

신경망을 이용한 선물가 예측

김성환, 이상훈, 김기태
중앙대학교 컴퓨터공학과

Features Price Prediction Using Backpropagation Neural Network

Sung-Hwan Kim, Sang-Hoon Lee, Ki-Tae Kim
Dept. of Computer Science & Engineering, Chung-Ang University

요약

본 논문에서는 KOSIP 200 선물을 예측하기 위한 시스템으로 과거의 자료를 사용하여 거래패턴과 그 변화 및 시장의 가격과 거래량의 패턴을 학습하여 미래의 선물가를 예측하는 시스템으로 역전파 신경망(Backpropagation Neural Network)을 학습 알고리즘으로 하는 L2K 시스템 실험과 다양한 입력데이터와 훈련데이터의 변화를 테스트 하여 최적의 네트워크 구성을 하여 정확도를 향상 시켰다.

1. 서론

신경망은 복잡하게 상호 연결된 뉴런의 망으로 구성된 생체 학습 시스템에서 영감을 받은 것으로, 이런 생물학적 처리과정을 빌어 매우 효율적인 기계학습을 얻을 수 있다. 이러한 학습 특성 때문에 신경망은 여러 분야에서 사용되는데, 특히 학습을 통한 예측이나 인식 분야에서 탁월한 성능을 발휘한다. 또한, 신경망은 주식 시장의 기술적 지표[1]를 이용하여 미래 가격 경향을 예측하려는 많은 연구에도 사용된다. Recurrent 신경망을 이용한 주가 패턴 인식[9], modular 신경망을 사용한 주가 예측 시스템[10], rough set을 사용한 주식 거래 규칙 추출[11] 등 많은 방법들이 제안되었지만 예측 정확도의 결과가 충분히 만족스럽지 못했다. 본 논문은 선물 시장의 데이터의 패턴을 기계학습을 통해 미래의 선물가를 예측하기 위한 시스템으로 보다 높은 정확성을 위하여 역전파 신경망(Backpropagation Neural Network)을 이용한 L2KT 시스템을 통하여 다양한 네트워크 구조와 학습 시 조건을 다양하게 하여 기계학습을 시켰다.

실제 선물시장의 선물 데이터를 사용하여 시뮬레이션 한 실험 결과는 적용한 방법이 유용함을 보여주었다.

본 논문의 구성은 다음과 같다. 2장에서는 역전파 신경망 모델에 대해 살펴보고, 3장에서는 이를 구현한 L2K 예측 시스템의 개요와 실험 데이터를 설명한다. 4장에서는 구현된 시스템에 대한 실험 결과를 보이고, 5장에서는 결론을 맺고 추후 연구 과제를 기술한다.

2. 관련 연구

역전파 신경망은 입력층, 은닉층, 출력층으로 이루어진 계층적 네트워크이다. 네트워크의 각 유닛은 인접한 층의 모든 유닛들과 전방향으로 연결되어 있다. 신경망의 구조는 그림1과 같다.

역전파 신경망은 단층 퍼셉트론의 단점인 선형 분리 한계를 극복한 보다 강력한 기계학습의 방법이며, 또한 역전파 신경망(Backpropagation Neural Network)은 단일 이진(binary) 출력으로 제한되지 않고, 연속적인 범위 안의 어떠한 값으로도 출력값을 가질 수 있다. 학습 방법과 순서는 다음과 순서는 다음과 같다. 각 유닛(o)의 차례 학습율(η)을 적용하여 차이(Δw)만 큼 하위 계층 노드의 링크 가중치 값을 조정한다. 조정된 링크 값으로 하위층 유닛의 출력과 링크의 가중된 합을 계산하여 출력층의 목표값과 출력값의 에러율을 계산한다.

.이 과정을 계속 반복하여 예측 결과 값이 허용오차 안으로 떨어지면 학습을 중단한다. 출력 결과는 0과 1사이의 범위를 갖는다.

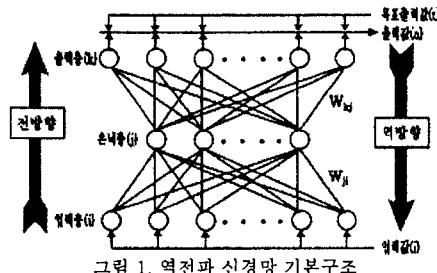


그림 1. 역전파 신경망 기본구조

$$w_i = w_i + \Delta w_i$$

$$\Delta w_i = \eta(t - o)x_i$$

$$o(x) = w \cdot x$$

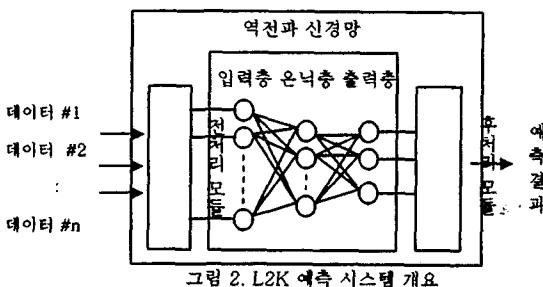
x : 하위층 출력의 유닛, w : 링크의 가중치 값
 η : 학습율, t : 목표값, o : 출력값, i : 유닛 번호

출력층 유닛의 출력값은 전달 함수 $f(x)$ 에 의하여 계산된다. 따라서 출력층의 에러는 출력값에 대한 전달 함수의 도함수인 $f'(x)$ 와 목표값과 출력값 차의 곱을 통하여 쉽게 구할 수 있다. 하지만 은닉층 유닛들은 목표 출력 값이 없기 때문에, 이들의 에러 계산이 미묘해진다. 이 문제는 Rumelhard와 McClelland가 은닉층 유닛들의 에러를 계산하기 위한 방법[8]을 고안해 냈으므로써 해결되었다. 은닉층의 유닛이 높은 에러를 산출하는 출력층 유닛의 출력에 많은 영향을 한다면 은닉층의 노드 또한 높은 에러를 가져야 한다. 출력층 유닛들에 연결된 은닉층 유닛의 링크 값들과 그것들에 대응되는 출력층 유닛의 에러를 곱해서 합하고, 전달 함수의 도함수를 통해 계산된 은닉층 유닛의 출력과 이 합을 곱함으로써 은닉층 유닛의 에러를 측정할 수 있다.

역전파 신경망(Backpropagation Neural Network)의 단점으로는 대표적으로 지역최소점 오류, 과도한 학습을 통해 역작용(Overshitting)이 발생할 수 있으며, 새로운 데이터가 발생했을 경우 네트워크의 기계학습을 다시 해야 되다는 점, 또한 네트워크의 구조상에서 은닉층의 레이어 수와 각각의 노드의 수를 결정하는 특별한 방법이 없다는 것이다.

3. L2K 예측 시스템

L2K 예측 시스템의 개요는 그림 1과 같다. 예측 시스템은 입력 패턴으로 중권거제소 종목데이터를 이용하여 만든 기술적 지표(technical index)를 전처리하여 사용하고, 출력으로 나온 결과값을 후처리하여 예측값을 발생시킨다. 그림 1과 같이 시스템은 전처리 모듈(preprocessing module), 역전파 신경망, 후처리 모듈(postprocessing module)로 구성되어 있다. 전처리 모듈(preprocessing module)은 상이한 여러 가지 지수들을 신경망 입력 패턴의 형태인 0과 1사이의 값으로 정규화 한다. 그러면 네트워크는 입력 패턴으로부터 주가의 변화를 인식한다. 최종적으로 후처리 모듈(postprocessing module)은 인식 결과를 예측가격으로 변환한다.



3.1 입력 데이터

시스템의 입력 패턴을 형성하는 데이터 항목들은 시가, 고가, 저가, 수량, 종가 등이 될 수 있다. 본 논문에서는 가격 지수를 이용해서 선물가를 예측하였고, 이를 각 지수는 전처리 모듈에 의해 신경망 모델의 입력 형태인 0과 1사이의 값으로 정규화 된다.

3.2 신경망 모델

n 개의 유닛을 가진 하나의 입력층과, m 개의 유닛을 가진 s 개의 온닉층, t 개의 출력 유닛을 갖는 하나의 출력층으로 구성되어 있다. 본 논문에서는 전달 함수로 Sigmoid 함수를 사용하였고, 온닉층과 출력층의 예러를 계산 공식은 다음과 같다.

• 출력층의 예러 함수

$$E_{LN-1,j}(t+1) = f'(n_{LN-1,j}(t+1)) \left(o_{(modLN)} - n_{LN-1,j}(t+1) \right)$$

LN : 층의 개수(0번이 입력층, LN-1은 출력층)

• 온닉층의 예러 함수

$$E_{i,j}(t+1) = f'(n_{i,j}(t+1)) \sum_{l=0}^{t-1} \left(w_{i,j \rightarrow i+1,l}(t) \cdot E_{i+1,l}(t+1) \right)$$

$i, j : i$ 번째 층의 j 번째 노드

• Sigmoid 전달 함수

$$f(x) = \frac{1.0}{1.0 + e^{-x}}$$

여기에서 중요한 것은 학습에 사용되는 데이터 선별과 학습율, 모멘텀, 가중치의 초기값과 같은 네트워크의 파라미터, 그리고 n , m , s , t 를 적절하게 잘 조합하는 것이 가장 중요한 문제이다. 본 논문에서는 학습율, 모멘텀, 온닉층의 개수와 온닉노드의 개수를 변화시키는 실험을 통해 가장 정확성이 높고, 효율적인 네트워크를 구성하여 그들을 비교하고, 평가하였다.

3.3 출력 데이터

출력 유닛은 선물가 예측이나 상승, 보합, 하락 신호를 나타낼 수 있다. 본 논문에서 출력 유닛의 값은 선물 예측에 사용되고, 후처리 모듈에 의해 0과 1사이의 값으로 정규화 되어 있는 값들이 주로 변환된다.

4. 실험 및 평가

본 논문의 실험 목적은 선물시장의 과거의 데이터를 이용하여 선물시장에서의 거래 패턴을 찾고 패턴을 기계학습을 시켜 미래의 선물가를 예측하며 그 예측의 정확성을 높이는 것이 목표이며, 이런 목표를 충족하기 위해서는 학습을 시키는 네트워크 구성과 입력 데이터들의 설정이 중요하였다.

실험을 위해 무작위로 네트워크를 설정하여 출력층의 노드수는 1개로 고정시켰으며, 입력층과 각 층의 노드수, 온닉층의 수, 학습율, 허용오차범위, 모멘텀을 변경하면서 다양한 네트워크 구조와 학습 조건을 주어 다수의 네트워크를 구조를 살펴보았으며, 그 중에 학습이 뛰어난 10개의 모델을 선정하여 실험을 했으며, 그 10 가지 모델은 표 1과 같다.

표 1. 실험 네트워크의 구성 예

	온닉층	학습율	오차	모멘텀	정확성
실험 1	15	0.4	0.05	0.9	68%
실험 2	15, 5	0.4	0.05	0.9	74%
실험 3	15, 8	0.4	0.05	0.9	76%
실험 4	15, 8, 6	0.4	0.05	0.9	79%
실험 5	15, 8, 6, 10	0.4	0.05	0.9	83%
실험 6	16, 8, 4	0.4	0.01	0.9	82%
실험 7	9, 3	0.4	0.05	0.9	78%
실험 8	6, 9, 6	0.4	0.01	0.9	80%
실험 9	6, 16, 4	0.4	0.01	0.9	82%
실험 10	5, 10, 4	0.4	0.05	0.9	79%

실험 5의 네트워크 구조와 학습조건이 선물가 예측을 하는데 있어 가장 높은 정확성을 나타내는 것을 확인 할 수가 있었으며, 최종적으로 이 네트워크 구조와 학습조건을 사용하여 5분 간격 데이터와 60분 간격 데이터 두 데이터 집단을 사용하여 실험을 하였으며 그 결과값은 아래 그림과 같이 결과를 확인 할 수 있었다.

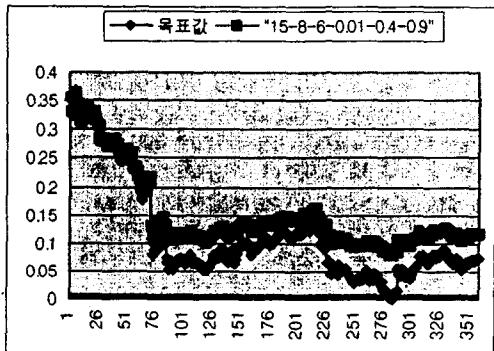


그림 3. 5분봉(시가-저가-고가-종가-수량-종가)

첫 번째 실험은 다음 표 2와 같은 구조를 사용하였으며, 그 결과값은 그림 3과 같은 정확성을 나타내고 있다.

표 2. 실험 I 네트워크 구조

	입력 층	온닉 층	출력 층
노드수	4	15 8 6	1

두 번째 실험은 똑 같은 네트워크 구조와 학습 조건을 동일하게 하였고, 데이터 값을 60분 간격으로 하여 입력하였다.

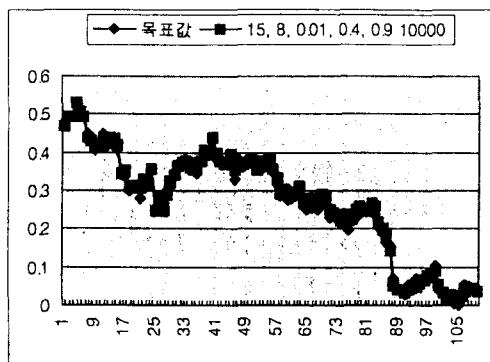


그림 4. 60분봉(시가-저가-고가-수량-종가)

세 번째 실험의 네트워크 구조는 단지 입력층의 노드 수만 변경하였다. 네트워크의 구조는 다음 표3과 같다.

표 3 실험 II 네트워크 구조

	입력층	은닉층	출력층
노드수	3	15 8 6	1

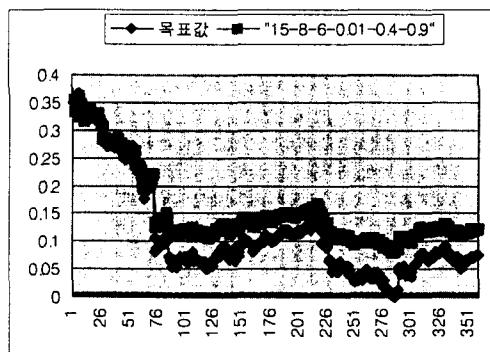


그림 5. 5분봉(시가-저가-고가-종가)

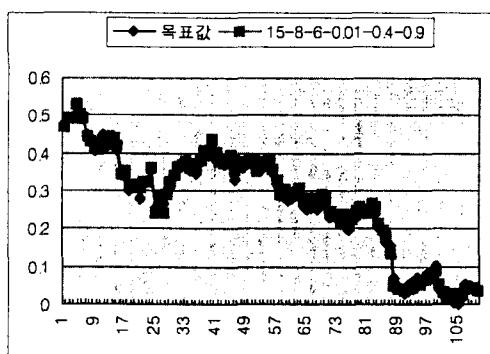


그림 6 60분봉(시가-저가-고가-종가)

위 실험 결과에서 보여주듯이, 5분 간격인 데이터 보다는 60분 간격의 데이터가 효율적인 학습을 통해 정확성을 향상되었음을 볼 수가 있으며, 60분간격 데이터를 사용했을 경우 뛰어난 정확성을 보여주고 있다.

5. 결론 및 추후과제

본 논문에서는 역전파 신경망 모델을 이용하여 실제 선물 시장의 과거 데이터를 사용하여 패턴을 찾고 기계학습을 시켜 미래의 선물 데이터를 예측하는데 신경망 모델을 이용한 L2K 시스템을 사용하여 미래 선물가를 예측의 정확성을 높이는데 목표가 있었다.

이를 위해 다양한 역전파 신경망의 구조와 다양한 데이터 값을 통하여 신경망의 학습능력과 예측성능을 테스트 한 결과 위에 서보았듯이 역전파 알고리즘이 주가 예측에 상당한 정확성을 볼 수가 있었고, 적합하다는 것이 증명되었다.

하지만, 살아있는 생명체처럼 움직이는 선물시장을 예측하기에는 어려움이 많다. 실제 데이터의 패턴보다 시장 원리에 더 많은 영향을 받으며, 외부적인 영향이 선물가에 상당히 많은 영향을 주기 때문이다.

정확한 선물가 예측을 위해서는 보다 많은 데이터와 실제로 영향을 주는 데이터를 분석하고 이를 이용한 실현이 필요하고, 역전파 신경망 네트워크에서는 레이어수와 노드 수를 결정하는 방법이 확실하지 않아 최적의 네트워크 구조를 찾기가 어렵고 최적이라 할 수 없는 문제와, 과도한 학습으로 인한 역효과(Overfitting)를 효과적으로 막을 수 있는 방법이 확실하지 않다는 문제점을 가지고 있다. 이로 인해 단순한 역전파 신경망 모델뿐만 아니라 다른 신경망 모델을 이용한 네트워크의 개발이 요구된다.

참고문헌

- PRING, M.J., Technical Analysis Explained, McGRAW-HILL, 1985.
- BENARD, W., DAVID, E.R. and MICHAEL, A.L., Neural Networks: Applications in Industry, Business and Science, COMMUNICATIONS OF THE ACM, Vol. 37, No. 3, 1994, pp. 313~333.
- WASSERMAN, P.D., Neural Computing: Theory and Practice, VAN NOSTRAND REINHOLD, 1989.
- KIMOTO, T., ASAKAWA, K., YODA, M. and TAKEOKA, M., Stock Market Prediction System with Modular Neural Networks, Proceedings of the 1990 International Joint Conference on Neural Networks, 1990, pp. 1/1-1/6.
- KAMOJO, K. and TANIGAWA, T., Stock Price Pattern Recognition - A Recurrent Neural Network Approach, Proceedings of the 1990 International Joint Conference on Neural Networks, 1990, pp. 1/215-1/221.
- Steve Lawrence and C. Lee Giles, Ah Chung Tsoi., Lessons in Neural Network Training : Overfitting May be Harder than Expected, Proceedings of the Fourteenth National Conference on Artificial Intelligence, AAAI-97, AAAI Press, Menlo Park, California, pp. 540-545, 1997.
- Steve Lawrence and C. Lee Giles., Overfitting and Neural Networks : Conjugate Gradient and Backpropagation, International Joint Conference on Neural Networks, Como, Italy, July 24-27, IEEE Computer Society, Los Alamitos, CA, pp. 114-119, 2000.
- Rumelhart, D. and J. McClelland., Parallel Distributed Processing : Explorations in the Microstructure of Cognition, I & II., Cambridge, MA:MIT Press, 1986.
- Ken-ichi Kamijo and Tetsuji Tanigawa, Stock Price Pattern Recognition - A Recurrent Neural Network Approach,
- Takashi Kimoto and Kazuo Asakawa, Morio Yoda and Masakazu Takeoka, Stock Market Prediction System with Modular Neural Networks,
- Kyoung-jae Kim, Jin-nyoung Huh and Ingoo Han, Trading rule extraction in stock market using the rough set approach,