

우리나라 증권시장과 거시경제변수： ANN와 VECM의 설명력 비교

정성창* · Timothy H. Lee**

〈요 약〉

본 연구의 목적은 VECM(Vector Error Correction Model)과 인공지능 모형(Artificial Neural Networks)을 이용하여 우리나라 증권시장과 거시경제 변수들과의 장기적 관계에 대한 설명력을 비교해보고자 함에 있다. VECM이 APT(Arbitrage Pricing Theory)에 기초를 둔 선형동학 모형이라고 한다면, 인공지능 모형은 비모수적 비선형모형이라는 점에서, 두 방법론의 분석결과를 직접 비교하는 것은 의미있는 연구라고 할 수 있다. 인공지능모형을 주로 활용하는 선행연구들에 의하면, 증권시장은 시장의 특이패턴들로 인해 계량경제학적 접근인 선형 모형보다는 인공지능 모형을 통해 증권시장의 움직임을 설명하고 예측하는 것이 더 바람직할 수도 있다는 것이다. 따라서, 본 연구에서는 VECM분석에서 자료의 안정성을 검증하고, 공적분 벡터를 발견한 이후, 장기적 균형관계의 실증적 분석을 하였다. 그리고, 인공지능 모형에서는 delta rule과 Sigmoid 함수를 이용한 GRNN(General Regression Neural Net)과 Back-Propagation등의 방법들을 활용하였다. 이러한 분석결과, Back-Propagation 모형이 다른 모든 모형들보다도 더 우수한 설명력을 보여주고 있었다. 이러한 결과들은 인공지능모형이 동태적인 선형 모형보다도 더 우수한 설명력을 제공할 수 있는 가능성을 보여주고 있었다.

I. 서 론

증권시장과 거시경제 변수들간의 이론적 및 실증적 관계에 대한 연구는 재무경제학 분야에서 다양한 시각에서 끊임없이 논의되어 오고 있다. 이론적으로는 Fama(1970, 1981)와 Chen(1991)이 다기간 경제 모형에서 실질 경제활동은 소비와 투자기회 집합에 영향을 주게되고, 이러한 변화들이 증권시장에서 가격으로 평가되어지므로, 결과적으로 경제 상황변수들의 변화는 주가와 밀접한 관계를 갖고 있음을 체계적으로 보여 주었다. 또 한

* 전남대학교 경영대학

** Equifax Knowledge Engineering, Vice President

*** 본 연구는 2000년도 전남대학교 경영대학 연구기금의 지원을 받아 수행되었으며, 본 논문의 작성에 유익한 조언을 하여주신 익명의 심사위원들께 감사드립니다.

편으로는 Ross(1976)에 의해 APT(Arbitrage Pricing Theory)가 제시되면서부터 Chen, Roll and Ross(1986)는 가치평가모형을 기초로 주식가격에 영향을 미치는 주요한 경제적 상황요인들을 식별하여 검증함으로써, 주식 가격과 거시 경제 변수들간의 실증적 분석에 대한 종합적 접근이 시작되었다.

Chen, Roll and Ross(1986)의 실증적 분석이 제시된 이후, 주가와 거시경제 변수들간의 관계에 대한 분석은 계량경제학의 발달과 더불어 더욱 정교한 방법론들을 활용하기 시작하였다. 전통적인 방법들이었던 다중 회귀분석으로부터, VAR(Vector Auto Regression Model), 그리고 공적분 분석을 포함한 VECM(Vector Error Correction Model) 등을 주로 이용하여 왔다. 미국의 경우, Lee(1992), Campell and Ammer(1993), 그리고, Thorbecke(1977)등의 연구가 VAR 모형을 사용한 대표적인 연구들이다. 경우에 따라서는, 개별 거시경제 변수들과 주식가격과의 관계에 대해서도 심도있는 분석이 진행되어 왔다. Fama and Schwert(1997), Geske and Roll(1983), Defina(1991) 등의 연구에서는 인플레이션과 주가와의 관계를 분석하였으며, Jones and Kaul(1996)의 연구에서는 국제 원유가격과 주식가격과의 관련성을 검증하였다. 그리고, Chopra and Lin(1996)의 연구에서는 거시경제 변수를 이용하여 주가예측에 활용하는 방법론들을 정리하여 주목할 만하다.

거시경제 변수들과 증권시장의 관계에 대한 국내의 선행연구도 연구방법론에 따라 다양한 방법론들을 사용하여 연구되어 왔다. 첫째, 다중 회귀분석모형을 이용한 김철교, 박정옥, 백용호(1990), 정기웅(1991), 김형규(1991)등의 연구와 연립 회귀방정식을 이용한 이준행(1994)의 연구들이다. 다중회귀분석과 연립방정식을 이용한 연구들은 거시 경제 변수들과 주가지수의 관계는 보여줄 수 있지만 주가지수의 동태적인 측면을 무시하기 쉽다는 한계점을 갖고 있다. 둘째는 ARMAX(Autoregressive Moving Average with Exogenous Variables) 모형과 VAR(Vector Autoregressive Model) 모형이 있다. ARMAX 모형(권영준, 김성태, 이홍파 신기철, 1990)은 주가지수는 ARMA 과정으로 하고 주가지수에 영향을 미치는 경제 변수들은 외생 변수로 간주하는 모형으로서 매우 유익하나, 이 모형은 거시경제 변수들이 상호 관련되어 내생 변수로 작용할 수 있다는 것을 고려할 수 없다. VAR 모형(이상재, 1993 ; 김종권, 1999)은 고려하는 모든 변수들을 내생변수로 간주하고 변수들의 정태적 및 동태적인 상호관계를 분석하기 때문에 적합한 모형이라고 할 수 있다. 그러나, VAR 모형은 시계열의 안정성을 위한 변수들의 차분 과정에서 시계열 본래의 고유정보를 상실한다는 문제점을 갖고 있으며, 장기적 균형관계를 보여주지 못하는 한계점을 갖고 있는 것으로 밝혀지고 있다.

VECM(Vector Error Correction Model)은 이러한 VAR 모형들의 문제점을 개선할 수 있는 방법이라고 할 수 있다. 일반적으로 종합주가지수를 포함한 대부분의 거시경제 변수들의 시계열은 안정성(Stationarity)을 갖고 있지 않는 것으로 밝혀지고 있으며, 이러한 불안정적인 시계열의 경우 공적분의 관계를 갖게 된다면 시계열변수들간의 장기적 균형 관계와 단기적 동태적 관계를 검증할 수 있는 모형이 VECM이다. 공적분 검증은 단일 변수 시계열의 경우 Engle and Granger(1987)의 방법이 사용되나 다변량 시계열의 경우 Johansen(1988, 1991)의 다변량 공적분 검증 방법이 더 우수한 것으로 보고되고 있다. 정성창(2000)의 연구는 VECM을 이용하여 증권시장과 거시경제 변수들간의 장기적 관계를 규명한 국내 최초의 연구로서 주목할 만하다.

한편, 최근들어 인공지능모형을 이용한 증권시장과 거시경제 변수들간의 관계규명이 새로운 연구주제로 등장하고 있다. Hamid(1996), Wong, Wang, Goh and Quek(1992), Episcopes and Davis(1996), Grudnitski and Osburn(1993), Kaastra and Boyd(1995), Peterson and Peterson(1996) 등의 연구에서는 주식가격 예측모형으로서 인공지능모형을 사용하였다. 그들의 연구결과, 대부분의 경우 인공지능을 이용한 주가예측 모형이 종래에 사용하여 왔던 계량경제적인 모형들보다 설명력이 더욱 우수한 것으로 나타나고 있다.

국내에서도 인공지능모형을 이용하여 증권시장을 설명한 연구로는 이건창, 김원철(1997)과 정용관, 윤영섭(1998) 등의 연구가 있다. 이건창과 김원철(1997)의 연구에서는 기계자식에 의한 추론과 전문가 지식에 의한 추론을 결합한 퍼지논리지원 지식결합 메커니즘을 제시하고, 이러한 결합메카니즘이 각각의 전문가시스템보다 더 유용한 결과를 가져다주고 있음을 보이고 있다. 정용관, 윤영섭(1998)의 연구에서는 계량경제학적인 모형들과 인공지능모형을 비교한 국내 최초의 연구로서 매우 의미있는 연구라 할 수 있다. 이들은 증권시장의 특이패턴들로 인해 선형모형으로서는 주가움직임을 추정하기 어려운 점들이 많기 때문에, 인공지능모형을 통해 주가움직임을 예측해보고 각 모형들의 예측력을 비교해보아야 한다고 주장한다. 분석결과, 인공지능모형은 다중회귀분석 모형보다 우월한 성과를 제공하는 것으로 나타났다.

증권시장과 거시경제 변수들의 체계적 관계에 대하여 계량경제학적으로는 VAR의 한 계점을 개선한 VECM이 활용되어 장기적 균형관계에 대하여 분석되었으며, 다른 한편으로는 인공지능모형들이 별도로 증권시장과 관련되어 적극 활용되어 왔다. 정성창(2000)의 연구에서 VECM이 VAR보다 더 우월한 설명력을 보여주고 있다는 점을 고려할 때, 인공지능모형의 설명력은 VECM과 비교되어야 한다. 그러나, 지금까지의 선행연구에서는 다중회귀분석모형과 인공지능모형을 비교함에 그치는 한계점을 보이고 있다.

이 점이 본 연구를 실시하게 된 배경이다. 따라서, 본 연구의 목적은 VECM과 인공지능 모형을 이용하여 우리나라 증권시장과 거시경제 변수들과의 장기적 관계를 규명하며, 두 모형들의 설명력을 비교하고자 함에 있다. VECM이 재무론의 APT에 기초를 둔 선형동학모형이라고 한다면, 인공지능모형은 예측모형으로서 비모수적 비선형모형이라는 점에서, 두 방법론의 분석결과를 직접 비교하는 것은 매우 의미있는 연구라고 할 수 있다. VECM분석에서는 자료의 안정성 검증, 공적분 벡터의 발견, 장기적 균형관계의 실증적 분석을 하게 되며, 인공지능모형에서는 delta rule과 Sigmoid 함수를 이용한 GRNN (General Regression Neural Net)과 Back-Propagation등의 방법들이 활용된다.

II. VECM과 인공지능모형

1. 공적분검증과 VECM

1) 단위근 검증

시계열자료가 불안정적(non-stationary)일 경우 가성회귀(spurious regression) 현상이 발견될 수 있기 때문에, 맨먼저 모든 시계열 자료들의 안정성을 판단하는 단위근 검증(unit root test)이 실시된다. 단위근의 존재를 검증하는 전통적인 방법은 Dickey와 Fuller에서 사용된 ADF(Augmented Dickey-Fuller) 검정법이며, ADF 검정법은 다음과 같이 표시된다.

$$\Delta x_t = \alpha + \beta T + \rho x_{t-1} + \sum_{i=1}^m \lambda_i \Delta x_{t-i} + \varepsilon_t \quad (1)$$

단, x_t	= t 시점에서 각 변수들의 값
T	= 시간추세
Δx_{t-1}	= $x_{t-1} - x_{t-2}$
ε_t	= 평균 0이고 분산이 σ^2 인 i.i.d. 오차항
$\alpha, \beta, \rho, \lambda$	= 계수들

단위근 검증에서 검증하고자 하는 귀무가설은 $H_0 : \rho = 0$ (단위근이 존재한다)이다. 만약 모든 시계열자료가 단위근을 갖고 있다는 귀무가설을 기각한다면, 시계열자료가 안정적이라고 할 수 있으므로 VAR 모형이 직접 이용될 수 있다. 그러나, 만약 검증 결과 귀무가설을 기각하지 못하면, 시계열자료가 불안정하다는 의미가 되므로 불안정한 시계

열 자료를 차분을 통해 안정화시키거나, 혹은 공적분 관계를 검토하여야 한다. 동일한 자료에 대하여 Phillips-Perron의 단위근 검증도 실시하고자 한다.

2) Johansen의 다변량 공적분 검증과 VECM

단위근 검증 결과 시계열자료가 불안정적일 경우에는 두 가지의 접근법이 존재한다. 첫째는 연속적인 차분 과정을 거쳐 안정적 시계열을 도출한 다음 회귀분석을 수행하는 과정이다. 본 연구의 경우 주가와 거시경제 변수들간의 다변량적 관계를 체계적으로 정리하는 특정한 이론이 존재하지 않고, 본 연구의 목적이 여러 경제 변수들의 정태적 및 동태적인 상호관계를 분석하고자 함에 있으므로, 벡터자기회귀모형(Vector Autoregressive Model ; VAR)이 가장 적절한 모형이라고 할 수 있다. 그러나 이러한 차분된 시계열을 이용하는 것은 시계열의 고유한 잠재 정보를 상실시키므로 동태적이고 안정적인 장기 균형을 도출할 수 없게 된다는 한계점을 갖고 있다. 둘째는 첫 번째의 한계점을 극복하는 방안으로서 공적분(Cointegration) 관계 여부를 검토한 후에 공적분이 존재한다면 벡터오차수정모형(Vector Error Correction Model ; VECM)을 이용하는 것이다. Engle과 Granger(1987)에 따르면, 공적분이 존재할 경우 1차 차분된 변수로 구성되는 VAR 모형은 모형설정의 오류를 범하게 되므로, 이 경우 공적분에서 얻어지는 오차항을 이용하는 새로운 VAR 모형, 즉 벡터오차수정모형을 구성하여야 한다. 따라서, 본 연구에서는 시계열의 불안전성이 발견되고 다변량공적분이 발견되면 벡터오차수정모형을 이용하고자 한다.

공적분의 검증 방법은 단일변수 시계열자료의 경우 Engle과 Granger(1987)의 방법이 일반적으로 사용되나, 본 연구의 경우처럼 다변량 시계열 자료인 경우에는 Johansen(1991)의 다변량공적분 검정 방법(Johansen, 1988 ; Johansen, 1991 ; Johansen and Juselius, 1990)이 다른 방법들보다 더 우월한 것으로 알려져 있으므로 Johansen의 다변량공적분 검정 방법을 사용하고자 한다. 이러한 이유로 Mukherjee and Naka(1995), Mookherjee and Yu(1997), 그리고 Cheung and Ng(1998)의 연구들에서 Johansen(1991) 공적분 분석을 활용하고 있다. 벡터오차수정모형의 구조 속에서 공적분 벡터의 모수가 추정되므로 VAR로부터 도출된 벡터오차수정모형을 나타내면 다음과 같다.

$$\Delta X_t = \mu - \Pi X_{t-k} + \sum_{j=1}^{k-1} j \Delta X_{t-j} + \varepsilon_t \quad (2)$$

여기에서, Δ 는 1차 차분을 나타내고, μ 는 상수항 벡터, k 는 시차구조, 그리고 ε_t 는

가우시안 백색잔차 벡터이다. 또한, $\Gamma_j = -I + \Pi_1 + \Pi_2 + \dots + \Pi_j$, $j = 1, 2, \dots, k$, 즉, Γ_j 는 (pxp) 행렬로서 j 번째 시차에서 p 개 수식들 간의 단기조정을 나타내는 변수들이다. 단, p 는 모형에서 고려하는 변수의 수를 의미한다. 그리고 $\Pi = -I + \Pi_1 + \Pi_2 + \dots + \Pi_k$, 즉, 계수행렬 Π 는 p 개의 변수들간의 장기적 균형관계에 관한 정보를 보유하고 있다.

Johansen의 다변량공적분 검증이란 모형에서 고려하는 변수들 사이에 존재하는 공적분 벡터의 수, Π 의 계수(rank)의 수에 의하여 결정된다. 만약 Π 의 계수가 $r \leq (p-1)$ 이면, 변수들간에 r 개의 공적분 벡터가 존재한다고 할 수 있다. 만약 행렬 Π 가 full 랭크를 가지고 있다면, p 개의 변수벡터들은 정상적인 시계열이라는 것을 의미하며, 차분없이 VAR 모형을 사용하여야 한다. 반면, 행렬 Π 가 null행렬이라면, 수준변수들간의 장기적 균형관계가 존재하지 않는다는 것을 의미하며, 이 경우에는 1차 차분한 변수들을 이용한 VAR 모형이 사용되어야 한다. 만약 행렬 Π 의 랭크가 1과 p 의 사이에 있는 어떤 r 이라면, 이것은 $\Pi = a\beta'$ 가 되도록 하는 (pxr) 행렬의 a 와 β 가 존재한다는 것을 의미한다. 단, 여기에서 a 는 조정계수이고 β 는 공적분 벡터이다. 이러한 경우에 p 개의 변수를 나타내는 벡터인 X_t 는 비정상적이라고 할지라도 $\beta'X_t$ 는 정상적(stationary)이 된다. 공적분 벡터의 수를 결정하기 위하여 Johansen(1991)은 Trace통계량과 Maximum Eigenvalue 통계량을 제시하고 있다.

2. 인공지능모형(Artificial Neural Network)

인공지능모형이란 인간의 두뇌와 신경세포(neuron)들간의 연결관계에 착안하여, 이러한 연결관계(network)를 컴퓨터의 프로그램에 의해 모델링화한 것이다. 즉, 인간 지능의 부분적인 기능을 컴퓨터의 알고리즘으로 실현해보자 한 방법론으로서, 전기, 전자, 컴퓨터, 기계공학자들을 중심으로 신경회로망(neural network)의 기능과 구조를 하드웨어적, 소프트웨어적 방법으로 실현하고 활용하는 영역이다. 인공지능모형에는 크게 나누어 지도학습(supervised learning) 모형과 비지도학습(unsupervised learning) 모형으로 구별된다¹⁾.

본 연구에서는 지도학습모형 중에서 주가예측모형에 적용하기에 가장 적합한 General Regression Neural Net(GRNN) 모형과 Back-Propagation 방법을 활용하고자 한다. GRNN은 본 연구의 목적이 어떤 자료를 집단별로 분류(classification)하기보다는 예측을 하고자 함에 있고, GRNN이 Probabilistic Net Work의 일반화된 모형이기 때문이다.

1) 인공지능모형에 대한 자세한 내용은 도용태, 김일곤, 김종환, 박창현(1997)을 참조 바람.

그리고 Back-Propagation은 입력변수와 출력변수가 모두 연속변수들이며, 여러 개의 입력변수와 한 개의 출력변수로 구성되어 있는 경우 출력변수와 입력변수들간에 비선형변환함수를 설정하는데 가장 적절한 모형이라고 알려져 있기 때문이다.

1) GRNN

GRNN은 독립변수들로서 확률변수벡터 X 의 측정치들이 주어져 있을 때, 종속변수로서 Y 의 조건부 평균값을 계산하기 위한 표준적인 통계적 모형이다. 조건부 평균이란 독립변수벡터가 주어져 있을 때 확률변수 Y 가 통계적으로 가장 가능한 값을 의미하는 바, 조건부 평균값을 계산하기 위해서는 독립변수와 종속변수들의 결합확률분포에 관한 정보가 요구된다. GRNN에서는 이러한 결합확률분포가 Parzen 추정방식을 이용한 training vector들로부터 추정된다.

2) Back-Propagation

전형적인 Back-Propagation은 항상 1개의 입력층과 1개의 출력층, 그리고 최소한 1개 이상의 은닉층을 갖는 네트워크로서, 각 층은 다음 층들과 완전하게 연결되어 있다. Back-Propagation 알고리즘에서는 학습과정에서 입력과 연결강도를 이용하여 구한 출력값과 목표값의 차이인 오차를 하위 처리단위로 되돌려 보냄(역전파 : back-propagate)으로써 오차를 감소시키는 방향으로 연결강도를 조정하며, 이와 같은 연결강도의 조정을 오차의 크기를 인정할 수 있을 때까지 반복함으로써 학습이 이루어진다.

III. 실증분석 결과

1. 변수의 선정 및 자료

본 연구에서 선택한 거시경제 변수들은 Chen, Roll and Ross(1986)의 기본적인 가치평가 모형에 기초를 두고, 국내외 선행연구(Mukherjee and Naka, 1995 ; Mookerjee and Yu, 1997 ; Cheung and Ng, 1998 ; 정성창, 2000)들의 연구 결과들을 고려하여 금융부문, 실물 혹은 생산부문, 해외부분으로 나누어 부문별로 주요 변수들을 선정하였다²⁾. 본 연구에서는 정성창(2000)의 연구와 동일한 변수를 사용하였다. 즉, 주식가격을 나타내는 변수로는 월평균 종합주가지수(KOSPI)를 사용하였으며, 거시경제 변수들로는 단기금리

2) 이 부분에 대한 자세한 논의는 정성창(2000)을 참조하시오.

(CALL), 장기금리(CBY), 인플레이션(CPI), 화폐공급(RM2), 산업생산지수(IP), 국제오일가격(OIL), 경상수지잔액(TB), 원달러환율(WS), 그리고 원엔환율(WY)을 선택하였다.

먼저 금융부문에서 장기이자율을 나타내는 변수로서 3년 만기 회사채 유통수익률(CBY ; 월평균, %)을 선택하였으며, 단기이자율을 나타내는 변수로서 콜금리(CALL ; 월평균, %)를 사용하였다. Chen, Roll and Ross(1986)의 연구에서 주식가격에 영향을 미치는 이자율 관련 변수들로서 채무불이행 위험프리미엄과 기간위험프리미엄 변수 등을 활용하였으나, 우리나라의 경우에는 미국의 T-Bond와 T-Bill과 같은 장·단기국채, 그리고 투기적 등급의 채권 시장 등이 발달하지 않은 관계로 이러한 변수의 사용이 거의 불가능하다. 따라서, 우리나라에서 가장 대표적인 금리라고 할 수 있는 3년 만기 회사채 유통수익률과 콜금리를 금리변수로 활용하였다. 그리고, 주식가격과 금리와는 역의 관계가 성립할 것으로 가정한다³⁾.

금융부문에서 인플레이션을 측정하기 위하여 사용한 변수는 소비자물가지수(CPI)와 통화공급량(RM2)이다. 소비자물가지수는 1990년의 소비자 물가지수를 100으로 하여 계산된 것이며, 통화공급량은 10억원 단위로 표시된 실질 통화공급량의 평균잔액이다. 주식평가 모형에 의하면, 다른 모든 요인들이 일정하고 물가가 상승하면 투자자들은 구매력 상실을 보상받기 위하여 더 높은 위험조정할인율을 요구하게 되며, 결국 주식가격은 하락하게 된다. 즉, 물가와 주식가격과의 관계는 부(-)의 관계를 갖는다는 것이다. 한편, 물가 상승으로 기업의 명목현금흐름이 인플레이션과 동일한 비율로 증가한다면 주식평가 모형의 기대현금흐름의 크기가 증가하게 되어, 결국 주식은 인플레이션의 헛지수단이 될 수 있다. 대부분의 선진국을 대상으로 한 선행 실증연구들에서는 안정적이고 낮은 수준의 인플레이션은 실물분야에서의 경제성장을 도와서 주가와 정(+)의 관계를 갖게 될 것으로 기대된다. 그러나, 대부분의 선행연구(Fama and Schwert, 1977 ; Geske and Roll, 1983 ; Chen, Roll and Ross, 1986 ; Chen, 1991 ; DeFina, 1991)들은 주식이 인플레이션의 헛지 수단이 되지 못하여 물가와 부(-)의 관계를 갖고 있음을 보고하고 있다.

통화량이 주가에 미치는 영향에 관해서는 기간에 따라 달라지는 것으로 보고되고 있다. 단기적으로는 통화량이 증가하면 이자율이 하락하여 위험조정할인율이 감소하고, 투자의 증대로 승수 효과에 의한 기대현금흐름이 증가되어 주식가격은 상승하게 된다. 반면, 장기적으로는 통화량이 증가하면 인플레이션과 이자율이 상승하여 위험조정수익률이 상승하게 되고, 결국 주식가격을 하락시키는 결과를 가져온다고 주장한다. 즉, 통화량

3) 자세한 내용은 James, Koreisha and Partch(1985)을 참조할 수 있다. 이들의 연구에서는 미국 시장을 대상으로 주식가격과 명목이자율간의 시계열 상관분석을 실시하였다.

과 주가는 견해에 따라 정(+) 혹은 부(-)의 관계를 가질 수 있음을 의미한다.

실물부문에서 실물경기수준을 나타내는 변수로서 산업생산지수(Industrial Production ; IP)와 국제원유가격(OIL)를 사용한다. Fama(1990)와 Geske and Roll(1983) 등의 연구에서 보인 것처럼, 경기가 활황(불황)을 보이면 기업들의 생산 활동이 활발(위축)해지므로 기업 수익의 증가(감소)와 함께 주가는 상승(하락)하게 된다. 그리고 Jones and Kaul(1996)의 분석에서 제시된 것처럼, 우리나라는 원유 순수입 국가이므로 경제성과는 국제원유가격과 부의 관계가 있을 것으로 기대된다⁴⁾. 우리나라의 경우 오일수입량은 1980년대 총수입금액의 약 30% 정도, 1990년도에는 총 수입금액의 약 15% 정도를 차지할 정도로 오일가격이 우리 경제에서 중요한 부분을 차지하고 있다. 국제원유가격을 나타내는 변수로는 미국의 종합원유가격을 사용하였다.

마지막으로 해외부문을 나타내는 변수로서 무역수지(TB), 원달러환율(WS)과 원엔환율(WY)변수를 사용하였다. 우리나라는 경제에서 해외 부문이 차지하는 비중이 크기 때문에 해외시장 변수는 중요한 역할을 하게 된다. 환율의 절상은 수출은 줄고 수입은 늘어 경상 수지가 나빠지고 주가를 하락시키는 측면이 있으나, 다른 한편으로는 수입 물가가 떨어져 국내 물가가 하락하여 주가를 상승시키는 측면도 있다. 반면 환율의 절하는 수출은 늘고 수입은 늘어 경상수지개선으로 주가를 상승시키는 측면이 있는 반면, 다른 한편으로는 수입 물가가 상승하여 국내 물가를 상승시키게 되어 주가를 하락시키는 영향이 있을 수 있다. 따라서, 해외시장 변수와 주가와의 관계는 단정지어 설명할 수 없다. 경상수지(TB)를 나타내는 변수로는 100만 달러로 표시되는 경상수지 잔액을 이용하였다. 마지막으로 원달러환율(WS)과 원엔환율(WY)은 미국달러와 일본엔화에 대한 월말 환율을 사용하였다.

본 연구에서 사용하고 있는 자료는 1980년 1월부터 1996년 6월까지의 월별자료로서 「주식」, 한국 은행의 「조사통계월보」, 그리고 통계청자료(KOSIS)등에서 구한 것들이다⁵⁾. 원유가격은 미국에너지성에서 발간되는 월간 에너지리뷰(Monthly Energy Review)에서 발췌하였다. 모든 거시경제 변수들은 계절성이 있는 것으로 나타나 계절변동 후 자료를 사용하였으며, 모든 자료에 계절변동후 Log변환을 취하였다⁶⁾. 본 연구에서 사용한 소프트웨어는 EViews(VECM 분석용)와 SAS의 E-Miner(인공지능모형 개발용)를 사용하였다.

<표 1>은 주가와 9개 거시경제 변수들에 대한 기본통계량을 나타내고 있다. 파넬

4) 국제원유가격과 주식가격과의 관계에 관한 자세한 분석은 Jones and Kaul(1996)의 연구를 참조하시오.

5) 자료를 1996년 6월까지로 한정한 것은 본 연구의 목적이 두 방법의 설명력을 비교하고자 함에 있기 때문에 1997년에 발생한 금융위기와 그 이후의 급격한 변화기간을 배제하기 위함이다.

6) 무역수지가 (-)의 값인 경우는 절대값을 취한 후 Log변환을 하고, 다시 (-1) 값을 곱하여 사용하였다.

<표 1> 기본 통계량

	KOSPI	CALL	CBY	CPI	IP	M2	OIL	TB	WS	WY
파넬 A : 수준형태로의 자료										
평균	488.81	13.12	16.12	93.21	84.55	56237	22.04	-36.79	762.11	511.66
중위수	541.00	12.49	14.45	86.40	86.20	40464	19.08	-87.80	774.90	526.31
표준편차	330.61	3.65	4.74	24.65	38.19	41613	6.81	539.13	70.49	176.39
최대값	1110.5	24.80	32.20	142.30	166.30	156492	37.48	1764.1	892.20	904.21
최소값	101.70	8.30	10.97	47.80	30.10	9922.3	11.26	-1512	580	233.91
파넬 B : 자연대수를 취한 자료										
평균	5.87	2.54	2.75	4.50	4.33	10.65	3.05	-0.033	6.63	6.175
중위수	6.30	2.51	2.67	4.45	4.45	10.61	2.95	-0.04	6.65	6.26
표준편차	0.87	0.25	0.25	0.26	0.49	0.79	0.31	0.50	0.10	0.36
최대값	7.01	3.22	3.49	4.96	5.10	11.96	3.64	1.37	6.79	6.80
최소값	4.54	2.10	2.41	3.87	3.43	9.07	2.45	-1.53	6.36	5.45
파넬 C : 1차 차분한 자료(all 10^{-2})										
평균	1.136	-0.324	-0.452	0.549	0.764	1.471	-0.119	-0.210	0.170	0.602
중위수	0.740	-0.705	-0.499	0.4401	1.0171	1.5081	-0.380	0.291	0.173	0.258
표준편차	6.137	6.897	3.894	0.651	4.599	1.850	6.387	41.18	0.846	3.311
최대값	17.31	23.10	11.63	3.661	14.50	9.014	35.26	180.12	4.20	10.78
최소값	-15.31	-21.92	-15.96	-0.458	-18.93	-5.60	-25.68	-149.6	-2.589	-8.527

A는 수준변수, 파넬 B는 수준변수에 자연대수를 취한 값을, 그리고 파넬 C는 1차 차분 변수에 대한 기본통계량을 보여주고 있다. 자료에 따르면, 우리나라의 주식가격은 지난 15년 동안 년 평균 약 13.6%의 성장률(월 평균 약 1.136%)을 나타냈으며, 산업생산은 월 평균 약 0.76% 정도로 성장했으며, 달러에 대한 원화 가치는 월평균 약 0.17%정도 절하하였다. 일본 엔화에 대한 원화 가치는 월 약 0.60%정도 절하하였다. 화폐공급량(M2)은 월 1.47%정도씩 증가하였지만, 소비자물가지수로 표현된 인플레이션은 월 평균 0.549%로 나타났다. 장·단기 이자율의 변화량은 음(-)으로 나타났으나 매우 적은 값이다. 국제원유가격과 무역수지의 크기도 매우 적은 크기로 감소하였다.

2. 공적분 분석과 VECM 결과

1) 단위근 검증

<표 2>는 수준변수와 1차 차분변수들에 대하여 4개월 시차를 갖고 ADF 단위근 검증을 실시한 결과이다. 검증결과 대부분의 자료에서 모든 변수들이 일반적으로 비정상적

<표 2> 수준변수와 1차 차분변수에 대한 ADF 단위근 검증(4개월 시차)

	수준변수 자료			1차 차분 자료		
	상수와 추세 없음	상수 포함	상수와 추세 포함	상수와 추세 없음	상수 포함	상수와 추세 포함
KOSPI	-1.5417	-0.9126	-1.3047	-5.1949***	-6.1942***	-6.1936***
CALL	-1.3334	-2.8461*	-2.5400	7.0858***	-7.1579***	-7.3409***
CBY	-1.5240	-3.0926**	-2.9007	-5.5667***	-5.7111***	-5.8217***
CPI	3.3618	-0.8323	-2.3481	-3.0021***	-4.0563***	-3.9289**
IP	5.4014	-1.0296	-1.6160	-6.8929***	-9.7847***	-9.8344***
M2	5.8661	-0.7590	-2.9560	-3.8118***	-7.9144***	-7.9396***
OIL	-0.5577	-1.8090	-2.4422	-7.4793***	-7.4761***	-7.4667***
TB	-1.8926*	-1.9013	-1.9435	-9.4280***	-9.4083***	-9.4757***
WS	0.9178	-2.5081	-2.4712	-2.8966***	-3.0003***	-2.8728
WY	1.7904	-0.9975	-2.3642	-5.4417***	-5.7500***	-5.6988***

주) *, **, 그리고 ***는 10%, 5%, 그리고 1% 수준에서 각각 유의함을 나타냄.

<표 3> 수준변수와 1차 차분변수에 대한 Phillips-Perron 단위근 검증(4개월 시차)

	수준변수자료			1차 차분자료		
	상수와 추세 없음	상수 포함	상수와 추세 포함	상수와 추세 없음	상수 포함	상수와 추세 포함
KOSPI	1.8725	-1.1244	-1.2530	-10.2161***	-10.4209***	-10.4292***
CALL	-1.0415	-2.585	-2.311	-15.057***	-15.081***	-15.200***
CBY	-1.4269	2.2200	-2.1661	-9.7139***	-9.7973***	-9.8298***
CPI	7.0512	-2.8611*	-4.2406***	-6.6491***	-9.3509***	-9.5276***
IP	4.0716	-0.6735	-3.9443**	-20.7503***	-23.9094***	-23.8372***
M2	9.6501	-1.8948	-4.9873***	-9.0669***	-12.7876***	-12.8255***
OIL	-0.3927	-2.0966	-2.8851	-6.7815***	-6.7673***	-6.7499***
TB	-6.1071***	-6.1156***	-6.1294***	-29.6424***	-29.5668***	-29.5896***
WS	1.6520	-2.9529**	-2.5370	-6.8741***	-7.1175***	-7.2857***
WY	2.1320	-1.2983	-2.2567	-11.7999***	-12.0873***	-12.0877***

주) *, **, 그리고 ***는 10%, 5%, 그리고 1% 수준에서 각각 유의함을 나타냄.

인 특성을 가지고 있으며, 모든 변수들이 I(1) 과정을 따르는 것을 발견할 수 있었다. 여기에서 시차의 결정이 실증결과에 중요한 영향을 줄 수 있다고 판단되어, 본 연구에서는 각 변수별로 Newey and West(1994)의 검증방법을 이용하여 최적의 시차를 구하였다. 그 결과, 본 연구에서 사용하는 모든 변수들은 4개월 시차가 최적임을 보여주었다⁷⁾.

동일한 자료를 이용하여 Phillips-Perron의 단위근 검증을 실시한 결과가 4개월 시차의 경우 <표 3>에 나타나 있다. 이 결과도 ADF 단위근 검증과 마찬가지로, 4개월 시차가 최적이었으며 본 연구에서 고려하는 모든 변수들은 I(1)과정을 따르는 것으로 나타났다.

2) Johansen의 다변량 공적분 검증과 VECM

공적분 검증의 결과가 <표 4>에 제시되어 있다. <표 4>에서는 시차를 4개월로 할 경우에 대한 공적분 검증결과가 Trace 통계량과 λ_{\max} 통계량과 함께 나타나 있다. Trace 통계량과 λ_{\max} 통계량에 따르면, 최소한 두 개 이상의 공적분 벡터가 존재하는 것으로 나타나고 있다. 즉, Trace 검증의 결과에 따르면, $r \leq 2$ 로 표시되는 귀무가설은 기각되고 $r > 2$ 로 해석할 수 있으며, 반면 λ_{\max} 값에 따르면 $r \leq 1$ 로 표시되는 귀무가설을 기각하여 $r = 2$ 로 해석할 수 있다⁸⁾.

<표 4> Johansen의 공적분 검증 결과(4개월 시차)

Hypothesized No. of CE(s)	Trace Statistic	λ_{\max}	Critical values			
			Trace(5%)	Trace(1%)	$\lambda_{\max}(5\%)$	$\lambda_{\max}(1\%)$
$r = 0$	303.96***	70.08***	233.13	247.18	62.81	69.09
$r \leq 1$	224.88***	61.34**	192.89	205.95	57.12	62.80
$r \leq 2$	163.54**	42.59	156.00	168.36	51.42	57.69
$r \leq 3$	120.94	36.37	124.24	133.57	45.28	51.57
$r \leq 4$	84.57	29.38	94.15	103.18	39.37	45.10
$r \leq 5$	55.18	21.51	68.52	76.07	33.46	38.77
$r \leq 6$	33.67	13.33	47.21	54.46	27.07	32.24
$r \leq 7$	20.33	12.48	29.68	35.65	20.97	25.52
$r \leq 8$	7.85	7.70	15.41	20.04	14.07	18.63
$r \leq 9$	0.15	0.15	3.76	6.65	3.76	6.65

주) *, **, 그리고 ***는 10%, 5%, 그리고 1% 수준에서 각각 유의함을 나타냄.

7) 본 연구에서는 최적시차의 결정이 필요할 때마다 Newey and West(1994)의 절차를 이용하였다. 참고로, 동일한 자료에 대하여 12개월로 시차를 가정할 경우에도 전반적인 결과에 크게 영향을 받지 않고 있었다.

<표 5> 벡터오차수정 모형(VECM)에서 1차 차분변수에 대한 추정결과

(4개월 시차모형, ()는 표준오차, []는 t통계량을 나타냄)

변 수	1개월 시차	2개월 시차	3개월 시차	4개월 시차
KOSPI	0.1102 (0.08130) [1.3557]	-0.0224 (0.0791) [-0.2829]	-0.2061** (0.0869) [-2.3716]	-0.2099* (0.0854) [-2.4582]
	-0.0950 (0.07257) [-1.1351]	0.08379 (0.07381) [1.1351]	-0.1076 (0.0744) [-1.4458]	0.0395 (0.0695) [0.5689]
	-0.2662** (0.1449) [-1.8363]	0.1934 (0.1488) [1.2997]	0.0685 (0.1408) [0.4868]	-0.1698 (0.1292) [-1.3138]
CALL	0.2618 (0.9485) [0.2760]	0.2864 (0.9380) [0.3053]	1.2722 (0.8969) [1.4185]	0.7739 (0.8263) [0.9366]
	0.06918 (0.1290) [0.5360]	-0.0088 (0.1427) [-0.0622]	0.0465 (0.1384) [-0.3359]	0.0636 (0.1176) [0.5412]
	0.7947*** (0.2909) [2.7318]	0.9205*** (0.3005) [3.6313]	-0.0616 (0.2748) [-0.2245]	0.3173 (0.2709) [1.1709]
CBY	-0.2689*** (0.0927) [-2.8988]	0.2448** (0.1247) [1.9631]	-0.1120 (0.1249) [-0.8967]	-0.0963 (0.0998) [-0.9652]
	-0.0463** (0.0194) [-2.3801]	-0.0198* (0.0215) [-0.9246]	-0.0147 (0.0201) [-0.7346]	-0.0155 (0.0150) [-1.0303]
	-0.2559 (0.6602) [-0.3876]	-0.3998 (0.7492) [-0.5336]	-0.5909 (0.7920) [-0.5336]	-0.8598 (0.7423) [-1.1583]
CPI	-0.0092 (0.1371) [-0.0671]	-0.1406 (0.1463) [-0.9615]	0.1281 (0.1465) [0.8750]	-0.0921 (0.1421) [-0.6478]
	0.2618 (0.9485) [0.2760]	0.2864 (0.9380) [0.3053]	1.2722 (0.8969) [1.4185]	0.7739 (0.8263) [0.9366]
	0.06918 (0.1290) [0.5360]	-0.0088 (0.1427) [-0.0622]	0.0465 (0.1384) [-0.3359]	0.0636 (0.1176) [0.5412]
IP	0.7947*** (0.2909) [2.7318]	0.9205*** (0.3005) [3.6313]	-0.0616 (0.2748) [-0.2245]	0.3173 (0.2709) [1.1709]
	-0.2689*** (0.0927) [-2.8988]	0.2448** (0.1247) [1.9631]	-0.1120 (0.1249) [-0.8967]	-0.0963 (0.0998) [-0.9652]
	-0.0463** (0.0194) [-2.3801]	-0.0198* (0.0215) [-0.9246]	-0.0147 (0.0201) [-0.7346]	-0.0155 (0.0150) [-1.0303]
M 2	-0.2559 (0.6602) [-0.3876]	-0.3998 (0.7492) [-0.5336]	-0.5909 (0.7920) [-0.5336]	-0.8598 (0.7423) [-1.1583]
	-0.0092 (0.1371) [-0.0671]	-0.1406 (0.1463) [-0.9615]	0.1281 (0.1465) [0.8750]	-0.0921 (0.1421) [-0.6478]
	0.2618 (0.9485) [0.2760]	0.2864 (0.9380) [0.3053]	1.2722 (0.8969) [1.4185]	0.7739 (0.8263) [0.9366]
OIL	-0.0463** (0.0194) [-2.3801]	-0.0198* (0.0215) [-0.9246]	-0.0147 (0.0201) [-0.7346]	-0.0155 (0.0150) [-1.0303]
	-0.2559 (0.6602) [-0.3876]	-0.3998 (0.7492) [-0.5336]	-0.5909 (0.7920) [-0.5336]	-0.8598 (0.7423) [-1.1583]
	-0.0092 (0.1371) [-0.0671]	-0.1406 (0.1463) [-0.9615]	0.1281 (0.1465) [0.8750]	-0.0921 (0.1421) [-0.6478]
TB	-0.2559 (0.6602) [-0.3876]	-0.3998 (0.7492) [-0.5336]	-0.5909 (0.7920) [-0.5336]	-0.8598 (0.7423) [-1.1583]
	-0.0092 (0.1371) [-0.0671]	-0.1406 (0.1463) [-0.9615]	0.1281 (0.1465) [0.8750]	-0.0921 (0.1421) [-0.6478]
	0.2618 (0.9485) [0.2760]	0.2864 (0.9380) [0.3053]	1.2722 (0.8969) [1.4185]	0.7739 (0.8263) [0.9366]
WS	-0.0463** (0.0194) [-2.3801]	-0.0198* (0.0215) [-0.9246]	-0.0147 (0.0201) [-0.7346]	-0.0155 (0.0150) [-1.0303]
	-0.2559 (0.6602) [-0.3876]	-0.3998 (0.7492) [-0.5336]	-0.5909 (0.7920) [-0.5336]	-0.8598 (0.7423) [-1.1583]
	-0.0092 (0.1371) [-0.0671]	-0.1406 (0.1463) [-0.9615]	0.1281 (0.1465) [0.8750]	-0.0921 (0.1421) [-0.6478]
WY	-0.2559 (0.6602) [-0.3876]	-0.3998 (0.7492) [-0.5336]	-0.5909 (0.7920) [-0.5336]	-0.8598 (0.7423) [-1.1583]
	-0.0092 (0.1371) [-0.0671]	-0.1406 (0.1463) [-0.9615]	0.1281 (0.1465) [0.8750]	-0.0921 (0.1421) [-0.6478]
	0.2618 (0.9485) [0.2760]	0.2864 (0.9380) [0.3053]	1.2722 (0.8969) [1.4185]	0.7739 (0.8263) [0.9366]

주) *, **, 그리고 ***는 10%, 5%, 그리고 1% 수준에서 각각 유의함을 나타냄.

8) Johansen의 공적분 검증에 대해서는 1개월 시차에서부터 12개월 시차까지 모든 시차를 대상으로 반복 실시하여, 각 시차별로 장기적 관계를 파악하였다. 그 결과 공적분 벡터의 수는 시차의 선택과 밀접한 관계가 있음이 알 수 있었고, 따라서 가장 적합한 시차를 결정하기 위하여 각 시차별로 공적분벡터의 수와 Akaike와 Schwartz 통계량을 검토한 결과, Akaike와 Schwartz 통계량이 시차 4개월 이후부터는 증가하는 크기가 많지 않아서, 본 연구에서는 4개월 시차가 가장 적합하다고 판단하였다. 자세한 사항은 정성창(2000)을 참조바람.

공적분 벡터의 수가 1개 이상 존재할 경우에는 아이겐 값이 가장 큰 공적분 벡터를 사용한다. 따라서, 4개월 시차를 고려할 경우, 우리나라 주가와 거시경제 변수들간의 장기적 균형관계를 나타내는 공적분 벡터는 다음과 같이 나타났다⁹⁾. 즉,

$$[1, -6.57, 7.17, -76.84, -3.99, 0.47, 4.88, -0.55, -20.34, 15.41]^{10)}$$

그리고, VECM 모형에서 1차 차분변수들에 대한 추정결과는 <표 5>에 제시되어 있다. 본 연구에서 추정된 모형들의 잔차를 분석하기 위하여 Jarque-Bera(1980)의 정규성 검증을 실시한 결과, CALL, CPI, IP, WY를 제외한 나머지 변수들의 정규성은 5%의 유의수준에서 기각되는 것으로 나타났다.

3. 인공지능모형 결과

1) GRNN

GRNN의 장점은 네트워크의 학습이 빠르며, 표본의 수가 많을수록 최적 회귀면에 수렴한다는 점이며, 특히, 비정상적인(non-stationary) 자료들을 잘 처리할 수 있다는 점등이다. 반면에 이 모형은 많은 메모리 용량을 사용한다는 단점을 가지고 있다. 본 연구의 GRNN 모형에서는 입력층에서 PE(Processing Elements)의 수를 9개, 출력층에서 PE의 수를 1개, 은닉층에서 Pattern PE의 수를 198개로 하였다. 학습규칙은 Delta Rule을 사용하였으며, 변환함수는 Sigmoid함수를 사용하였다.

2) Back-Propagation

Back-Propagation 모형에서는 두 개의 디자인을 시도하였다. 첫 번째 디자인 1에서는 입력 node의 수를 입력변수들의 수와 동일하게 하였다. 즉, 입력층에서 PE의 수를 9개

9) 시차별로 주가와 모든 거시경제 변수들간의 장기적 균형관계를 기대되는 계수의 부호(predicted)와 각 계수들의 부호를 시차별로 비교하였다. 그 결과 시차가 4개월일 경우에 가장 합리적인 결과를 가져다주는 것으로 판단되었다.

10) 이 결과에 의하면, 우리나라 주식가격과 단기이자율간에는 (+)의 장기적 관계, 장기이자율과는 (-)의 장기적 관계, 인플레이션과는 (+)의 장기적 관계, 생산활동과는 (+)의 장기적 관계, 오일가격과는 (-)의 장기적 관계, 통화량과는 (-)의 장기적 관계, 무역수지와는 (+)의 장기적 관계, 원달러환율과는 (+)의 장기적 관계, 그리고 원엔환율과는 (-)의 장기적 관계를 각각 갖는 것으로 나타났다. 그리고 이러한 계수들의 부호는 예상되는 부호와 거의 일치하고 있음을 알 수 있었다. 그리고, 자료에 선형추세가 있는지 여부를 검증하기 위하여 $-2\ln(Q, H_2^*(4) | H_2(4))$ 을 계산한 결과 185.88으로 나타났으며, 그 결과 1% 유의수준에서 선형추세가 없다는 귀무가설은 기각되었다. 따라서 본 연구의 자료에서는 선형 deterministic 추세가 있다는 것으로 간주되어 모든 결과들은 선형추세와 함께 해석된다.

로, 출력층에서 PE의 수를 1개로, 은닉층의 수를 1개로, 은닉층에서 PE의 수를 7개로 하였다. 학습규칙은 Delta Rule을 사용하였으며, 변환함수는 Sigmoid함수를 사용하였다. 두 번째 디자인 2에서는 $i + 10$ 번째 기간의 KOSPI를 i 번째부터 $i + 9$ 번째 기간까지의 자료를 바탕으로 하여 예측하는 모형이다. 입력층에서 PE의 수를 90개로, 은닉층에서 PE의 수를 50개로 한 것을 제외하고는 디자인 1과 동일하다.

4. VECM과 인공지능모형의 설명력 비교

본 연구의 목적은 동태적 선형모형인 VECM과 비모수적모형으로 비선형모형이라고 할 수 있는 인공지능모형의 설명력을 비교하고자 함에 있다. VECM 모형을 이용하여 장기적 균형관계는 위에서 제시되었으며, VECM 모형의 추정에서 단기적 조정과정을 제시한 자료가 <표 5>에 나타나 있다. VECM과 인공지능모형의 설명능력을 비교하기 위하여 RMSE(root mean square error)와 Theil's Inequality Coefficient (U Coefficient)를 계산한 결과가 <표 6>에 제시되어 있다. 여기에서 VECM과 Back-Propagation의 Design 2가 설명력에서 매우 우수한 결과를 보여주고 있다. GRNN은 훈련과정에서 매우 빠른 루틴을 제공한다는 장점은 있지만, 다른 방법들에 비하여 예측력이 뒤지는 것을 볼 수 있다. 즉, Back-Propagation의 디자인 2가 다른 모든 모형들보다도 더 우수한 예측력을 보여주고 있다. 이러한 결과들은 인공지능모형이 주가예측 모형으로서 계량경제적인 동태적인 선형모형 보다도 더 우수한 설명력을 제공할 수 있는 가능성을 보여주는 결과라고 할 수 있다¹¹⁾.

<표 6> RMSE와 Theil's U Coefficient를 이용한 VECM 모형과 인공지능모형의 설명력 비교

	방법론 및 모형	RMSE	U Coefficient
ANN			
	GRNN	0.20693	0.017437
	Back Propagation		
	Design 1	0.10809	0.009094
	Design 2	0.03584	0.00302
VECM		0.04673	0.00392

주) 여기에서 $RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^f - Y_t^a)^2}$ 이다. 단, 여기에서 Y_t^f 는 예측된 값, Y_t^a 는 실제값, T는 대상기간을 나타낸다. 그리고, U Coefficient는 $U = \frac{\sqrt{\frac{1}{T} \sum (Y_t^f - Y_t^a)^2}}{\sqrt{\frac{1}{T} \sum (Y_t^f)^2} + \sqrt{\frac{1}{T} \sum (Y_t^a)^2}}$ 로 정의된다.

IV. 결 언

증권시장과 거시경제 변수들간의 이론 및 실증적인 관계는 재무론에서 중요한 관심사이다. 이 주제에 대한 연구는 그 연구의 중요성을 고려하여 계량경제학의 발전과 더불어 지속적으로 실증분석이 이루어져왔다. 전통적인 방법론이었던 다중회귀분석으로부터, 회귀분석과 시계열 모형을 결합시킨 동태적 모형으로서 ARMAX 모형과 VAR 모형 등이 주로 활용되었다. 최근 들어서는 Johansen의 공적분 분석을 포함한 VECM 모형 등이 장기균형 관계를 제시한다는 점과 VAR 모형보다는 설명력이 높다는 점에서 새롭게 활용되고 있다. 이러한 계량경제학적인 접근법과는 별도로, 또 한편에서는 인공지능모형이 발달하면서 증권시장과 거시경제 변수들간의 관계규명이 새로운 연구주제로 등장하고 있다. 인공지능모형을 주로 활용하는 선행연구들은 증권시장의 특이패턴들로 인해 계량경제학적 접근인 선형모형으로서는 주가움직임을 추정하기 어려운 점들이 많기 때문에, 인공지능모형을 통해 주가움직임을 예측하고 설명하는 것이 더 바람직하다고 주장한다. 따라서, 본 연구의 목적은 VECM과 인공지능모형을 이용하여 우리나라 증권시장과 거시경제 변수들과의 장기적 관계에 대한 설명력을 비교해보고자 힘에 있다. VECM이 재무론의 APT에 기초를 둔 선형동학 모형이라고 한다면, 인공지능모형은 예측모형으로서 비모수적 비선형모형이라는 점에서, 두 방법론의 분석결과를 직접 비교하는 것은 매우 의미있는 연구라고 할 수 있다.

VECM 분석에서는 자료의 안정성 검증하고, 공적분 벡터를 발견한 이후 장기적 균형 관계의 실증적 분석을 하였다. 그리고, 인공지능모형에서는 delta rule과 Sigmoid 함수를 이용한 GRNN과 Back-Propagation등의 방법들을 활용하였다. 이러한 분석결과, Back-Propagation의 디자인 2가 다른 모든 모형들보다도 더 우수한 예측력을 보여주고 있었다. 이러한 결과들은 인공지능모형이 증권시장을 설명하거나 주가를 예측모형으로서 계량경제적인 동태적인 선형모형 보다도 더 우수한 설명력을 제공할 수 있는 가능성을 보여주고 있었다. 그렇지만, 계량경제적인 모형들의 결과는 계수의 부호와 크기의 유의성

11) 모형의 설명력은 표본기간을 어떻게 구분하는가에 따라 달라질 가능성이 있기 때문에, 본 연구에서는 전체 기간을 두 기간으로 분류하여 동일한 분석을 실시하였다. 기간의 구분은 Hansen and Johansen (1993)들의 공적분 안정성 검증 방법을 활용한 결과, 1987년 전후에 구조적 변화가 발견되었다. 따라서, 본 연구에서는 1987년 1월을 중심으로 두 기간으로 분류하였다. 분석 결과, 기간별 결과는 전체 기간을 대상으로 한 결과와 유사한 결과를 가져다 주었다.

을 분석함으로서 계수들의 경제적 의미를 해석할 수 있는 장점이 있는 반면, 인공지능 모형의 경우는 입력층과 출력층간의 가중치들에 대한 경제적 의미를 해석하기가 곤란하다는 점등의 한계점을 가지고 있다는 점에도 주목할 필요가 있다.

참 고 문 헌

- 김형규, “주식의 가격결정요인에 관한 실증적 연구”, 재무관리연구, 제8권 제2호, (1991), 131-164.
- 권영준, 김성태, 이홍, 신기철, “한국종합주가지수 예측모형 비교”, 증권학회지, 제12집, (1990), 375-402.
- 김종권, “주식수익률에 대한 거시경제변수의 영향분석”, 재무관리연구, 제16권 제1호, (1999), 155-170
- 김철교, 박정옥, 백용호, “제경제지표가 종합 및 업종지수에 미치는 영향에 관한 연구”, 증권학회지, 제12집, (1990), 347-375.
- 도용태, 김일곤, 김종완, 박창현, “인공지능 - 개념 및 응용 -”, 희중당, 1997.
- 이건창, 김원철, “전문가 시스템의 추론성과를 향상시키기 위한 퍼지논리지원 지식결합 메카니즘에 관한 연구”, 경영학연구, 제26권 제2호, (1997), 407-426.
- 이상재, “주요 거시경제변수가 주가에 미치는 동태적 효과”, 동서경제연구소, 1993.
- 이준행, “KSRI거시 계량모형”, 한국증권업회 연구자료 94-7, 1994.
- 정기웅, “거시경제변수와 주가 - 한국 주식시장에서의 실증분석”, 재무관리연구, 제8권 제12호, (1991), 111-129.
- 정성창, “우리 나라 증권시장과 거시경제변수 - VECM을 중심으로 -”, 재무관리연구, 제17권 제1호, 계재확정, 2000.
- 정용관, 윤영섭, “인공신경망모형을 이용한 주가의 예측가능성에 관한 연구”, 재무관리 연구, 제15권 제2호, (1998), 369-399.
- Brown, S. J., T. Otsuki, “Macroeconomic Factors and the Japanese Equity Market : The CAPM Project, in E. J. Elton and M. Gruber, eds.,”*Japanese Capital Markets* (Harper and Row, New York), 1990.
- Campbell, John Y. and John Ammer, “What moves the Stock and Bond Market? A Variance Decomposition for Long-Term Asset Returns,” *Journal of Finance*, March (1993), 3-37.
- Chen, N, Roll, R and S. Ross, “Economic Forces and the Stock Market,” *Journal of Business*, (1986), 383-403.
- Chen, N., “Financial Opportunity and the Macroeconomy,” *Journal of Finance*, (June 1991), 529-554.

- Cheung, Yin-Wong and Lilian K. Ng, "International Evidence on the Stock Market and Aggregate Economic Activity," *Journal of Empirical Finance* 5, (1998), 281-296.
- Chopra, Vijay Kumar and Lin, Patricia, "Improving Financial Forecasting : Combing Data with Intuition," *Journal of Portfolio Management*, (Spring 1996), 97-105.
- Cutler, David M., J. M. Poterba, and L. H. Summers, "What Moves Stock Prices?," *Journal of Portfolio Management*, (Spring 1989), 4-11.
- DeFina, R. H., "Does Inflation Depress the Stock Market?," *Business Review*, FRB of Philadelphia, (Nov./Dec. 1991), 3-12.
- Elton, E. J. and M. Gruber, "A Multi-index Risk Model of the Japanese Stock Market," *Japan and the World Economy*, (1988), 21-44.
- Engle, R. F. and C. W. Granger, "Co-integrated and Error Correction : Representation, Estimation, and Testing," *Econometrica*, 55, (1987), 251-276.
- Episcopos and Davis, "Predicting Returns on Canadian Exchange Rates," forthcoming in *Neural Computing and Application Journal*, 1996.
- Fama, E. and W. Schwert, "Asset Returns and Inflation," *Journal of Financial Economics*, 5, (1977), 115-146.
- Fama, E., "Multiperiod Consumption-Investment Decision," *American Economic Review*, 60, (1970), 163-174.
- Fama, E., "Stock Returns, Real Activity, Inflation and Money," *American Economic Review*, 71, (1981), 545-565.
- Geske, Robert and Richard Roll, "The Monetary and Fiscal Linkage between Stock Returns and Inflation," *Journal of Finance*, 38, (1983), 1-33.
- Gonzalo, Jesus, "Five Alternative Methods of Estimating Long-run Equilibrium Relationships," *Journal of Econometrics*, 60, (1994), 203-233.
- Grudnitski and Osburn, "Forecasting S&P and Gold Futures Prices : An Application of Neural Networks," *The Journal of Futures Markets*, 13(6), (1993), 631-643.
- Hamao, Y., "An Empirical Investigation of the Arbitrage Pricing Theory," *Japan and the World Economy*, (1988), 45-61.
- Hamid, "Financial Forecasting with Neural Networks and Time Series Models : The Case of Jakarta Stock Exchange," *Working Paper*, School of Management,

- Boston University, 1996.
- Hansen, H and Soren Johansen, "Recursive Estimation in Cointegrated VAR-Models," *Working Paper*, University of Copenhagen, 1993.
- James, C., S. Koreisha and M. Partch, "A VARMA Analysis of the Causal Relations Among Stock Returns, Real Output, and Nominal Interest Rates," *The Journal of Finance*, (1985), 1375-1384.
- Jarque, C. M. and Bera, A. K., "Efficient Tests for Normality, Homoscedasticity and Serial Independence of Regression Residuals," *Economic Letters*, (1980), 255-59.
- Johansen, S., "Estimation and Hypothesis Testing of Cointegration Vectors in Gaussian Vector Autoregressive Models," *Econometrica*, 59, (1991), 1551-1580.
- Johansen, S. and Katarina Juselius, "Maximum Likelihood Estimation and Inference on Cointegration-with Application to the Demand for Money," *Oxford Bulletin of Economics and Statistics*, 52, (1990), 169-210.
- Johansen, S., "Statistical Analysis of Cointegration Vectors," *Journal of Economic Dynamics and Control*, 12, (1988), 231-254.
- Jones, Charles M. and Kaul, Gautam, "Oil and the Stock Market," *Journal of Finance*, (June 1996), 463-491.
- Kaastra and Boyd, "Forecasting Futures Trading Volume Using Neural Networks," *The Journal of Futures Markets*, 15(8), (1995), 953-970.
- Lee, Bong-Soo, "Causal Relations Among Stock Returns, Interest Rate, Real Activity, and Inflation," *Journal of Finance*, 47, (1992), 1591-1603.
- Mukherjee, Tarun K., Atsuyuki Naka, "Dynamic Relations Between Macroeconomic Variables and the Japanese Stock Market : an Application of a Vector Error Correction Model," *The Journal of Financial Research*, (Sum. 1995), 223-237.
- Mookerjee, Rajen and Qiao Yu, "Macroeconomic Variables and Stock Prices in a Small Open Economy : The Case of Singapore," *Pacific-Basin Finance Journal*, 5, (1997), 377-388.
- Newey and West, "Automatic Lag Selection in Covariance Matrix Estimation," *Review of Economic Studies*, 16(4), (1994), 631-.
- Peterson and Peterson, "Neural Network Forecast of S&P 500 prices : Implication for Academic Research and Futures Trading Systems," *Working Paper*, Texas

- Tech University, 1996.
- Phillips, P. C. B., "Optimal inference in Cointegrated Systems," *Econometrica*, 59, (1991), 283-306.
- Ross, S. A., "The Arbitrage Theory of Capital Asset Pricing," *Journal of Economic Theory*, 13, (1976), 341-360.
- Thorbecke Willem, "On Stock Market Returns and Monetary Policy," *Journal of Finance*, (June 1997), 635-654.
- Wong, Wang, Goh and Quek, "Fuzzy Neural Systems for Stock Selection," *Financial Analyst Journal*, (January–February 1992), 47-52.