

# 자기연상 학습 신경망과 부호 입력 변수를 이용한 종합주가지수 “왼쪽어깨” 패턴 검출

백진우 조성준  
서울대학교 산업공학과

## “Left Shoulder” Detection in Korea Composite Stock Price Index Using an Auto-Associative Neural Network and Sign Variables

Jin-Woo Baek Sung-Zoon Cho

Dept. of Industrial Engineering, Seoul National University

### Abstract

We proposed a neural network based “left shoulder” detector. The auto-associative neural network was trained with the “left shoulder” patterns obtained from the Korea Composite Stock Price Index, and then tested out-of-sample with a reasonably good result. A hypothetical investment strategy based on the detector achieved a return of 132% in comparison with 39% return from a buy and hold strategy

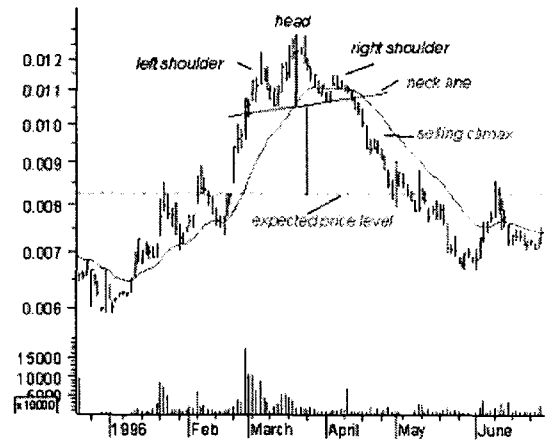


그림 1. 머리어깨 모형

### 1. 서론

기술적 분석을 하는 증권 분석가들은 매매 순간을 결정하기 위하여 주가 차트를 분석하는 방법을 사용한다[6]. 이 방법을 패턴 분석이라고 하는데 과거 주가 차트에 나타나 있는 특정의 모양들을 연구하여 현재 주가의 움직임을 그것에 맞추어 봄으로써 주가 추이를 예측하는 방법이다. 특히 최근들어 데이터 마이닝기법을 이용하여 예측하는 연구들이 진행되고 있다[3].

“머리어깨모형(Head and Shoulder Formation, HSF)”은 차트 패턴중에 많이 알려진 것중의 하나이다[7](그림 1 참조). 이것은 주가 추세가 반전한다는 것을 알려주는 대표적인 패턴중의 하나이다. 특히 왼쪽어깨형(Left Shoulder, LS)은 HSF가 시작하고 있음을 알리는 패턴이다. 만일 LS를 검출할

수 있다면 주식매수와 같은 방법을 통하여 수익을 낼 수 있다. 또는 LS가 지난 후에 Head를 검출하여 선물을 매도하는 방법을 사용할 수도 있다.

일반적으로 증권 분석가들은 HSF가 형성된 후에 차트의 형태를 정성적으로 분석하여 이것이 HSF인지 아닌지를 판단한다. 이 과정은 주관적인 선입견을 배제할 수 없을 뿐만 아니라 종종 예측도 빗나가는 경우가 많다.


그러나 HSF 판단과정에서 과거의 데이터를 이용하여 보다 정확하게 HSF를 검출할 수 있다.

이를 위한 방법으로 신경망을 사용한 패턴 분류방법을 사용할 수 있는데, 이 검출 문제는 2-class 패턴 분류 문제로 정형화할 수 있다. LS 패턴과 LS 패턴이 아닌 데이터를 이용하여 신경망을 학습시키고 난 후 테스트 데

이터 혹은 현재 시점의 데이터를 입력으로 주게 되면 신경망은 이를 LS인지 아닌지를 분류하게 된다. 그런데 이 방법은 LS 패턴이 아닌 데이터를 충분히 수집할 수 없다는 문제점이 있다. 이것은 신경망을 이용한 분류 문제 중에서 한 Class의 데이터가 없거나 있다하더라도 충분히 수집할 수 없는 경우에 발생하는 "partially exposed environment" 문제이다. 관련된 문제로서 위폐 검출문제, 키입력 패턴을 이용한 사용자 확인문제 등이 있다.

최근 자기연상학습 신경망(Auto-Associative Neural Network, AANN)이 이 문제를 해결하는데 있어서 효과적이라는 연구가 있었다[1]. AANN은 입력과 출력 벡터가 같은 신경망이다. 2장에서 AANN의 자세한 내용과 어떤 이유로 LS의 검출에 AANN을 사용할 수 있는지를 소개하였다.

본 논문에서 제안한 LS 검출 방법은 다음과 같다. 첫째, LS 패턴을 과거의 데이터에서 찾아낸다. 둘째, 찾아낸 데이터를 이용하여 AANN을 학습시킨다. 셋째, 학습이 된 AANN에 데이터를 입력하고 출력과 비교를 한다. 만일 입력과 출력이 비슷하면 주어진 데이터는 LS 패턴이 되고 그렇지 않다면 LS가 아닌 패턴이 된다. LS 패턴 신호가 발생하면 매수하고 LS가 아닌 패턴 신호가 발생하면 매도나 혹은 이에 관련된 다른 전략을 구사하면 된다 (그림 2 참조).



## 2. LS 검출을 위한 자기연상 학습 신경망

AANN은 입력과 출력간의 차이가 최소가 되도록 맵핑(mapping)해주는 신경망이다.  $F$ 를 신경망의 맵핑 함수,  $x_i$ 를 입력 벡터,  $y_i$ 를 출력벡터라 하면, 신경망은 식(1)로 주어진 에러함수를 최소화하는 방향으로 학습을 하게 된다.

$$E = \sum_{i=1}^N \|x_i - y_i\|^2 = \sum_{i=1}^N \|x_i - F(x_i)\|^2 \quad \text{식(1)}$$

여기서 맵핑 함수  $F$ 는 식(2)와 같이  $F_1$ ,

$F_2$ 로 나눌 수 있다.

$$F(.) = F_2(F_1(.)) \quad \text{식(2)}$$

$F_1$ 은 차원 감축을 하는 맵핑함수이고,  $F_2$ 는 차원 확장을 하는 함수이다. 차원 감축은 의 가중치(weight)들이 잡아낸 subspace 위로 입력벡터를 사영시키는 것이다. 차원 확장은 차원 감축된 벡터들을 의 가중치(weight)들이 잡아낸 hypersurface 위로 맵핑시켜주는 것이다. 일반적으로 신경망의 전이함수(transfer function)가 비선형이기 때문에 subspace와 hypersurface는 비선형의 특징을 갖는다.

한편, 과거의 주가 데이터는 그 당시의 추세와 특징을 내포하고 있고 이러한 추세와 특징은 시간 간격을 두고 반복된다. 따라서 HSF의 LS에 해당하는 주가 데이터는 다른 구간의 데이터와는 다른 특징을 갖게 된다. 이를 AANN의 입력 변수로 설정하면 AANN의 subspace에 의해 LS만의 특징을 잡아낼 수 있다.

LS 데이터로 학습을 한 AANN은 비슷한 특징을 갖는 LS 데이터에 대해서 입력과 출력 벡터의 에러가 작게 된다. 그러나 LS가 아닌 데이터가 입력으로 주어지면 에러는 커진다. 이 에러에 대하여 적당한 threshold를 적용하면 LS인지 아닌지를 검출할 수 있다.

## 3. 데이터 수집 및 신경망 학습

실험을 위해 종합주가지수(KOSPI) 데이터를 사용하였다. 기간은 1997년 4월 1일부터 2000년 7월 24일까지이다. 거래일  $i$ 에 대하여 시가를  $O(i)$ , 고가를  $H(i)$ , 저가를  $L(i)$ , 종가를  $C(i)$ , 변동을  $N(i)$ , 거래량  $V(i)$ 을 그리고 거래대금을  $M(i)$ 라 하자. 그리고 다음과 같은 5일, 20일 이동평균을 계산하였다.

$$C_{MA}^{20}(i) = \frac{1}{20} \sum_{j=i-19}^i C(j), \quad C_{MA}^5(i) = \frac{1}{5} \sum_{j=i-4}^i C(j)$$

$$N_{MA}^{20}(i) = \frac{1}{20} \sum_{j=i-19}^i N(j), \quad V_{MA}^{20}(i) = \frac{1}{20} \sum_{j=i-19}^i V(j)$$

이 이동평균을 이용하여  $[O(i) - C_{MA}^{20}(i)]$ ,  $[H(i) - C_{MA}^{20}(i)]$ ,  $[L(i) - C_{MA}^{20}(i)]$ ,  $[C(i) - C_{MA}^{20}(i)]$ ,  $[N(i) - N_{MA}^{20}(i)]$ ,  $[V(i) - V_{MA}^{20}(i)]$ ,  $[C(i) - C_{MA}^5(i)]$ 를 계산하였고 이 값이 양이면 1, 음이면 -1 값

을 입력으로 하는 부호변수를 사용하였다.

그리고  $\log(C(i)/C(i-1))$ 를 추가하여 총 8개의 입력변수를 사용하였다. 이 과정에서 이동평균을 포함시키면 입력변수의 개수를 효과적으로 줄일 수 있고 과도하게 학습하는 것을 막을 수 있다[4].




그림 3. 1997.4부터 2000.7까지의 종합주가지수 데이터

그림 3은 실험에서 사용한 종합주가지수 데이터를 그래프로 나타낸 것이다. 1999년 3월 이전의 데이터로 학습을 하였고, 1999년 3월 이후의 데이터로 테스트를 하였다. 그런데 실제로 학습 구간내의 모든 데이터를 학습에 사용한 것이 아니라 LS에 해당하는 86일간의 데이터로 학습을 하고 27일간의 데이터로 validation을 하였다. LS 구간은 다음과 같은 기준으로 선정을 하였다.

- 30일 이상의 구간에서 부분 최고점(local maximum)에 해당하는 정점(selling climax)을 선택한다(그림.1 참조).
- 목선(neckline)에 의해 설정된 LS를 선택한다.
- LS에 해당하는 구간의 데이터를 선정한다.(단어 및 자세한 내용은 [5],[6] 참조)

실험에 사용한 AANN의 구조는 8L-12N-5N-12N-8L이다. L은 신경망의 transfer function이 선형 함수라는 것을 의미하고 N은 비선형 함수라는 것을 의미한다(tangent sigmoid를 사용함). 학습방법은 gradient descent방법을 사용하였고 과도 학습을 방지하기 위하여 early stopping방법을 사용하였다. 실험은 MATLAB 5.3으로 구현하였다.

#### 4. 결과




그림 4. 테스트 데이터의 시험 결과

그림 4는 테스트 구간의 종합주가지수와 신경망의 LS 검출 결과를 나타낸 것이다. 검은 막대로 표시된 부분이 LS에 해당하는 곳이다. Threshold 값인 1500은 실험적으로 결정하였다.

실험결과를 평가하기 위하여 False Rejection Rate(FRR)과 False Acceptance Rate(FAR) 두가지의 분류평가 방법을 사용하였고 재무 평가를 하기 위하여 수익률을 계산하였다.

FRR과 FAR은 다음과 같이 정의하였다.

$$FRR = \frac{\sum_{i \in \{i | D(i)=1\}} L(i)}{\sum_{i=1}^n L(i)}, \quad FAR = \frac{\sum_{i \in \{i | L(i)=0\}} D(i)}{n - \sum_{i=1}^n L(i)}$$

여기서 n은 테스트 데이터의 총 개수이고,  $D(i), L(i)$ 는 다음과 같이 정의하였다.

$$D(i) = \begin{cases} 0 & \text{if classified as non-LS at } i\text{th day} \\ 1 & \text{if classified as LS at } i\text{th day} \end{cases}$$

$$L(i) = \begin{cases} 0 & \text{if non-LS at } i\text{th day} \\ 1 & \text{if LS at } i\text{th day} \end{cases}$$

LS 검출 신호에 의해 매매를 하는 전략을 사용하였다. 즉, 가 0에서 1로 바뀌면 매수를 하고 가 1에서 0으로 바뀌면 매도를 하는 것이다. 그리고 이 수익률의 비교를 위하여 매수 후 계속 유지하는 buy and hold 방법의 수익률도 계산하였다. 이를 수식으로 표현하면 다음과 같다.

LS 신호에 의한 수익률=

$$\frac{\sum_{i \in \{i | D(i)=1\}} (O(i+2) - O(i+1))}{O(1)}$$

$$\text{Buy and Hold의 수익률} = \frac{(C(n) - O(1))}{O(1)}$$

표1. 테스트 구간에서 AANN의 성능

Measurement	Value(total 348 days)
FRR	24.4 % (22 days / 90 days)
FAR	12.4 % (32 days / 258 days)
LS 신호에 의한 수익률	132 % (693.4 points / 524.9 points)
Buy and Hold의 수익률	39 % (203.9 points / 524.9 points)

LS 신호에 의해 거래를 할 경우에는 다음 날 시가에 매수 혹은 매도를 한 것으로 가정하였고 거래비용과 충격비용은 없다고 가정하였다.

표 1은 테스트 데이터(1999년 3월-2000년 7월)에서 AANN의 성능을 계산한 결과를 정리한 것이다. LS 신호에 의한 수익률이 약 132%가 나왔다. 이것은 buy and hold에 의한 수익률보다 3배정도 많다.

한편 FRR과 FAR간에는 trade off가 있다. Threshold를 높이면 FAR은 줄어드는 대신 FRR은 증가하게 된다.

### 5. 결론

본 논문에서는 신경망을 기반으로 "머리어깨형(head and shoulder formation)"의 "왼쪽 어깨형(left shoulder)"을 검출하는 방법을 제안하였다. 23개월 동안(1997년 4월-1999년 2월)의 종합주가지수 데이터에서 왼쪽 어깨형에 해당하는 구간으로 자기연상학습 신경망(Auto-Associative Neural Network)을 학습시켰다. 그리고 1999년 3월-2000년 7월까지의 데이터로 테스트를 하였다. 학습 데이터 기간 내에 IMF가 있었다는 사실을 고려할 때 결과는 비교적 우수하였다. LS 검출 신호에 의한 전략의 수익률이 132%였고 이와 비교하여 Buy and hold의 전략이 39%였다. 본 논문에서 제안한 방법에는 몇 가지 제한이 있다.

첫째, 성능을 측정하기 위한 평가방법이 공정하지 못할 수 있다. 단순히 맞춘 날짜의 수를 이용하는 것이기 때문에 천천히 증가하는 LS의 경우 False Acceptance Rate와 False Rejection Rate는 이를 공정하게 반영치 못한다. 둘째, LS 검출 신호는 시장 진입 신호(매수)이다. 시장 진입 신호 못지 않게 시장에서 나오는 신호 역시 중요하다. 이 문제는 오른

쪽 어깨(Right Shoulder) 혹은 머리(Head)를 검출하는 것으로 해결할 수 있다. 종합주가지수로 학습한 AANN을 이용하여 코스닥 지수나 다른 개별종목에 응용하는 연구도 흥미로울 것이다. 그리고 LS뿐만 아니라 다른 패턴들, 예를 들면 다중모형, 대칭형, 확대형등에 대하여 적용하는 것도 유용할 것이다.

### 참고

본 연구는 뇌 과학 및 공학 연구 프로그램과 두뇌한국 21 프로젝트의 지원을 받았다.

### 6. 참고 문헌

- [1] S. Cho, C. Han, D. Han, & H. Kim.(2000). Web based Keystroke Dynamics Identity Verification using Neural Network. Journal of Organizational Computing and Electronic Commerce. In print
- [2] C. Bishop.(1995). Neural networks for pattern recognition. Oxford: clarendon press.
- [3] V. Guralnik, J. Srivastava.(1999). Event Detection from time Series Data. KDD-99 Proceeding of the fifth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. pp 33-42.
- [4] G. Deboeck.(1994). Trading on The Edge. John Wiley & Sons, Inc.
- [5] W.Eng.(1988). The Technical Analysis of Stocks, Options & Futures. McGraw-Hill.
- [6] TradeTalk company.(2000). "TraderTalk, Head & Shoulder Formations..htm",<http://www.tradertalk.com/tutorial/h&s.html>.
- [7] Borsanaliz.com company.(2000). "Tools for technical analysis stock exchange", <http://www.geocities.com/wallstreet/floor/1035/fo rmations.htm>
- [8] 한국증권거래소.(2000). "KOSPI & KOSPI 200", <http://www.kse.or.kr>.