

신경회로망을 이용한 종합주가지수의 변화율 예측

노 종래*, 이종호
인하대학교

Prediction of Monthly Transition of the Composition Stock Price Index Using Error Back-propagation Method

Jong Lae Roh, Jong Ho Lee
Inha university

abstract

This paper presents the neural network method to predict the Korea composition stock price index. The error back-propagation method is used to train the multi-layer perceptron network.

Ten of the various economic indices of the past 7 years are used as train data and the monthly transition of the composition stock price index is represented by five output neurons. Test results of this method using the data of the last 18 months are very encouraging.

1. 서론

주식시장은 자본주의 사회의 시장경제의 표본으로서 경제활동 및 동향에 따라 원리적 요인 또는 심리적 영향에 의하여 민감한 반응을 나타내게 된다. 투자자들과 기업가들은 이곳에서 경제적 요인과 각자의 경험을 바탕으로 수요공급의 법칙에 따라 거래를 형성하게 된다. 종합주가지수는 각종 주식거래가의 지표로서 주식투자여부를 판단하는 하나의 자료로서 사용될 수 있다. 따라서 종합주가지수를 상대적으로 신뢰성있게 예측한다는 것은 성공적인 투자를 위한 중요한 요건이라 할 수 있다.

주가예측을 위하여는 다변량 통계기법의 하나인 요인분석기법[1]을 이용하여 주가변동요인을 계량화하여 유추해석한다든지, 다중회귀분석방법[2]을 사용하여 회귀식을 이용하는 통계적방법이 쓰이고 있다. 그러나 위의 방법들은 통계적 기법의 한계인 계량화할수없는 주가결정요인 즉, 시장의 내적요인, 정치사회적요인등으로 인하여 대체로 장기예측에 사용되며 주가지수의 단기예측에는 Line chart나 Bar chart등의 도표를 이용하여 Filter rule이나 형태분석법등의 방법으로 주가변동모형을 분석하여 주가의 전환시점을 예측하는 기술적 분석방법[3]이 선

호되고있다. 위의 방법들은 그밖에도 변수간의 상관관계에 의한 비선형적특성을 고려하지 않고 각각이 독립적인 변수로서 선형화 하여 취급함으로서 수학적 모델화의 한계를 나타낸다.

주가지수의 예측에 관한 신경회로망의 적용은 1987년 Alan Lapedes[4]에 의해서 시도되었는데 이것은 자기회귀(Auto Regression)방법의 일종으로서 10주의 과거자료를 가지고 다음주의 주가를 예측하는것으로 10주와 4주의 단순이동평균[5]방법보다 우수하였다. Ken-ichi Kamijo 와 Testsuji Tanigawa[6]는 주가지수의 매일매일의 최고가, 최저가등을 수직봉으로 표시하는 Bar chart를 가지고 일련의 패턴으로서 recurrent 신경망에 학습시켜 실험하였다. Takashi Kimoto, et al., [7]은 'buying and selling timing prediction system'을 역전파학습방법을 이용한 모듈형의 신경망을 가지고 구성하여 buy and hold전략과 비교하여 높은 수익률을 얻을 수 있음을 보았다.

본 논문에서는 역전파 학습방법을 이용한 다층퍼셉트론을 이용하여 종합주가지수의 월별 변화정도를 예측하였다. 입력변수값으로는 제한된 크기를 가지는 이진수와 전년대비, 전월대비의 증감만을 나타내는값을 사용하였고 출력값인 종합주가지수의 월별 변화정도는 증가와 감소를 각각 세구간으로 나누어 나타내었다. 신경회로망의 중간뉴런수와 학습율, 모멘텀은 각각의 경우를 달리한실험으로 최적모형을 선정하여 학습시간을 줄였으며 변화하는 주식 및 경제세계를 반영하기 위하여 월별 예측을 위한 재현이 진행될때 학습구간을 1개월씩 이동시켜가면서 재학습을 시켰다.

2. 문제의 기술

미래의 종합주가지수에 영향을 미치는 변수로서 종합주가지수, 건설주, 도매주, 금융주, 배당수익율, 주가수익비율 등의 주식관련자료와 금리, 애대

율, 최종소비지출증가율, 총고정투자증가율, 종합수지등의 경제관련자료를 포함하여 15개의 항목을 들 수 있는데 이중 유사성이 있는항목은 단순평균하여 10개의 항목을 주가예측 신경회로망의 입력변수로 사용하였다. 일반적인 선행처리의 경우 실자료의 값에 log를 취하거나 평활화하여 0과 1 사이의 실수형값으로 사용하지만 상기 10개의 입력변수에서는 5개 bit의 이진수로 표현하였다. 이들 자료의 학습은 84년 1월부터 89년 6월까지의 월별자료를 사용하였으며 학습구간을 전체의 선행처리구간으로 잡고 아래와 같은 식을 이용하여 각각의 학습자료의 크기를 0과 31 사이의 값으로 표현하였다.

$$N(X_i) = \left[\frac{X_i - P_x}{Q_x - P_x} \right] * (28 - 3) + 3 \quad \text{--- (1)}$$

$X_i : X$ 변수의 i번째값

$P_x : X$ 변수의 최소치로부터 10%순위에 있는 변수값

$Q_x : X$ 변수의 최대치로부터 10%순위에 있는 변수값

단, $0 \leq N(X_i) \leq 31$ 로 포화하며 $N(X_i)$ 는 반올림에 의한 정수값.

10개의 항목에 전체 50bit의 뉴런으로 표현하게 되며 전월대비, 전년대비 증감을 표시하는 20bit를 추가하여 모두 70개의 bit가 입력을 위하여 사용된다. 지도출력으로는 월별종합주가지수의 증감을 2 out-of-5 code 를 사용하여 매우증가, 증가, 조금증가, 조금감소, 감소, 매우감소의 6구간으로 표현한다. 이 2 out-of-5 code 는 모든 지도 출력값이 5개의 출력뉴런중 반드시 1개는 1을 나타내도록하여 재현시 신뢰할수있는 출력을 얻은것인지 확인할수있게 한다. 표 1에서 보듯이 첫번째 bit는 종합주가지수가 전달대비 증가인 경우 항상 1이되며 마지막 bit는 전달대비 감소인 경우 항상 1이 되도록 하였다.

표 1. 출력 code 의 의미

Table 1. The output codes and their meaning.

출력 code	의 미	종합주가지수 변화량
0 0 0 1 1	매우감소	-6.9 이하
0 0 1 0 1	감소	-6.8 ~ -1.6
0 1 0 0 1	조금감소	-1.5 ~ 0
1 0 0 1 0	조금증가	0 ~ 5.3
1 0 1 0 0	증가	5.4 ~ 29.6
1 1 0 0 0	매우증가	29.7 이상

3. 학습방법

역전파학습의 학습단계는 각 입력값에 대해 충

력을 산출하는 순방향처리와 지도출력과 실출력사이에서 발생하는 오차를 역으로 진행시켜 이 오차를 최소화하는 쪽으로 층과 층사이의 연결강도를 변화, 조절하는 역방향처리로 구성 된다. 연결강도 W^1, W^2 의 초기치는 -0.1과 0.1사이의 난수로 사용하였다. 식②는 입력벡터 X 로부터 출력벡터 O 를산출하는 순방향처리를 나타낸다. 입력벡터 X 는 연결강도 W^1 과 곱하여 중간층에 전달되고 이값은 sigmoid의 비선행전달함수를 거쳐 중간층 뉴런의 출력이된다. 중간층의 출력행렬은 연결강도 W^2 와 곱해져서 출력뉴런에 전달되고 sigmoid함수를 거쳐 출력층의 출력이된다.

$$O = \text{sig}[W^2 \cdot \text{sig} [W^1 \cdot X]] \quad \text{--- (2)}$$

여기서

$$\text{sig}(x) = \frac{1}{1 + e^{-x}}$$

O : 출력벡터 [$p*1$]

X : 입력벡터 [$n*1$]

W^1 : 중간층뉴런과 입력뉴런의 연결강도 행렬 [$m*n$]

W^2 : 출력뉴런과 중간층뉴런의 연결강도 행렬 [$p*m$]

역방향처리과정은 출력뉴런에서 지도출력과 실출력의 오차를 최소화하도록 연결강도 W^2 를 조절하고 중간층의 지도출력을 얻어 중간층과 입력층 사이의 연결강도 W^1 을 조절하는 반복학습의 형태이다.

Sigmoid 함수 $y = \text{sig}(x)$ 의 미분값은 식③이라 할때

$$\frac{\partial y}{\partial x} = y * (1 - y) \quad \text{--- (3)}$$

이식을 이용하여 각각의 출력뉴런의 델타값은 식 ④와 같다.

$$\delta_{pk} = (T_{pk} - O_{pk}) \cdot O_{pk} \cdot (1 - O_{pk}) \quad \text{--- (4)}$$

출력층과 중간층 사이의 연결강도의 조절은 아래와 같다.

$$\Delta W_{kj}(n) = \eta \cdot \delta_{pk} \cdot O_{pj} + \alpha \cdot \Delta W_{kj}(n-1)$$

$$W_{kj}(n+1) = W_{kj}(n) + \Delta W_{kj}(n)$$

p : 입력패턴번호

k : 출력층의 뉴런번호

j : 중간층의 뉴런번호

i : 입력층의 뉴런번호

n : 반복회수

δ_{pk} : k 번째 뉴런의 델타값

T_{pk} : k 번째 뉴런의 지도출력

O_{pk} : k 번째 뉴런의 실출력

η 는 학습률로서 연결강도의 변화크기를 조절한다. α 는 모멘텀상수로서 이전의 연결강도변화량을 반영한다. 중간층의 오차는 지도출력값이 없으므로 출력층의 텁타값과 출력층과 중간층의 연결강도의 곱의 합으로 나타낸다.

$$(T_{pj} - O_{pj}) = \sum_k \delta_{pk} \cdot W_{kj}$$

$$\delta_{pj} = O_{pj} \cdot (1 - O_{pj}) \cdot \sum_k \delta_{pk} \cdot W_{kj}$$

중간층과 입력층 사이의 연결강도의 변화량은 아래와 같다.

$$\Delta W_{ji}(n) = \eta \cdot \delta_{pj} \cdot O_{pi} + \alpha \cdot \Delta W_{ji}(n-1)$$

$$W_{ji}(n+1) = W_{ji}(n) + \Delta W_{ji}(n)$$

출력층의 총오차는 다음과 같으며

$$E_{total} = \frac{1}{2} \sum_p \sum_k (T_{pk} - O_{pk})^2 \quad \text{--- (5)}$$

이 총오차가 적절히 산정된 오차허용치를 만족하게 되면 반복학습을 끝낸다.

제현은 순방향처리와 동일한과정이다. 본 논문에서는 뉴런 입출력값으로 이진수를 사용하므로 출력뉴런의 전달함수는 0.5의 문턱값을 갖는 hard limit 함수를 사용하였다. 출력의 data format으로 2 out-of-5 code를 사용하였으므로 출력뉴런중 1의 값을 갖는 뉴런이 2개가 아닐경우는 문턱값을 0.4에서 0.6의 범위 이내로 상하향조정 함으로서 2개의 뉴런에 1의 값이 나오도록 유도하였다. 출력은 5개의 뉴런에 의하여 6종류의 변화율을 나타내는데 현재의 종합주가지수와 다음달의 종합주가지수의 증감 정도가 각각 3구간으로 나누어 표현된다.

4. 실험 및 결과

다중 퍼셉트론의 문제점은 학습시간이 길다는 점과 적정 중간층뉴런의 갯수를 정하는 일이다. 학습속도는 학습률의 크기와 학습자료의 직교성과 관계되는데 충분한 직교성을 위하여 입력뉴런을 이진 값으로 표현하였다. 학습률과 중간층뉴런의 갯수의 결정은 그림 1에서와 같이 뉴런수와 학습률을 달리하여 실험하여 결정하였다. 중간층뉴런이 40개인 A의 경우가 가장 빨리 수렴하고 중간층 뉴런이 20개인 C의 경우가 다음으로 수렴하였다. B의 경우는 학습률이 커질때 초기의 오차감소속도는 증가하지만 발산이 발생되는 것을 보여준다. D와 E는 부족한 중간층 뉴런의 갯수의 경우인데 느린학습형태를 보여준다. PC의 계산속도를 감안하여 연결강도의 수를 적절히 한 c의 구조를 선택하였다.

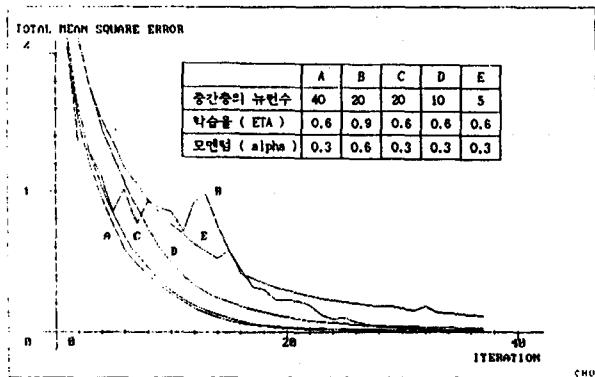


그림 1. 신경회로망의 총자승오차.

Fig. 1. Total mean square error of the neural network.

표 2. 예측값의 비교

Table 2. Desired output and the actual output.

월별	지도 출력	예측값	비교
89. 8.	1 1 0 0 0	1 0 1 0 0	유사1
89. 9.	1 0 1 0 0	0 0 0 1 1	상위
89.10.	0 0 0 1 1	0 1 0 0 1	유사2
89.11.	0 0 1 0 1	0 1 0 0 1	유사1
89.12.	1 0 0 1 0	1 1 0 0 0	유사2
90. 1.	0 1 0 0 1	0 0 0 1 1	유사2
90. 2.	0 0 0 1 1	0 0 0 1 1	일치
90. 3.	0 0 1 0 1	0 0 1 0 1 (0.4)	일치
90. 4.	0 0 0 1 1	0 0 0 1 1	일치
90. 5.	0 0 1 0 1	0 0 0 1 1	유사1
90. 6.	0 1 0 0 1	0 1 1 0 1	불능
90. 7.	0 0 0 1 1	0 0 1 0 1	유사1
90. 8.	0 0 0 1 1	0 0 1 0 1	유사1
90. 9.	0 0 0 1 1	0 0 0 1 1	일치
90.10.	1 1 0 0 0	0 1 0 1 1	상위
90.11.	1 0 0 1 0	0 0 0 1 1	상위
90.12.	1 0 1 0 0	1 0 0 1 0	유사1
91. 1.	1 0 0 1 0	1 0 0 1 0	일치

일치 (실제의 변화율과 일치)	5개
유사1 (증감의 정도가 한개만 틀린 경우)	6개
유사2 (증감의 판단만 맞은 경우)	3개
상위 (증감의 판단 자체가 틀린 경우)	3개
불능 (출력뉴런의 format 이 다른 경우)	1개

학습구간으로서 1984년 1월부터 1989년 6월 까지의 5년 6개월간의 월별자료로 66개의 학습패턴을 사용하였다. 각항목의 입력 data로서 크기를 나타내는 5bit의 수와 전월대비와 전년대비의 증감을 표현하는 2bit data를 사용하므로 입력층뉴런은 70 개로 구성된다. 출력층은 5개의 뉴런을 사용하였고, 중간층뉴런은 20개이고 학습율은 0.6을 사용하여 실 험한결과 약 200번정도의 iteration후에 총오차허용치(약 0.002)를 만족하였다. 학습후 재현을 통해서 다음달의 증감율을 예측하여서 증감율의 구간이 실제와 일치하는 경우와 유사한 경우와 상반되는 경우로 구분하여 표 2에 제시하였다. 월별예측이 진행됨에 따라 학습구간을 1개월씩 이동하면서 재학습을 시켰으며 이때 수렴이 안되는 경우에는 연결강도를 낸 수를 사용하여 초기화 시킨 후 새로이 학습을 시행하였다. 대개의 경우 완전히 잘못예측한것을 재학습 시킬때는 수렴이 안되므로 다시 연결강도를 초기화 해줘야 한다.

5. 토의

총 18개월의 예측에서 증감의 판단 자체가 그릇된 것은 3개월이고 예측불능의 경우는 1개월이었다. 유사와 일치의 경우를 합하면 증감예측의 정확도가 약 78% 되어 매우 만족할만한 결과라 생각된다. 앞으로 이 신경회로망 모델을 이용하여 주별 주가예측을 실행해 보고자하며 종합주가지수의 증감 상황이 아닌 크기를 표현하는 출력값을 예측하는 문제도 고려하고자한다. 이와같은 예측문제에 있어서 편의상 고정구간(1개월)의 data를 사용하였으나 상황에 따른 가변구간 예측이 표현 가능하다면 대단히 효용성있는 예측방법이 되리라본다. 또한 신경회로망의 예측결과에 의거한 모의투자를 시행하여 일정 기간이 지난후의 수익율을 산출해보는 것도 흥미있는 실험이 될것이다. 출력으로서 종합주가지수 뿐 아니라 종목별 주가지수를 취급한다면 이모델의 효용 가치는 월등 증대될것으로 본다.

참고문헌

- [1] 명 인식, "주가지수 요인분석", 주식, 한국증권 거래소, pp.3-21, 1989.
- [2] 이 주호, "주가지수 회귀분석", 주식, 한국증권 거래소, pp.24-38, 1989. 3.
- [3] 최 영수, "한국 증권 시장의 경우: 기술적 분석 기법의 유통성 분석", 과학기술원 석사논문, 1987.
- [4] Lapedes, A. & Farber, R., "Non-Linear Signal Processing using Neural Networks: Prediction and System Modeling". Los Alamos National Laboratory report, LA-UR-87-2662.
- [5] Spyros Markridakis and Steven C. Wheelwright, "Interactive Forecasting", Holden-Day, Inc., 1978.
- [6] Ken-ichi Kamijo and Tetsuji Tanigawa, "Stock Price Pattern Recognition - A Recurrent Neural Network Approach - ", INNS, vol.1, I-215 - I-222, 1990.
- [7] Takashi Kimoto, Kauzo Asakawa, Morio Yoda and Masakazu Takeoda, "Stock Market Prediction System with Modular Neural Network", INNS, vol.1, pp.I-1 - I-6, 1990.
- [8] T. P. Vogl, J. K. Mangis, A. K. Rigler, W. T. Zink, and D. L. Alkon, "Accelerating the Convergence of the back-Propagation Method", Biol. Cyb. 59, pp.257-263, 1988.
- [9] D.E.Rumelhart, et al., "Parallel Distributed Processing" vol.1, MIT press, 1986.
- [10] Yoh-Han Pao, "Adaptive Pattern Recognition and Neural Networks" Addison-Wesley Publishing Company, pp.269-290, 1989.
- [11] Philip D. Wasserman, "Neural Computing Theory and Practice", Van Nostrand Reinhold, pp.43-75, 1989.