⁸⁾를 더한 값(net_j)을 비선형함수로 전환해 다음 단계의 처리단위로 출력하는 기능을 한다. 예를 들어 위 그림의 은닉층의 처리단위는 θ 와 입력층의 연결된 각 처리단위로부터 그들의 출력값을 연결강도로 곱하여 받아들이고 이들의 합을 비선형전환하여 출력층의 처리단위로 출력한다. 이와 같은 입력과 출력이 각층의 처리단위에서 이루어지고 최종적으로 출력층에서 계산값이 구해진다. 이때, 사용되는 비선형전환함수로는 <식 4>와 같은 시그모이드함수가 가장 일반적으로 사용된다.⁹⁾ 이 전환함수는 $[-\infty, +\infty]$ 구간에서 나타나는 출력을 $[0, 1]$ 구간¹⁰⁾으로 제약하기 위해 사용되어 squashing함수라고 한다.

$$f(\text{net}) = \frac{1}{1 + e^{-\text{net}}} \quad <\text{식 } 4>$$

2. 백프로퍼게이션 학습알고리즘

ANN모형이 자료에 대해 학습한다함은 모형의 계산값이 목표값에 가깝도록 연결강

8) θ 는 회귀식에서 상수항과 같은 역할을 하는 것으로, 초기 다층퍼셉트론모형에서는 포함되지 않았으나 후에 모형의 수렴능력을 향상시키기 위해 추가되었다.

9) 이 이외에도 계단(hard limiter)함수, 임계논리(threshold logic)함수, 탄젠트(tangent)함수 등의 비선형함수가 사용되기도 한다.

10) 학습의 목적상 함수를 변형시켜 $[-1 \sim 1]$ 사이의 값으로 출력하게도 한다.

도를 조정함을 의미한다. 즉, 앞에서와 같은 다층퍼셉트론모형에서 최종출력값이 구해지면 이 값과 제시된 목표값과의 오차를 구하고, 이 오차가 최소화되는 방향으로 각 층에서의 연결강도를 조정하는 과정인 학습이 이루어져야 한다¹¹⁾.

백프로퍼게이션 알고리즘에서는 입력과 연결강도를 이용해 구한 출력값과 목표값의 차이인 오차를 하위 처리단위로 되돌려 보냄(backpropagate)으로써 오차를 감소시키는 방향으로 연결강도를 조정하며, 이와 같은 연결강도의 조정을 오차의 크기를 인정할 수 있을 때까지 앞에서 설명한 모든 과정을 반복함으로써 학습이 이루어진다. 백프로퍼게이션 알고리즘에 따른 연결강도 w_{ij} 의 조정은 <식 5>와 같다.

$$\Delta w_{ji}(n+1) = \eta \delta_{pj} x_{pi} + a \Delta_p w_{ji}(n) \quad <\text{식 } 5>$$

출력 처리단위에서 $\delta_{pj} = (t_{pj} - o_{pj}) f'(net_{pj})$

은닉처리단위에서 $\delta_{pj} = \sum_k \delta_{pk} w_{kj} f'(net_{pj})$

이때, a 는 상수, n 은 학습회수

각 처리단위간 연결강도의 변화분은 목표값과 실제값의 오차 또는 상위단계에서 전달된 오차를 학습계수로 조정한 후($(\eta \delta_{pj} X_{pi})$ 모멘텀($a \Delta_p w_{ji}(n)$))을 더하여 결정한다. 이때, 모멘텀은 학습의 속도를 증가시키기 위한 항목으로 학습횟수에 따라 연결강도의 조정 속도를 다르게 한다.

IV. 예측모형의 추정

본 연구에서는 경제변수 및 증권시장변수를 이용하여 주별 및 월별 KOSPI 수익률을 예측해보고자 한다.¹²⁾ 특히, 앞서 설명한 바와 같이 서로 유사한 구조를 가지는 선형모형과 ANN모형의 예측능력과 비교함으로써 주가예측에서 특이패턴을 고려하는 것이 얼마나 중요한가를 검증하고자 한다.

11) 이와 같이 최종 출력값에 비교할 학습의 대상인 목표값이 주어진다는 점에 따라 백프로퍼게이션은 감독학습(supervised learning)알고리즘의 하나이다.

12) 거래제도 및 규제 등에 따른 특이패턴은 일별 또는 일중수익률에서 더 두드러지게 나타날 수 있지만, Black(1986)이 지적한 노이즈 문제가 추가적으로 발생할 수 있어 고려하지 않았다. 개별기업에 대한 예측 역시 개별적 특성에 의한 노이즈 문제로 고려하지 않았다.

1. 표본기간

우선 예측기간은 월별예측의 경우에는 1986년 3월부터 1997년 2월까지의 130개월을 고려하였다. 1980년대 초반과 중반에서는 체계적으로 정리된 공시자료를 구하기 어려웠고, 특히 고객예탁금제도가 1986년 3월부터 시작되어 고객예탁금 자료를 구할 수 있는 1986년 3월을 시작월로 정하였다. 주별예측의 경우는 증권시장의 국면을 고려하여 하락기인 1989년 4월 12일부터 1992년 8월 19일까지의 기간 1과, 보합 및 상승기인 1992년 8월 26일부터 1997년 2월 28일까지의 기간 2로 나누어 표본기간을 잡았다.¹³⁾

2. 예측변수와 모형의 선정

예측변수들을 선정하기 위하여 우선 국내외의 많은 연구에서 주가와 관련을 가진다고 보고된 변수들을 1차로 수집하였다. 그리하여 국내경제변수로 통화량(월말잔액 기준 M2와 M2a), 소비자물가지수, 생산자물가지수, 경기선행지수, 경기동행지수, 생산지수, 그리고 이자율(3년만기 회사채수익률과 국민주택채권수익률), 국제경제변수로는 수출, 수입, 무역수지, 신용장액, 달러환율을 선정하였고, 그리고 증권시장변수로는 주식거래량, 고객예탁금, 신용잔고, 전기수익률의 표준편차 등 총 18개 변수들을 1차로 선정하였다¹⁴⁾. 그러나 주별예측에서는 경제변수가 주별로는 발표되지 않기 때문에 증권시장변수인 고객예탁금, 신용잔고, 거래량, 수익률의 표준편차만을 예측변수로 사용하였다.¹⁵⁾

이렇게 18개 예측변수를 선정한 후에는 두 모형에 공통적으로 사용할 수 있는 예측변수를 선정하여야 한다. 그러나 의미 있는 소수의 예측변수를 선정하기 위해서는 앞에서 고려한 총 18개의 변수와 아울러 각 변수의 시차변수까지를 모두 고려하여 총 50-60개의 변수들을 대상으로 해야 하기 때문에 많은 시간과 노력이 필요하게 된다. 이러한

13) 이러한 기간의 구분은 장하성(1994)을 참조하였다.

14) Koresha와 Partch(1985), Geske와 Roll(1983), Fama(1981), Lee(1992) 등은 이자율, 경기, 인플레이션 및 통화량 등의 경제변수, Bailey와 Chung(1995)과 Jorion(1991)은 환율 및 국제교역활동, Jennings, Stark와 Fellingham(1981) 및 국내의 남상구와 박종호(1996)는 신용잔고, Tauchen와 Pitts(1983), Karpoff(1987), Gallent, Karpoff와 Tauchen(1992)은 거래량, 장하성(1994)은 고객예탁금과 주가와의 관계를 확인하였다.

15) 증권시장자료인 고객예탁금, 신용잔고, 거래량은 평균의 개념이다. 예를 들어 주별 고객예탁금은 주간 누적 고객예탁금을 해당영업일 수로 나누어 구하였다.

문제를 해결하기 위해 다음과 같이 선형모형과 ANN모형의 기준에 따라 예측변수로서의 적합성을 구하고, 두 기준을 모두 충족시키는 변수를 최종적으로 선정하였다.

우선 주가의 선형관계를 가지는 예측변수를 선정하기 위해 교차상관분석과 VAR모형에 의한 분산분해의 결과를 이용하였다. 1차로 18개의 변수에 대한 교차상관관계분석을 통해 주가에 대해 유의한 선행관계를 가지는 변수를 찾아내고, 2차로 교차상관분석에서 주가에 대해 선행관계를 가지는 것으로 나타난 변수들 또는 다른 변수들과의 조합을 이용한 분산분해를 통해 주가에 대한 선행 설명력의 크기를 구해 가장 적합한 예측변수 및 해당변수의 시차를 구하였다.¹⁶⁾ 또, ANN모형에 적합한 변수를 선정하기 위해 입력층에 5개의 처리단위를 가지고 은닉층을 1개 가지는 ANN모형을 구성하였다¹⁷⁾. 이 모형에 해당 변수와 목표값에만 실제 관측치를 대입하고 나머지 변수는 평균값을 일관적으로 대입해 동일한 회수를 학습시켰을 때 오차를 최소로 하는 변수와 그 변수의 시차를 구하였다.

이러한 두 가지 관계를 동시에 만족시켜 예측을 위해 선정된 변수는 <표 1>에 정리하였다. 이때, 월별 변수중 CONIX(-1)와 DEPOSIT(-2)는 교차분석에서 유의하지는 않았지만¹⁸⁾, ANN모형을 통한 학습에서 오차를 비교적 크게 줄이는 것으로 나타나 선정되었다¹⁹⁾.

<표 1> 각 기간별 예측변수

월별 변수	주별 기간1 변수	주별 기간2 변수
CONIX(-1) 전월경기동행지수	CREDIT(-3) 3주전 신용잔고	DEPOSIT(-1) 전기 고객예탁금
PPI(-1) 전월 생산자물가지수	DEPOSIT(-3) 3주전 고객예탁금,	CREDIT(-1) 전기 신용잔고
FX(-1) 전월 달러환율,	STD(-1) 전주 수익률의 표준편차	VOL(-2) 2주전 거래량
STD(-1) 전월수익률 표준편차,	VOL(-2) 2주전 거래량	STD(-2) 2주전 수익률 표준편차
DEPOSIT(-2) 2개월전고객예탁금		

16) 부록에 예측모형에서 사용된 변수들과 주가의 교차상관분석, 분산분해분석의 결과를 나타내었다.

17) ANN모형의 구체적인 형태와 학습방법은 다음절에서 소개한다.

18) 교차상관분석에서 CONIX(-1)와 DEPOSIT(-2) 각각의 유의수준(p값)은 13%와 18%이었다.

19) 주가와 유의한 결과를 가지는 것으로 나타난 변수중 예측변수간의 상관관계가 큰 경우는 다중 공선성(multicollinearity)의 문제를 발생시킬 수 있으므로, 두 변수중 주가와의 관계가 큰 것을 선택하였다.

3. 기초통계량

각 변수의 기초통계값은 <표 2>에 정리되어 있다. 각 변수가 시계열상의 추세를 갖는지를 검증하기 위하여 확장 디키풀러(Augmented Dickey Fuller ; ADF) 검증을 실시하였다. ADF-t값을 보면, 월별자료에서는 경기동행지수, 생산자물가지수, 대미환율, 고객예탁금, KOSPI, 그리고 주별기간 1과 2에서는 KOSPI와 고객예탁금이 단위근을 가지는 것으로 나타난 것을 볼 수 있다. 따라서 이 변수들에 대해서는 로그차분을 통해 안정시계열로 전환하였다²⁰⁾.

<표 2> 예측변수의 기초통계량

A : 월별자료 (1986년 3월 - 1997년 2월)

변수	관찰치수	평균	표준편차	최대값	최소값	ADF t값
CONIX	130	105.0	21.2	144.9	67.3	-2.280
PPI	130	102.9	8.63	119.1	90.8	-2.353
FX ¹⁾	130	768.3	57.8	889.9	666.3	-2.426
DEP ²⁾	130	1,807,818	881,917	3,823,333	168,085	-2.825
STD	130	0.0117	0.0041	0.0265	0.0052	-3.915**
KOSPI	130	702.86	217.76	1105.62	199.76	-1.857
D(CONIX)	129	0.0064	0.0061	0.0281	-0.0100	-8.820***
D(PPI)	129	0.0020	0.0044	0.0119	-0.0088	-7.293***
D(FX)	129	-0.0010	0.0079	0.0269	0.0079	-4.177***
D(DEP)	129	0.0198	0.2065	0.6921	-0.6989	-12.406***
D(KOSPI)	129	0.0132	0.0737	0.1901	-0.1997	-14.026***

B : 주별 기간 1 (1989년 4월 12일 - 1992년 8월 19일)

변수	관찰치수	평균	표준편차	최대값	최소값	ADF t 값
KOSPI	142	727.25	128.96	983.53	492.66	-2.346
CREDIT ²⁾	142	1,778,713	463,341	2,663,558	1,048,613	-2.069
DEPOSIT ²⁾	142	1,652,064	413,844	2,984,129	897,772	-4.508***
STD	142	0.2774	0.0151	0.2984	0.26498	-13.489***
VOL ³⁾	142	133,738	72,335	462,575	42,082	-5.191***
D(KOSPI)	141	-0.0037	0.0348	0.19752	-0.1436	-15.136***
D(CREDIT)	141	-0.00008	0.0325	0.1517	-0.0965	-6.526***

20) 따라서 앞으로 본 논문에서 사용되는 모든 변수는 차분표시(D(·))를 하지 않은 경우도 안정화 시킨 시계열을 의미한다.

C : 주별 기간 2 (1992년 8월 26일 - 1997년 2월 28일))

변수	관찰치수	평균	표준편차	최대값	최소값	ADF t 값
KOSPI	242	851.98	136.93	1138.39	513.82	-2.4936
CREDIT ²⁾	242	1,767,342	309,661	2,663,533	1,163,119	0.8605
DEPOSIT ²⁾	242	2,666,533	513,268	4,101,362	1,249,627	-3.3359**
STD	242	0.27813	0.01966	0.40801	0.26780	-14.4172***
VOL ³⁾	242	319,763	125,328	672,710	94,857	-5.5408***
D(KOSPI)	241	0.00237	0.02832	0.09084	-0.06101	-14.5517***
D(CREDIT)	241	0.00369	0.03014	0.17248	-0.10891	-5.7587***

주 : 1) 단위 : 원 2) 단위 : 100만원 3) 단위 : 100주

* 10%에서 유의적 ** 5%에서 유의적 *** 1%에서 유의적

D()는 해당 변수의 차분값을 의미함

4. 예측모형의 추정

특이패턴 인식에 따른 예측능력 비교를 위해 ANN모형에 대응하는 선형모형으로 다중회귀(REG)모형을 선택하였다. REG모형과 ANN모형은 구조가 유사하고 단지 변수들간의 관계에 대한 가정에서 선형과 비선형, 그리고 모수모형과 비모수모형으로 대칭된다.

앞서 선정된 변수들을 이용한 REG모형과 ANN모형의 예측모형을 추정하기 위해 다음과 같은 방법을 사용하였다. 월별예측에서는 REG모형과 ANN모형 모두 총 130개의 관찰치중 마지막 30개를 제외한 100개의 관찰치로, 또 주별예측에서는 기간 1에서 총 172개의 관찰치중 142개로, 기간 2에서는 총 242개중 212개를 훈련자료(training data)로 하여 예측변수와 주가움직임간의 관계를 추정하였다. 그리고 이렇게 구한 패턴을 나머지 30개의 예측자료에 적용함으로써 예측성과를 검증하였다.

(1) 다중회귀분석

다중회귀분석을 통해 추정된 예측모형의 추정결과는 <표 3>과 같다. 월별자료와 기간 1의 주별자료에서는 유의한 계수와 F값이 나타났지만 기간 2의 주별자료에서는 어떠한 유의한 값도 나타나지 않았다.

<표 3> 각 기간 추정된 다중회귀모형과 계수

월별: $r_t = c + \beta_1 PPI_{t-1} + \beta_2 FX_{t-1} + \beta_3 CONIX_{t-1} + \beta_4 STD_{t-1} + \beta_5 DEPOSIT_{t-2}$

주별1: $r_t = c + \beta_1 DEPOSIT_{t-3} + \beta_2 CREDIT_{t-3} + \beta_3 STD_{t-1} + \beta_4 VOL_{t-2}$

주별2: $r_t = c + \beta_1 DEPOSIT_{t-1} + \beta_2 CREDIT_{t-1} + \beta_3 STD_{t-2} + \beta_4 VOL_{t-2}$

월별자료		주별자료 (기간1)		주별자료(기간2)	
변수	계수	변수	계수	변수	계수
C	-0.0436*	C	-0.0392	C	0.0460
β_1	-2.9370	β_1	0.0595**	β_1	-0.0104
β_2	-3.5167***	β_2	-0.1701**	β_2	-0.0490
β_3	1.4806	β_3	0.1299	β_3	-0.1553
β_4	4.3217**	β_4	0.0049	β_4	-0.0092
β_5	-0.0615*				
R ²	0.2359	R ²	0.0689	R ²	0.0250
Adj R ²	0.1935	Adj R ²	0.0430	Adj R ²	0.0023
F	5.557***	F	2.6629**	F	1.1028

주) 1) ***는 1% 수준, **는 5% 수준, 그리고 *는 10% 수준에서 유의적임.

(2) 인공신경망모형²¹⁾

ANN모형을 구성하기 위해 입력층에는 회귀분석과 같은 변수를 평균과 표준편차를 이용해 표준화된 값을 대입하였고, 목표값은 0.1~0.9 범위로 전환해²²⁾ 대입하였다. 또한 은닉층은 1개를 가정하였다. 즉, 월별자료에 대한 ANN모형은 입력층에 바이어스항을 제외하고 5개의 처리단위를 가지고, 은닉층에는 3개에서 5개까지 처리단위의 수를 변화시키면서 최적 모형을 선정하였다. 주별자료 모형은 입력층에 바이어스항을 제외하고 4개의 처리단위를 가지고, 하나의 은닉층에 3개에서 5개의 처리단위를 가지는 경우를 고려하였다.²³⁾

각각의 대안모형에 대해 시행착오를 통해 적절한 학습계수와 모멘텀항의 크기, 노이즈항의²⁴⁾ 크기 등을 정하였고, 학습의 회수는 역시 과잉학습(over fitting)의 가능성

21) 본 연구에는 Rao와 Rao(1993)의 ANN알고리즘을 참조 및 보완, 수정하여 사용하였다.

22) 본 연구에서 사용한 시그모이드 함수 출력값의 범위는 0~1 이지만, 이에 대응하는 실제 목표값의 범위를 0.1~0.9로 제한함으로써 학습의 속도를 증가시키고자 하였다.

23) 학습에 사용할 수 있는 관측치의 수가 많지 않기 때문에 발생하는 과잉학습 문제를 피하기 위해 처리단위 수를 제한하였다.

을 고려하여 정하였다²⁵⁾. 그리고 초기 연결강도가 난수로 주어진다는 점을 고려해 각 구조에 대해 3개씩의 대안모형을 형성하였다. 최종모형의 선정을 위해 학습자료중에서 무작위로 30개씩을 선정하여 검증자료를 형성하고 모형 선정은 검증자료에서 평균 오차를 최소로 하는 것으로 하였다. 최종적으로 월별의 경우에는 5-4-1²⁶⁾모형이, 기간 1의 주별에는 4-5-1모형이, 기간 2의 주별에는 4-4-1모형이 선택되었다.

V. 예측성과의 비교

이와 같은 방법으로 추정된 모형을 예측자료에 적용함으로써 실제 미래주가를 예측하고 그 성과를 평가하고자 한다. 예측성과는 예측의 정확성과 투자수익의 크기의 두가지 측면에서 추정하였다. 기존의 연구에서는 패턴의 존재여부에 관심이 있어 패턴의 통계적 유의성 또는 예측오차의 크기만을 평가하였으나, 예측의 결과가 투자활동으로 연결되어야 한다는 점을 고려하여 본 연구에서는 예측정보를 이용한 투자수익의 경제적 유의성도 확인하였다.

1. 예측의 정확성 비교

예측의 정확성은 일반적으로 <식 6>와 같이 구해지는 표준화된 평균제곱근(standardized root mean square; SRME)과 표준화된 절대평균오차(standardized absolute mean error; SAME), 그리고 예측값과 실제값의 상관계수로 표시하였다.²⁷⁾

-
- 24) 노이즈항은 해가 지역적 극값을 찾는 경우를 방지하기 위해 추가된 요소이다. 이 값의 크기가 너무 작으면 본래의 사용 목적을 달성할 수 없고, 반대로 너무 크면 본래의 패턴을 희석시킬 수 있기 때문에 적정한 크기를 선정하는 과정이 필요하다.
 - 25) 과잉학습 문제를 피하기 위한 학습횟수, 모멘텀 및 노이즈의 크기 등을 정하는 정형화된 방법은 존재하지만 이 방법들 역시 학습조건을 정하는데 있어 지침이 될 뿐 절대적인 기준은 되지 못 한다. 특히 개별적인 학습조건에 대한 지침을 마련할 수는 있지만 여러 학습조건을 동시에 고려해 최적의 학습조건을 결정하기 어렵다. 따라서 본 연구에서는 정형화된 학습방법에서 구한 값을 기준으로 하여 실제 예측모형 및 유사모형에 다양한 조건으로 수십차례에 걸친 학습과 평가를 거침으로써 적정한 학습횟수와 모멘텀, 노이즈의 크기를 정하였다.
 - 26) 5-4-1이라 함은 바이어스 항을 제외한 입력층의 처리단위 수가 5개, 은닉층의 처리단위 수가 4개이고 출력 처리단위 수가 1개인 모형을 의미한다.
 - 27) 따라서 SRMS나 SAME가 1보다 큰 경우에는 정확한 예측이 이루어지지 못한 경우를 의미하고 1보다 적은 경우에는 정확한 예측이 이루어진 것으로 해석된다.

$$SRMS = \sqrt{\frac{(O_i - T_i)^2}{n}} / \sigma \quad SAME = \frac{|O_i - T_i|}{n} / \rho \quad <\text{식 } 6>$$

이때, O_i = i 번째 예측에서 모형의 계산값 또는 출력값

T_i = i 번째 예측에서 실제값

σ = 실제값의 표준편차

ρ = 실제값의 절대평균오차

(1) 월별자료에서 예측의 정확성²⁸⁾

월별자료에 대한 예측성과는 <표 4>에 나타나 있다. 예측의 정확성을 나타내는 SRMS와 SAME는 REG모형과 ANN모형에서 모두 1보다 커 두 모형의 예측이 의미를 가지지 않는 것으로 보인다. 그러나 두 모형의 비교에 있어 ANN모형의 SRMS와 SAME이 REG모형의 값보다 작았고, 특히 상관계수는 유의한 값을 가져 ANN모형에 의한 예측이 REG모형보다는 우월함을 보이고 있다.

<표 4> 월별 자료 예측결과

	SAME	SRMS	상관계수
REG	1.2996	1.4213	-0.28462 (0.2239)
ANN	1.2161	1.3038	0.46590 (0.0384)

주) 괄호안은 p값

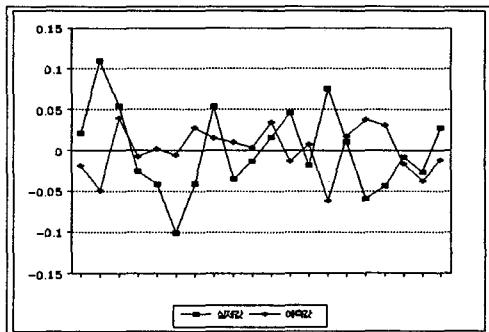
<그림 2>에는 예측의 결과를 그림으로 나타내 보이고 있다. 그림에서 보는 것과 같이 예측값들이 거의 실제 주가움직임과 유사한 변동성을 가지고 있는 것으로 보아 학습 또는 모형의 추정단계에서 상당히 유의적인 패턴을 구한 것으로 볼 수 있다.²⁹⁾ 그러나 추정된 패턴이 지속되지 않아 예측의 정확성은 그리 높지 않은 것으로 보인다.

28) ANN모형의 경우에는 초기조건이 달라 3개의 모형이 고려되었는데 각 모형의 결과가 유사하였다. 표에는 3개 모형의 결과 중에서 중간값을 나타내었다.

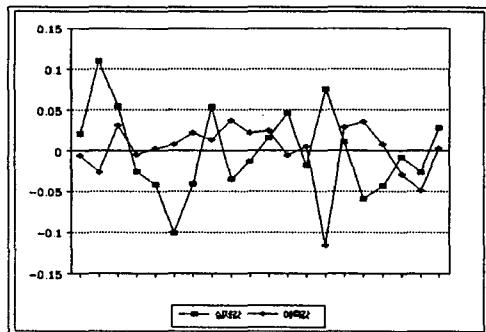
29) 일반적으로 패턴을 발견하지 못한 경우에는 회귀식의 계수에 해당하는 값이 작아 입력값의 변화에 대해 예측값이 민감하게 움직이지 않는다. 이런 점은 앞의 월별자료의 회귀식에서 계수의 유의성 및 모형의 유의성이 크게 나타난 것에서도 유추할 수 있다.

<그림 2> 월별수익률 예측결과

A : ANN모형



B : REG모형



이와 같이 주가에 패턴이 존재하더라도 그 패턴이 지속적으로 발생하지 않기 때문에 투자정보로 사용될 수 없다는 점은 주식시장이 효율적이고 동시에 주가를 예측할 수 없다는 것을 보이는 증거가 된다. 그러나 월별수익률의 예측에서 자료의 수가 충분하지 못해 다양한 기간에 대해 패턴인식과 예측을 하지 못했다는 한계를 가진다고 볼 수도 있다.

(2) 주별자료에서 예측의 정확성

① 기간 1 주별수익률 예측

기간 1의 주별수익률 예측성과는 <표 5> A에 정리되어 있다. 이 경우에는 예측의 정확성인 SRMS와 SAME가 1보다 작아 예측가능성이 어느 정도 존재하는 것으로 보인다. 특히 ANN모형의 경우 SRMS와 SAME가 모두 REG모형의 경우보다 상당히 작게 나타나고, 상관계수도 ANN의 경우 훨씬 유의하게 나타나고 있다.

② 기간 2의 주별수익률 예측

기간 2의 주별수익률 예측은 <표 5> B에 나타나있다. 예측의 정확성 측면에서 REG모형의 SRMS와 SAME는 1보다 큰 반면 ANN모형의 SRMS와 SAME는 1보다 작아 이 경우에도 역시 ANN모형을 이용한 특이패턴의 인식이 예측에 도움을 주는 것으로 보이고, ANN모형의 경우 상관계수도 REG모형과 달리 상당히 유의적인 값을 가지고 있다.

<표 5> 주별자료 예측결과

A : 기간 1

B : 기간 2

	SAME	SRMS	상관계수
REG	0.9887	1.0164	-0.1064 (0.6552)
ANN	0.9293	0.9931	0.5674 (0.0177)
REG	1.0786	1.1409	0.20195 (0.3932)
ANN	0.9896	0.9657	0.67421 (0.0041)

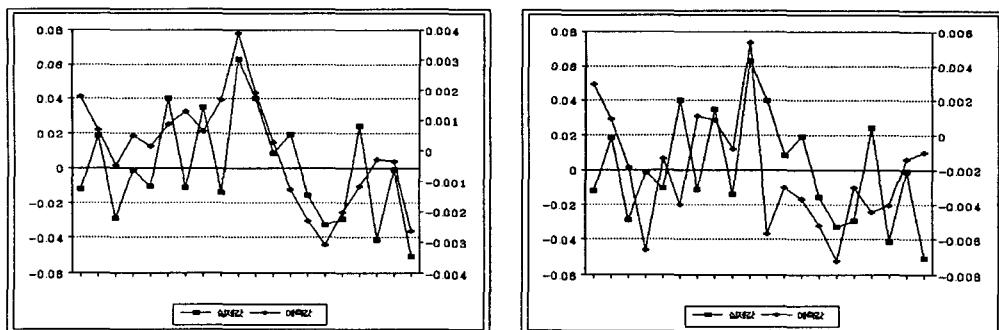
주) 괄호안은 p값

이와같은 예측성과를 <그림 3>에 그림으로 나타내었다. 그림에서 ANN모형에 의한 예측값은 실제수익률 수준을 나타내지는 못하지만, 패턴은 상당히 유사하다는 것을 보여준다. REG모형에서도 실제 주가패턴을 따르고는 있지만 그 정도가 ANN모형의 경우 보다는 미약한 것을 볼 수 있다. 이러한 점은 앞의 성과표에서 확인한 ANN모형이 나타내는 적은 예측오차 또는 유의한 상관계수값과 관련을 가지는 것으로 보인다.³⁰⁾

<그림 3> 주별예측의 결과 (기간 2)

A : ANN모형

B : REG모형



주) 왼쪽 수직축은 실제값, 오른쪽 수직축은 예측값을 나타낸다.

2. 투자성과의 비교

기존의 연구에서는 패턴의 유의성 또는 예측의 정확성만을 이용해 예측가능성을 평가하였다. 그러나 이와 같은 통계적 유의성뿐만 아니라 경제적 유의성 또한 중요한

30) 이러한 점은 성과표 상관계수에서 볼 수 있는 것과 같이 기간 1의 경우에서도 발견할 수 있었으나 그림으로 나타내는 것은 생략하였다.

평가기준이 되어야 할 것이다. 이러한 측면에서 본 연구에서는 REG모형과 ANN모형을 통한 예측결과를 간단한 보수적 투자전략에 적용하는 경우 얻을 수 있는 성과를 비교해 보고자 한다.

투자수익률을 비교하는데 있어 단순히 투자수익의 크기를 비교하는 것은 의미를 가지지 못하고, 수익의 크기와 아울러 위험의 크기를 함께 고려해야 한다. 따라서 경제적 유의성은 예측정보를 이용해 얻을 수 있는 평균수익률을 두가지의 위험추정치인 표준편차와 베타계수로 나누어 구한 위험조정 수익률로 표시하였다³¹⁾.

이때, 두 예측모형 각각에 대해 일정 투자금액을 가지고 매기간 초에 상승이 예측되면 예측대상인 KOSPI에 대해 전액 매입포지션을 취하고, 주가하락이 예측되면 전액 무위험채권을 매입한다고 가정하여³²⁾ 자금을 운용하였을 때 최종 투자성과를 구하였다. 이때, 무위험수익률은 해당기간의 평균 국민주택채권수익률을 사용하였고 예측에 의한 투자전략에서 실제 발생하는 거래비용을 포함하였다³³⁾. 또한 두 예측모형에 따른 거래성과를 같은 기간 매입-보유(B&H) 수익률과 비교하였다. 만일 예측모형에 의한 수익률이 거래비용을 포함하고도 B&H수익보다 크다면 보다 의미 있게 모형의 예측능력을 주장할 수 있을 것이다.

(1) 월별 투자성과비교

월별자료에서 투자성과 비교는 <표 6>에 정리되어 있다. 거래비용을 고려하기 전 두 예측모형에 의한 투자수익률은 위험에 관계없이 B&H성과보다 커 수익률예측이 의미를 가질 수 있는 것으로 보인다. 특히, ANN모형의 성과가 REG모형의 성과보다 더 큰 수익률을 제공하고 있어 특이패턴의 고려가 투자성과 측면에서도 의미를 가지는 것으로 보이지만, 거래비용을 고려한 경우에는 B&H수익보다 적게 나타났다.

31) 이때, 표준편차와 베타계수는 각각 예측을 통해 얻은 예측기간에서 얻은 수익의 표준편차(또는 분산)와 종합주가지수수익률과의 공분산을 이용하여 구하였다.

32) 주가의 예측력 검증이란 측면에서는 주가하락이 예상되는 경우에는 주가에 대한 공매 포지션을 취하는 것이 더 적합한 전략이 될 수 있다. 그러나 투자전략의 현실성 측면에서 우리나라 증권시장에서는 자유로운 공매가 허용되지 않으므로 주가가 하락한다고 예측되는 경우에는 주식 공매포지션보다는 채권 매입포지션을 취한다고 가정하였다.

33) 거래비용은 실제 거래에서 적용되는 비용인 매매시점에서 각각 거래대금의 0.5%, 그리고 매도 시점에서 거래세 0.2%를 가정하였다.

<표 6> 월별 자료 예측결과

	평균	평균/STD	평균/beta
REG	-0.0066	-5.0731	-0.0106
	-0.0268	-20.6259	-0.0429
ANN	-0.0015	-1.2830	-0.0028
	-0.0217	-18.5046	-0.0408
B&H	-0.0151	-5.2304	-0.0151

주) 위는 거래비용 불포함, 아래는 거래비용 포함

(2) 주별 투자성과 비교

<표 7>은 주별 예측에서의 투자성과를 보이고 있다. 이 표에서 보는 것과 같이 기간 1 및 기간 2 모두에서 위험고려의 여부와 관계없이 예측의 성과가 B&H성과보다 우월하고, 모형간 비교에서도 ANN모형의 성과가 REG모형의 성과보다 우월한 것으로 나타나고 있다.

거래비용을 포함한 경우에는 예측의 경우 B&H의 경우보다 수익률이 작게 나타났지만, 기간 2의 ANN모형에서는 거래비용을 초과한 수익률이 나타나 상당히 의미 있는 예측이 이루어진 것으로 보인다.

<표 7> 주별자료 예측결과

A : 기간 1

B : 기간 2

	평균	평균/STD	평균/beta		평균	평균/STD	평균/beta
REG	7.5E-5	0.3659	0.0002	REG	0.0035	8.8974	0.0070
	-0.0201	-98.1854	-0.0570		-0.0167	-42.9051	-0.0337
ANN	0.0024	11.5556	0.0067	ANN	0.0060	14.9305	0.0112
	-0.0177	-81.5321	-0.0472		-0.0142	-35.1985	-0.0265
B&H	-0.0110	-18.5321	-0.0110	B&H	-0.0035	-4.2052	-0.0035

주) 위는 거래비용 불포함 아래는 거래비용 포함

3. 예측변수와 주가와의 관계

앞절에서 미약하나마 주가와 선정된 예측변수간에 관계가 존재할 수 있음을 보았

다. 특히 특이패턴의 인식에 의해 두 변수의 관계가 선형모형의 경우보다 더 잘 설명될 수 있다는 가능성을 발견하였다. 본 절에서는 두 모형에서 추정한 주가와 예측변수들간의 관계를 비교해 보고 예측력의 차이의 원인에 대해 설명하고자 한다.

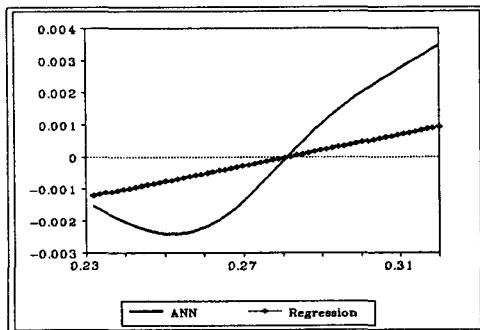
주가수익률과 예측변수간 선형관계의 표현은 회귀계수를 이용해 표시할 수 있지만, 앞에서 설명한 것과 같은 구조를 가지는 ANN모형의 경우에는 하나의 수치로 관계를 나타내기는 어렵다³⁴⁾. 또, 여러 개의 연결강도를 나열하면 그 의미가 정확하게 전달되기 어렵기 때문에 두 변수의 관계를 그림으로 나타내었다.

그림을 그린 방법은 다음과 같다. 우선 앞에서의 학습과정을 통해 얻은 연결강도에 입력층의 한 처리단위 입력값만을 일정범위에서 변화시키고, 나머지 처리단위의 입력값은 모두 0³⁵⁾을 대입하여 한 입력 처리단위의 변동에 따른 출력의 변화를 구하여 그림으로 표시하였다. 이때, 각 그림에는 ANN모형에서 얻은 결과뿐만 아니라, 같은 변수에 대한 회귀계수를 표시하여 두 모형에서 인식한 관계의 형태를 비교하였다.

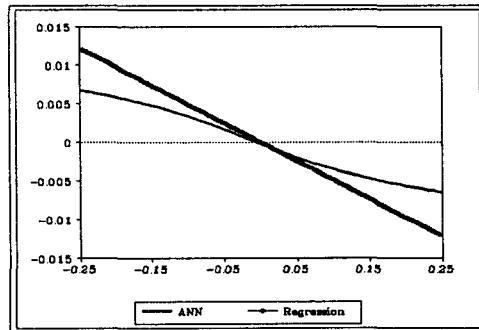
<그림 4>에는 ANN모형과 REG모형을 각각 이용하여 추정한 기간 1의 주별자료에서 주가수익률과 전기 표준편차와의 관계 및 기간 2의 주별자료에서 고객예탁금과 주가와의 관계를 나타내었다³⁶⁾.

<그림 4> 주가와 예측변수와의 관계

A : 표준편차 (주별 : 기간 1)



B : 고객예탁금 (주별 : 기간 2)



34) 예를 들어 출력층의 처리단위 수가 1개, 은닉층의 수가 1개, 은닉처리단위 수가 m 개인 경우 입력층의 한 처리단위의 변화에 의한 출력의 영향을 고려하기 위해서는 $2m$ 개의 연결강도를 고려하여야 한다.

35) 각 입력값은 평균과 표준편차로 표준화하였으므로 이 경우 0은 평균의 의미를 갖는다.

36) 다른 기간, 다른 변수의 경우에도 이와 유사한 형태를 나타냈으며 그림으로 표시하는 것은 생략하였다.

두 그림에서 보는 것과 같이 회귀계수와 ANN모형을 이용해 구한 관계는 추세적으로는 매우 유사하다. 즉, 두 모형이 인식한 주가수익률과 예측변수와의 관계는 추세적으로 일치해 REG모형과 ANN모형이 제공하는 정보의 내용은 본질적으로 다르지 않는 것으로 보인다. 그러나 ANN모형을 통해 두 변수간의 관계가 민감한 부분과 그렇지 않은 부분에 대한 조정이 가능하였고, 이러한 성질에 의해 예측의 정확성과 투자성과가 우월하게 나타난 것으로 보인다.

VI. 결론

이상으로 ANN모형을 이용하여 주가의 특이패턴을 고려하는 것이 기존의 선형모형을 사용하는 것보다 더 나은 예측정보를 얻을 수 있는지를 예측의 정확성뿐만 아니라 예측정보에 기초한 투자수익의 크기에 대해 검증하였다.

우선 본 연구의 검증 대부분에서 모형의 예측력 기준으로 사용된 정확성과 경제적 이익의 크기 두가지 측면에서 ANN모형이 REG모형보다 우월한 성과를 제공하는 것을 발견할 수 있었다. 특히 ANN모형의 예측값이 주가수익률 수준을 나타내지는 못했다 하더라도 실제주가 패턴과 상당히 유사한 모습을 띠고 있는 경우도 관찰할 수 있다.

이러한 결과는 선형모형이 인식하지 못하는 패턴이 주가의 움직임에 나타날 수 있으며, ANN모형을 이용한 패턴의 인식이 주가예측에서 의미를 가질 수 있다는 가능성을 보이는 결과이다. ANN모형이 인식하는 전반적인 패턴은 기존의 선형모형의 경우와 유사하지만 현실적 거래과정에서 나타나는 예측변수의 변화에 대한 주가움직임이 민감한 부분과 그렇지 않은 부분에 대한 조정이 가능하고, 이로인해 더 낳은 예측이 이루어질 수 있는 것으로 보인다. 그러나 본 연구는 ANN의 사용이 더 낳은 예측정보를 제공할 수 있다는 가능성을 보인 것으로 이러한 결론을 보다 일반화시키기 위해서는 보다 다양한 기간 및 수익률에 모형을 적용하기 위한 노력이 요구된다.

또한 다음과 같은 점에 대한 인식 역시 요구된다. 첫째, 이 논문의 결과는 주별 및 월별수준에서의 검증이다. 규제나 제도 등에 의한 패턴의 가능성은 일별 또는 일중의 미시구조 자료에서 더 크게 나타날 수 있기 때문에 만일 일별이나 일중의 수익률을 고려한다면 보다 유의한 결과가 나타날 수도 있었을 것이다.

둘째, 우리나라의 경제자료의 공시가 1980년대 초반에 아직 체계를 잡지 못하였기 때문에 다양한 변수를 검토하지 못하였다. 특히 이자율을 사용하기에는 어려움이 있

었는데, 무위험수익률에 대한 체계적인 자료가 존재한다면 위험프리미엄에 대한 예측이 가능하다.

셋째, ANN모형의 학습능력은 대부분의 패턴을 인식할 수 있지만 정확한 관계의 표현은 아니다. 또한 학습자료를 충분히 확보하지 못하거나, 기존의 선형에 바탕을 둔 설명이 이미 주가의 움직임을 충분히 설명할 수 있는 경우 ANN모형의 사용이 의미를 가지지 못해 사용에 주의가 필요하다. 그리고 보다 효과적인 예측이 이루어지기 위해 추가적인 모형 개발 및 다양한 변수에 대한 연구가 계속 이루어져야 할 것이다.

<부 록>

A-1. 교차상관분석 결과

표에서 보는 것과 같이, 월별에서는 전기의 생산자물가지수, 전월 수익률의 표준편차, 과거 -3, -2, -1의 환율이 현재 주가의 움직임과 유의한 관련을 가지는 것으로 나타났다. 그러나 고객예탁금은 주가에 후행하는 것으로 나타났다.

주별자료의 기간 1에서는 다른 변수의 움직임이 주가의 움직임을 선도한다기보다는 주가의 움직임이 다른변수의 움직임에 앞서는 것으로 나타났다. 기간 2에서도 이와 유사한 패턴이 발견되기는 하지만 수익률의 표준편차가 주가의 선행변수로 사용될 가능성이 보인다.

<표 A-1> 월별수익률과 선정된 설명변수간의 교차분석

변수	Lag -5 Lag 1	Lag -4 Lag 2	Lag -3 Lag 3	Lag -2 Lag 4	Lag -1 Lag 5	Lag 0
CONIX	-0.0491 0.1391	0.1609* 0.1364	0.0822 0.1249	0.0413 -0.0198	-0.0005 -0.1188	-0.0475
PPI	-0.0523 -0.1568*	-0.1405 -0.1188	-0.1035 -0.0843	0.0329 0.0410	-0.0711 -0.0461	-0.0832
FX	-0.0947 -0.2477***	-0.1676* -0.1999**	-0.0983 -0.2803***	-0.1170 -0.1640*	-0.1859** -0.0103	-0.2207**
DEPOSIT	0.0831 0.0663	-0.0334 -0.1196	-0.1137 0.0332	-0.0123 0.0598	0.3515*** 0.1513	0.2676***
STD	0.0203 0.2035**	-0.0761 0.0734	-0.0102 -0.0093	-0.1437 -0.0913	-0.0485 0.1332	-0.0156

<표 A-2> 주별수익률과 선정된 설명변수간의 교차분석 (기간 1)

변수	Lag -5 Lag 1	Lag -4 Lag 2	Lag -3 Lag 3	Lag -2 Lag 4	Lag -1 Lag 5	Lag 0
CREDIT	0.0765 0.0367	0.1810** -0.0088	0.1744** -0.1434*	0.2198*** -0.1171	0.344*** 0.00242	0.0676
DEPOSIT	-0.0691 -0.0178	0.0329 -0.0148	-0.0113 0.1476*	0.1230 0.0839	0.2521*** 0.0676	0.1674**
VOL	-0.1151 0.0005	-0.0527 0.0404	-0.0236 0.0278	-0.1128 0.0316	-0.0457 -0.0001	0.5227***
STD	0.0518 0.0515	0.0112 0.0142	-0.0201 -0.0517	0.0238 0.0846	0.0354 0.0191	0.0480

<표 A-3> 주별수익률과 선정된 설명변수간의 교차분석 (기간 2)

변수	Lag -5 Lag 1	Lag -4 Lag 2	Lag -3 Lag 3	Lag -2 Lag 4	Lag -1 Lag 5	Lag 0
CREDIT	0.0253 0.1011	0.0811 -0.0547	0.1105 -0.0457	0.0590 -0.0505	0.2970*** -0.0273	0.0226
DEPOSIT	-0.0170 0.1039	0.0618 0.0534	0.1356* 0.0649	0.0048 -0.1043	0.4265*** -0.0249	0.2066***
VOL	-0.1068 -0.0102	-0.1510** 0.1022	0.0295 0.0642	-0.1818** -0.0606	0.0590 -0.0229	0.5888***
STD	-0.0586 -0.0516	-0.0021 -0.1316*	-0.0173 -0.0994	0.0416 0.1406**	-0.0666 0.1013	-0.0898

주) *** : 1% 수준 ** : 5% 수준 * : 10% 수준에서 유의적

2. VAR을 이용한 분산분해 결과

앞에서 사용한 변수를 이용하여 <식 A-1>과 같은 VAR모형을 형성하고 이때, 각 주가 이외의 변수들이 주가의 움직임을 얼마나 설명하는지를 분산분해로 표시하였다. 이때, 요한슨 공적분검증(Johanson cointegration test)을 통해 변수들간에 공적분관계가 존재하는 월별 모형에 대해서는 <식 A-1>을 변형한 오차수정모형(error correction model)을 사용하였고, 공적분관계가 나타나지 않는 주별의 기간1과 기간2에 대해서는 VAR모형을 적용하였다. 변수의 차수는 모형의 AIC, SBC, F값 등을 고려하여 3가지 모형 모두 4차까지 사용하였다.

$$Y_t = \mu + A_1 Y_{t-1} + A_2 Y_{t-2} + \cdots + A_p Y_{t-p} + e_t \quad <\text{식 A-1}>$$

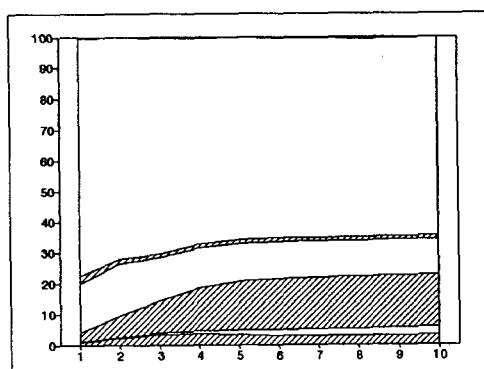
이때, Y : 변수 벡터 ($N \times 1$) μ : 상수항 벡터 ($N \times 1$)

A : 계수행렬 ($N \times N$) e : 오차항 벡터 ($N \times 1$)

N : 고려되는 변수의 수

아래에는 각 모형에서 얻은 분산분해의 결과를 그림으로 나타내었다. 월별에서는 KOSPI 움직임의 상당부분을 KOSPI 스스로가 설명하고 있으며, 시간의 흐름에 따라 환율의 설명력 증가가 눈에 띄인다. 주별에서는 기간에 관계없이 KOSPI의 움직임을 KOSPI 스스로가 약 50% 이상 설명하고 있다. 다른변수에 의한 설명력 증가는 기간1에서 고객예탁금, 기간 2에 수익률의 표준편차에 의해 이루어지고 있지만 유의하다고 보이지는 않는다.

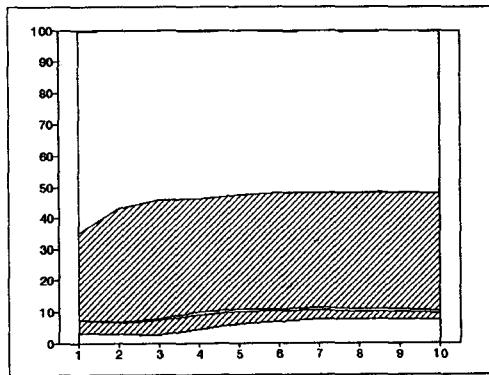
<그림 A-1> 월별 분산분해



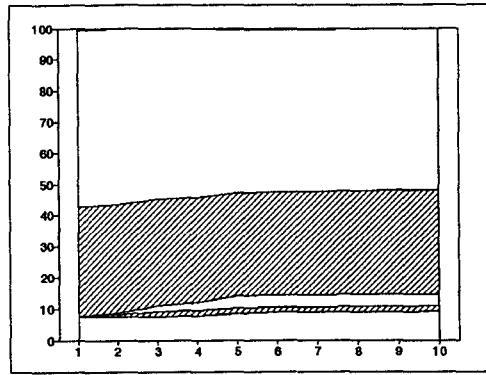
주) 아래부터 CONIX, PPI, FX, DEP, STD, KOSPI

<그림 A-2> 주별 분산분해

A : 기간 1



B : 기간 2



주) 아래부터 DEP, CRE, STD, VOL, KOSPI

참 고 문 헌

- 김진호, 신성환, “이동평균법과 신경망기법을 이용한 마켓타이밍 전략의 투자성과,” 증권학회지 19집, 1996, 111-143.
- 남상구, 박종호, “신용잔고가 주가지수의 예측치인가?,” 증권학회지 19집, 1996, 27-52.
- 박종엽, 한인구, “인공신경망을 이용한 한국종합주가지수 예측,” 한국전문가시스템학회 95 추계학술대회, 1995, 359-371.
- 신성환, “인공신경망모형과 이동평균법의 환율예측력 비교,” 금융연구 9권 1호, 한국금융연구원, 1995, 103-135.
- 이일균, “주가의 비선형성과 시계열적 특성,” 재무관리논총 3권 1호, 한국재무관리학회, 1996, 1-34.
- 장하성, “고객예탁금과 주가의 인과관계,” 재무연구 8호, 1994, 125-159.
- 한재민, 성시중, “백프로퍼게이션모형을 이용한 종합주가지수예측,” 한국전문가시스템학회 95 추계학술대회, 1995, 345-357.
- Black, F., "Noise," *Journal of Finance*, 41(3), 1986, 529-544.
- Breen, W., L. R. Glosten, and R. Jagannathan, "Economic Significance of Predictable Variance in Stock Index Returns," *Journal of Finance* 44(5), 1989, 1177 -1217.
- Campbell, J. Y., and R. Shiller, "The Dividend-Price Ratio and Expectation of Future Dividend and Discount Factors," *Review of Financial Studies* 1, 1988, 661-676.
- Bailey, W., and P. Chung, "Exchange Rate Fluctuation, Political Risk, and Stock Returns: Some Evidence from an Emerging Market," *Journal of Financial and Quantitative Analysis* 30(4), 1995, 541-561.
- Davis, J. L., "The Cross-Section of Realized Stock Returns: The Pre-COMPUSTAT Evidence," *Journal of Finance* 49(5), 1994, 1579-1593.
- Fama, E. F., "Inflation, Output, and Money," *Journal of Business* 55(2), 1982, 201 -232.
- Fama, E. F., "Stock Returns, Real Activity, Inflation and Money," *American Economic Review* 71, 1981, 545-323.
- Fama, E. F., and K. R. French, "Dividend Yield and Expected Stock Returns," *Journal of Financial Economics* 22, 1988, 3-25.
- Fama, E. F., and K. R. French, "The Cross-Section of Expected Stock Returns," *Journal of Finance* 47(2), 1992, 427-465.

- Fama, E. F., and M. H. Miller, *The Theory of Finance*, Dryden Press, 1976.
- Fama, E. F., and W. Schwert, "Asset Returns and Inflation," *Journal of Financial Economics* 5, 1977, 115-146.
- Fama, F. E., *Foundations of Finance*, Basic Book, 1976.
- Fisher, L., "Some New Stock Market Indexes," *Journal of Business* 39, 1966, 191 -225.
- French, K. R., and R. Roll, "Stock Return Variances: The Arrival of Informations and the Reactions of Traders," *Journal of Financial Economics* 17, 1988, 5-26.
- Geske, R., and R. Roll, "Monetary and Fiscial Linkage between Stock Returns and Inflation," *Journal of Finance* 38, 1983, 1-33.
- Grudnitski, G., and L. Osburn, "Forecasting S&P and Gold Futures Prices: An Application of Neural Networks," *Journal of Futures Markets* 13(6), 1993, 631 -643.
- Huang, R. D., and H. R. Stoll, "Market Microstructure and Stock Return Predictions," *Review of Financial Studies* 7(1), 1994, 179-213.
- James, C., S. Koresha, and M. Partch, "VARMA Analysis of the Causal Relatios among Stock Rerurn, Real Output, and Nominal Interest Rate," *Journal of Finance* 41, 1985, 1375-1384.
- Jenning, R. H., L. T. Stark and J. C. Fellingham, "An Equilibrium Model of Asset Trading with Sequential Information Arrival," *Journal of Finance* 36(1), 1981, 143- 161.
- Karpoff, J. M., "The Relation between Price Changes and Trading Volume; A Survey," *Journal of Financial and Quantitative Analysis* 22(1), 1987, 109-126.
- Kryzanowski, L. G., M. Wright and W. David, "Using Artificial Neural Networks to Pick Stocks," *Financial Analysts Journal* 49(4), 1993, 21-27.
- Lee, B. S., "Causal Relation among Stock Returns, Interest Rates, Real Activity, and Inflation," *Journal of Finance* 47(4), 1992, 1591-1603.
- Lippmann, R. P., "An Introduction to Computing with Neural Nets," *IEEE*, 1987, 36-52.
- Nelson, C. R., "Inflation and Rate of Return on Common Stock," *Journal of Finance* 31(2), 1976, 471-483.
- Nelson, C. R., and M. J. Kim, "Predictable Stock Returns: The Role of Small Sample Bias," *Journal of Finance* 48(2), 1993, 641-662.
- Rao, V. B., and H. V. Rao, *C++ Neural Networks and Fuzzy Logic*, Management

398 인공신경망모형을 이용한 주가의 예측가능성에 관한 연구

Information Source Inc., New York, 1993.

Shiller, R. J., "Theories of Aggregate Stock Price Movements," *Journal of Portfolio Management* 10(2), 1984, 28-37.

ABSTRACT

Most of the studies on stock price predictability using the linear model conclude that there are little possibility to predict the future price movement. But some anomalous patterns may be generated by remaining market inefficiency or regulation, market system that is facilitated to prevent the market failure. And these anomalous pattern, if exist, make them difficult to predict the stock price movement with linear model.

In this study, I try to find the anomalous pattern using the ANN model. And by comparing the predictability of ANN model with the predictability of correspondent linear model, I want to show the importance of recognitions of anomalous pattern in stock price prediction.

I find that ANN model could have the superior performance measured with the accuracy of prediction and investment return to correspondent linear model. This result means that there may exist the anomalous pattern that can't be recognized with linear model, and it is necessary to consider the anomalous pattern to make superior prediction performance.