

## 균등다층연산 신경망을 이용한 금융지표지수 예측에 관한 연구

김 성 곤\*, 김 환 용\*\*

## The Study of the Financial Index Prediction Using the Equalized Multi-layer Arithmetic Neural Network

Seong Gon Kim \*, Hwan Yong Kim \*\*

### 요 약

본 논문에서는 주식의 종가, 거래량, 기술적 지표인 MACD(Moving Average Convergence Divergence) 값과 투자 심리선값을 입력 폐턴으로 사용하여 개별 금융지표지수에 대한 매도, 중립 및 매수 시점 예측을 수행하는 신경망 모델이 제안된다. 이 모델은 역전파 알고리즘을 이용한 시계열 예측 기능과 균등다층연산 기능을 갖는다.

학습 데이터의 수가 각 범주들(매도, 중립, 매수)에 균일하게 분포되어 있지 않을 경우 기존의 신경망은 가장 우세한 범주의 예측 정확성만을 향상시키는 문제점을 가지고 있다. 따라서, 본 논문에서는 신경망의 구조, 동작, 학습 알고리즘에 대해 표현한 후 다른 범주의 예측 정확성도 향상시키기 위해 각 범주의 중요성을 이용하여 학습 데이터의 수를 조절하는 균등다층연산 방법을 제안한다. 실험 결과, 균등다층연산 신경망을 이용한 금융지표지수 예측 방법이 기존의 신경망을 이용한 금융지표지수 예측 방법 보다 각 범주에 대해 높은 정확성 비율을 보임을 확인할 수 있었다.

### Abstract

Many researches on the application of neural networks for making financial index prediction have proven their advantages over statistical and other methods. In this paper, a neural network model is proposed for the Buying, Holding or Selling timing prediction in stocks by the price index of stocks by inputting the closing price and volume of dealing in stocks and the technical indexes(MACD, Psychological Line).

\* 인천기능대학 정보통신시스템과 조교수  
\*\* 원광대학교 전기전자 및 정보공학부 교수

This model has an equalized multi-layer arithmetic function as well as the time series prediction function of backpropagation neural network algorithm. In the case that the numbers of learning data are unbalanced among the three categories(Buying, Holding or Selling), the neural network with conventional method has the problem that it tries to improve only the prediction accuracy of the most dominant category.

Therefore, this paper, after describing the structure, working and learning algorithm of the neural network, shows the equalized multi-layer arithmetic method controlling the numbers of learning data by using information about the importance of each category for improving prediction accuracy of other category. Experimental results show that the financial index prediction using the equalized multi-layer arithmetic neural network has much higher correctness rate than the other conventional models.

▶ Keywords : Neural Network, EMA(Equalized Multi-layer Arithmetic), Prediction

## I. 서 론

신경망은 하나의 정보처리 기술로서 그 기본 개념은 인간 두뇌의 생물학적 작동 형태에 대한 연구에 기반을 둔다. 일반적인 신경망의 이론을 살펴보면 신경망은 일정한 수의 입력을 가지고 특정한 연산 과정을 수행한 후 하나 또는 그 이상의 출력을 산출하는 것으로서 입력과 출력 사이를 연결 시켜 주는 다소 복잡한 공식을 산출해 내는 하나의 방법으로 간주될 수 있다. 이 입력과 출력의 관계를 어떻게 정해 주는가가 좋은 신경망을 구성하는 핵심이며 이 관계 정의 과정을 학습이라고 한다.

여러 개의 입력 값이 기대되는 결과 값과 함께 신경망으로 입력될 경우 신경망은 입력 자료에 대한 연산을 실행한 후 결과 값을 산출하고 산출된 결과 값과 기대되는 결과값을 비교하여 오차가 있으면 신경망은 현재의 정보를 가지고 연결 강도를 변경시키게 되며 점차 오차 확률이 감소하게 된다는 이론이다[1][2][3].

비선형 회귀 분석의 한 종류로서 패턴 인식 등 공학 분야에서 주로 사용되는 신경망 기법은 외국의 경우 1980년대에 처음 금융 분야에 도입되기 시작하였다. 그 이유는 금융 분야의 경우 특히 다양한 정보들을 신속하게 수집하고 정확한 예측을 수행하는 것이 중요하기 때문이다. 따라서 최근 들어 이러한 노력들이 경영 및 금융분야에 까지도 이어져 선진 금융 시장에서는 신경망을 이용한 금융 기법의 개발에 전력을 다하여 신경망이 채권 선물의 이율 예측, 외채의 이율 예측, 외환 시세 예측, 금융지표지수시장 예측 등 의 예측 문제들에 대해 응용되고 있다[4][5][6].

그 중에서 일부 제안된 모델들은 미래의 금융지표지수 변동의 특성을 갖는 금융지표지수 패턴들을 인식하기 위해 적용되고 있지만 이들 모델들에서 신경망의 학습 방법에 대해서는 거의 고려되지 않고 있습니다.

따라서, 학습 샘플의 수가 정해진 범주들 사이에서 균일하게 분포되어 있지 않은 경우에 일반 학습 방법을 갖는 신경망 모델은 가장 우세한 범주의 예측 정확성만을 향상시키기 위해 학습을 시도하여 결과들이 정확한 예측을 수행하는 데 있어서는 불충분하다는 문제점을 가지고 있다[7][8][10].

본 논문에서는 여러 가지 변수를 입력 패턴(시가, 고가, 저가, 종가, 거래량, MACD, 투자 심리선)으로 하는 균등다층연산 신경망을 이용해 개별 금융지표지수에 대해 매도, 중립, 매수 시점을 예측하는 시스템을 구현 하는 것이다. 또한 기존의 학습 방법을 갖는 신경망 모델과의 시뮬레이션 비교를 통해서 정확성 비율에 대한 상대적 유용성을 살펴보고자 한다.

본 논문에서는 기본적으로 2002년 5월 3일부터 2003년 3월 3일까지의 금융지표지수 자료를 학습 샘플로 사용하고, 2003년 3월 4일부터 2003년 6월 12일까지의 자료를 예측 샘플로 사용한다. 학습 샘플이 신경망에 제공되기 전에 분류 단계, 균등 단계, 랜덤 단계, 출력 단계 네 단계를 수행한 후 세 범주(매도, 중립, 매수) 신호를 균일하게 분포하여 가장 우세한 중립 신호의 예측 정확성만을 향상시키지 않고 적절한 시점에서 매도와 매수 신호를 더 많이 발생시켜 예측 정확성을 향상시키는 것이다.

본 논문의 2장에서는 신경망 알고리즘과 신경망 금융지표지수 예측 기법을 소개하였고 3장에서는 제안된 균등다층연산 기법과 이 기법을 이용한 금융지표지수 예측 시스템에 대해 설명하였다. 4장에서는 본 논문에서 제안된 기법과 기존 기법의 성능을 비교하여 그 결과를 제시하였으며 5장에서는 결론을 맺었다.

## II. 신경망 금융지표지수 예측의

### 이론적 배경

#### 2-1. 신경망 알고리즘

뇌와 신경계를 연구함으로써 영감을 얻는 신경망은 학습 사례로부터 구축되고 여러 층을 가진 망으로 표현될 수 있는 지식영역 기술이다.

신경망 모델은 학습 방법에 따라 지도학습(Supervised Learning)과 비지도 학습(Unsupervised Learning)으로 분류할 수 있다. 지도 학습은 신경망에 입력되는 데이터와 대응되는 지도 데이터를 같이 입력하여 지도 데이터에 근거한 학습을 수행하며, 비지도 학습은 지도 데이터 없이 입력 데이터만으로 학습을 수행한다.

지도 학습에 속하는 모델로는 단층퍼셉트론(Simple Perceptron), 다층퍼셉트론(Multi-layer Perceptron), 흡필드(Hopfield) 네트워크 등이 있다.

비지도 학습에 속하는 모델로는 카펜터-그로스버그(Carpenter - Grossberg), 코호넨(Kohonen)의 자기 조직화 형상지도(Self organizing feature map) 등이 있다 [1][2].

신경망 모델의 한 종류로서 지도 학습에 의한 예측 시스템에 일반적으로 널리 사용되는 다층퍼셉트론은 <그림 1>과 같이 자료가 입력되는 입력층(Input Layer), 결과를 출력하는 출력층(Output Layer), 입력층과 출력층 사이에 중간층인 은닉층(Hidden Layer)으로 구분되어진 계층 구조이다.

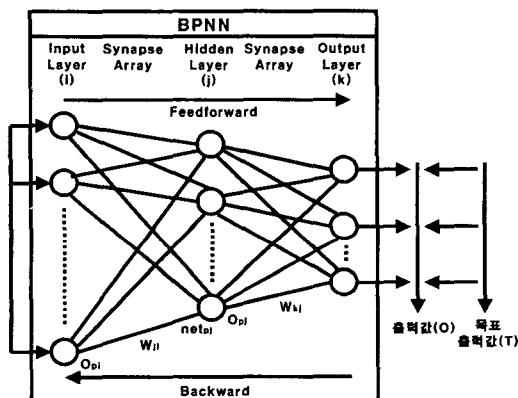


그림 1. 디층퍼셉트론의 구조  
Fig. 1 The structure of multi-layer perceptron

다층퍼셉트론의 학습 방법은 입력층의 각 유니트에 입력 데이터를 제시하면 이 신호는 각 유니트에서 변환되어 중간층에 전달되고 최종적으로 출력층으로 나오게 된다. 이 출력값과 목표 출력값을 비교하여 그 차이를 감소시키는 방향으로 연결 강도를 조정하는 것이다. 각 층에서 다음 층으로의 출력은 특정한 변환 함수에 의해서 이루어진다. 다층퍼셉트론에서는 변환 함수로서 시그모이드 함수(Sigmoid Function)를 사용한다.

시그모이드 함수는 유계 함수(Bounded function), 단조증가함수(Montone Increasing Function), 연속 함수(Continuous Function)와 같은 세 가지 특성을 만족해야 하므로 식 (1)과 같은 로지스틱 함수(Logistic Function)나 식 (2)과 같은 하이퍼볼릭 탄젠트 함수(Hyperbolic Tangent Function)가 사용된다.

$$f(x) = \frac{1}{(1 + e^{-x})} \quad \dots \dots \dots (1)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad \dots \dots \dots (2)$$

로지스틱 함수와 하이퍼볼릭 탄젠트 함수의 형태는 <그림 2>와 같다.

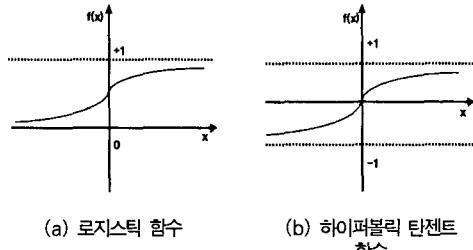


그림 2. 시그모이드 함수  
Fig. 2 Sigmoid function

신경망 기법 중에서 가장 널리 이용되고 있는 역전파 학습 알고리즘의 기본 원리는 입력층의 각 유니트에 입력 패턴을 주면 이 신호는 각 유니트에서 변환되어 중간층에 전달되고 최후에 출력층에서 신호를 출력하게 된다. 이 출력값과 기대값을 비교하여 오차를 줄여 나가는 방향으로 연결 강도를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결 강도를 조정해나간다. 지도 학습에서는 입력 및 원하는 목표 출력 패턴이 네트워크에 제시된다. 네트워크는 입력층에 주어진 입력 패턴이 출력층에 전파되면서 변한 출력 패턴을 목표 패턴과 비교한다.

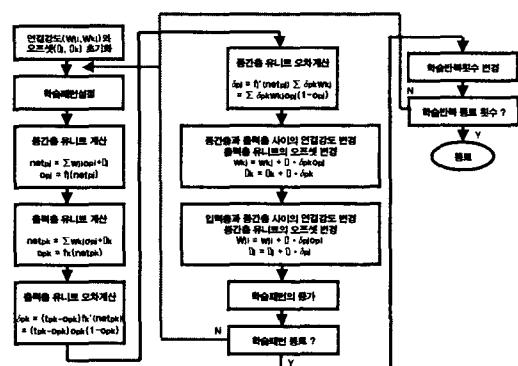


그림 3. 역전파 학습 알고리즘의 학습 과정  
Fig. 3 The learning process of backpropagation learning algorithm

네트워크에서 출력된 패턴이 목표 패턴과 일치하는 경우에는 학습이 일어나지 않고 일치하지 않는 경우에는 얻어진 출력 패턴과 목표 패턴의 차이를 감소시키는 방향으로 네트워크의 연결 강도를 조절하여 학습을 수행한다. 이에 대한 역전파 학습 알고리즘의 학습 과정은 <그림 3>과 같다 [4][5][6].

#### 2-2. 신경망 금융지표지수 예측 기법

개별 금융지표지수에 대해 매도, 중립 및 매수 시점 예측 시스템의 개요는 <그림 4>에 나타나 있다.

예측 시스템은 시가, 고가, 저가, 종가, 거래량으로 구성된 입력 데이터를 입력 패턴으로 분류하고 매도, 중립 및 매수 시점을 발생시킨다.

신경망의 출력 패턴은 <표 4>에 나타난 것처럼 세 개의 패턴으로 정의한다.

표 4. 신경망의 출력 패턴 정의

Table. 1 The output pattern definition of neural network

금융지표지수 곡선			신경망 출력 패턴
과 거 금융지표 지 수	현 재 금융지표 지 수	미래 금융지표 지 수	
상승	유지	하강	(1, 0, 0) : 매도신호
상승	유지	상승	
하강	유지	하강	(0, 1, 0) : 종립신호
하강	유지	상승	(0, 0, 1) : 매수신호

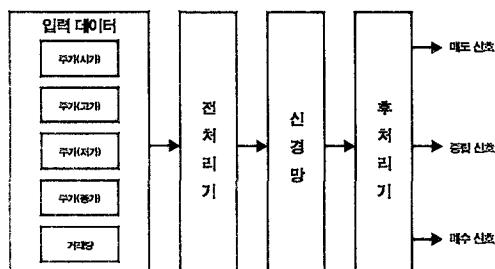


그림 4. 신경망 금융지표지수 예측 시스템의 구조  
 Fig. 4 The structure of the prediction system of the neural network financial index

<그림 4>에 나타난 바와 같이 시스템은 전처리기, 신경망, 후처리기로 구성된다. 전처리기는 신경망으로 입력 패턴을 제공하기 위해 학습용 데이터는 식 (3)의 정규화 함수(Normalized Function)를 사용하여 0 ~ 1 사이로 정규화하였다[9][10][11].

$$X_i^N = \frac{X_i - X_{MIN}}{X_{MAX} - X_{MIN}} \dots \dots \dots \quad (3)$$

그 후 예측 모델로서의 신경망은 입력 패턴으로부터 금융지표지수 곡선의 전환점을 인식하기 위해 입력층, 은닉층, 출력층으로 구성된 계층 네트워크로서 네트워크 내에 있는 각 유니트는 인접한 층에 있는 모든 유니트에 연결되어 하위층 유니트의 출력을 수신하여 총 입력을 결정하기 위해 연결강도 합을 계산하고 총 입력에 대해 로지스틱 함수를 적용함으로써 출력이 결정된다. 결정된 출력 데이터는 0 ~ 1 사이의 아날로그 값이다.

각각의 출력 패턴은 금융지표지수 곡선 패턴에 상응하여 다음과 같이 나타난다. 현재 금융지표지수가 미래 금융지표지수에 대해 위에 있으면 매도 신호, 현재 금융지표지수가 아래에 있으면 매수 신호, 어떠한 변화도 없을 시에는 중립 신호를 출력한다. 금융지표지수 곡선에서 미래 금융 지표지수에 대한 현재 금융지표지수의 상승과 하강 상태는 매도, 중립, 매수 시점과 밀접하게 관련되어 있다.

신경망 모델을 훈련시킬 때 학습 샘플의 출력 패턴은 세 가지 데이터인 5일전의 과거 금융지표지수, 현재 금융지표지수, 5일 후의 미래 금융지표지수에 의해서 계산된다. 신경망의 출력층에서 출력된 데이터는 0 ~ 1 사이의 아날로그 값이기 때문에 실질적인 출력 패턴은 세 개의 신경망 출력 패턴인 매도, 중립 및 매수 신호가 아니다. 따라서, 후처리기는 이 아날로그 값을 두 개의 문턱 값을 이용하여 '0' 또는 '1'의 값으로 전환시킨다. 출력이 0.4 값 미만에 있을 때에는 '0'이 설정되고 0.6 값 이상일 경우에는 '1'이 설정되고 0.4 ~ 0.6 값 사이에 있거나 전환된 패턴이 세 개의 범주에 속하지 않을 시에는 예측이 실패한 것으로 설정된다. 따라서, 후처리기는 인식 결과를 매도, 중립 및 매수 시점 신호로 전환시키는 기능을 수행한다[5][6][11].

### III. 제안된 신경망 금융지표지수 예측 개선 기법

#### 3-1. 제안된 균등다층연산 기법의 개요

신경망 금융지표지수 예측 시스템에서 학습 방법은 예측 정확성을 향상시키기 위해 개발되고 있다. 2장에서 나타낸 바와 같이 신경망 모델은 출력 패턴을 분류하기 위해 세 가지 출력 패턴(매도, 중립, 매수) 중에서 하나를 발생시킨다. 신경망의 학습 방법은 역전파 알고리즘을 이용한다. 이 알고리즘에서의 학습 방법은 예측 에러의 총합을 감소시키는 방향으로 유니트 사이의 연결강도를 조정해 나가는 것이다.

그러나, 학습 샘플 수의 편차가 출력 패턴 범주들(매도, 중립, 매수) 간에 클 경우에는 신경망은 가장 우세한 범주의 예측 정확성만을 향상 시키려고 시도하는 경향이 있다. 때문에 신경망 예측 시스템은 예상했던 것 보다 훨씬 우세한 범주에 비해 다른 범주를 덜 발생시킨다. 이것은 범주들에 대한 중요성의 정도가 거의 고려되지 않았기 때문이다. 이와 같은 문제점을 해결하기 위해 본 논문에서는 <그림 5>와 같이 균등다층연산 기법의 단계를 제안한다.

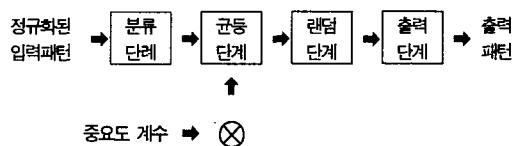


그림 5. 균등다층연산 기법의 단계  
Fig. 5 The step of equalized multi-layer arithmetic

<그림 5>에 나타난 바와 같이 학습 샘플이 신경망에 제공되기 전에 분류 단계, 균등 단계, 랜덤 단계, 출력 단계 네 단계를 수행한다. 분류 단계는 각 범주 내에 속하는 학습 샘플의 수를 계산하는 과정, 균등 단계는 각 범주의 중요성의 정보를 이용함으로써 각 범주에 속한 학습 샘플의 수를 비슷하게 만드는 과정, 랜덤 단계는 균등 단계에서 계산된 학습 샘플을 불규칙하게 분포하는 과정, 출력 단계는 랜덤 단계에서 불규칙하게 분포된 학습 샘플을 신경망에 제공하는 과정이다.

균등 단계에서 범주의 중요성 정도가 크면 클수록 계수는 더 커진다. 금융지표지수 예측 시스템에서 매도와 매수 신호의 범주가 중립 신호의 범주보다 훨씬 더 중요한 데도 불구하고 매도와 매수 신호의 학습 샘플이 중립 신호의 학습 샘플보다 더 적다. 그러므로 균등 단계에서 매도와 매수 신호의 범주에 계수를 더 크게 설정할 필요가 있다. 이 계수의 설정은 세 범주를 비슷하게 설정해주면 된다. 따라서, 금융지표지수 예측 시스템은 적절한 시점에서 매도와 매수 신호를 더 많이 발생시킬 수 있다.

#### 3-2. 제안된 신경망 금융지표지수 예측 시스템

본 논문에서 제안된 균등다층연산 기법을 적용한 신경망 금융지표지수 예측 시스템의 개요는 <그림 6>에 나타나 있다. 이 시스템은 전처리기로 입력되어 입력 패턴을 형성하기 위해 시가, 고가, 저가, 종가, 거래량과 기술적 지표로서 종기를 기반으로 계산된 MACD(Moving Average Convergence Divergence) 값과 투자 심리선(Psychological Line) 값 을 입력 데이터로 설정한다.

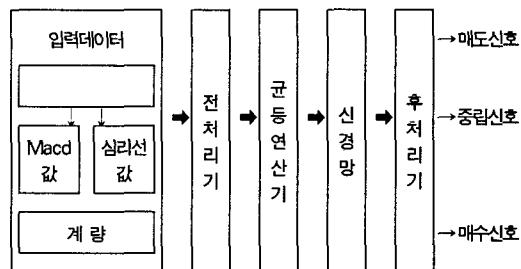


그림 6. 제안된 신경망 금융지표지수 예측 시스템  
Fig. 6 The prediction system of the proposed neural network financial index

여기서, 본 논문에서 적용한 기술적 지표인 이동 평균선, MACD, 투자 심리선에 대해 간단히 설명을 하면 다음과 같다. 이동 평균선은 그랜빌이 고안해낸 투자 전략으로서 일정 기간의 금융지표지수를 평균화한 것으로 전체적인 금융지표지수의 흐름을 관찰할 수 있기 때문에 매매 시점을 포착하는 방법이다. MACD는 제리드 아펠에 의해서 고안된 것으로 현재 금융지표지수 추세를 보다 정확하게 파악하고 향후의 추세 변화를 미리 감지하기 위해 사용되고 있으며 이 지표는 장기 이동 평균선과 단기 이동 평균선의 차이를 통해서 매도 및 매수 시점을 파악할 수 있다. 투자 심리선은 주식 시장에 대한 인기의 변화, 즉 투자 심리의 변화를 일정기간 동안 파악하여 과열 상태인지, 침체 상태인지를

알아보는 지표라고 할 수 있다. 계산 방법은 최근 10일 동안의 금융지표지수 중 상승한 일수와 하락한 일수를 계산해서 상승한 일수가 차지하는 비율로 나타낸다. 예를 들어, 10일 중에 금융지표지수가 상승한 날이 8일이라면 투자 심리선은 80%가 되는 것이고 상승한 날이 5일이라면 50%가 되는 것이다. 일반적으로 이 지표가 80% 이상이 되면 과열 상태로 경계지대, 20% 이하면 침체 상태로 안전지대로 평가된다. 기술적 지표인 단기(5일) 및 장기(15일) 이동 평균선, MACD, 10일 투자 심리선을 수식으로 나타내면 식 (4), 식 (5), 식 (6)과 같다.

$$5MA(\text{단기 이동평균선}) = \frac{1}{5} \times \sum_{t=1}^5 C_{t-i+1}, \dots \quad (4)$$

$$15MA(\text{장기 이동평균선}) = \frac{1}{15} \times \sum_{t=1}^{15} C_{t-i+1}$$

$$MACD = 5MA(\text{단기 이동평균선}) - 15MA(\text{장기 이동평균선}) \quad \dots \quad (5)$$

$$\text{투자 심리선}(10일) = \frac{1}{10} \times \sum_{t=1}^{10} UD_{t-i+1} \quad \dots \quad (6)$$

$(UD_i = 1 \text{ if } C_i > C_{i-1}, 0 \text{ if } C_i \leq C_{i-1})$

<그림 6>에 나타난 바와 같이 전처리기에 대한 입력 데이터로서 시가, 고가, 저가, 종가, 거래량과 종기를 기반으로 식 (4), 식 (5), 식 (6)으로 계산된 기술적 지표인 MACD 값과 투자 심리선 값이 전처리기에 입력되어 식 (7)의 정규화 함수를 사용하여 0 ~ 1 사이의 값으로 정규화하였다.

$$X_i^N = \left( \frac{X_i - X_{MIN}}{X_{MAX} - X_{MIN}} - 0.5 \right) * 2.0 \quad \dots \quad (7)$$

식 (7)을 이용하여 출력된 정규화된 입력 패턴은 균등다중 연산기에 입력되어 <그림 5>에서 나타낸 분류, 균등, 랜덤, 출력의 네 단계를 거쳐 신경망으로 입력시키기 위한 입력 패턴을 생성한다. 신경망의 학습은 <그림 3>에서 나타낸 역전파 학습 알고리즘을 이용하여 수행한다. 활성함수는 선형함수, 로지스틱 함수, 하이퍼볼릭 탄젠트 함수 중에서 선택 가능하며 최대 학습 반복수, 학습 파라미터, 은닉층도 조정하여 적용할 수 있도록 하였다. 신경망에서 출력된 데이터는 0 ~ 1 사이의 아날로그 값이기 때문에 실질적인 세 개의 출력 패턴(매도 신호, 중립 신호, 매수 신호)을 출력하기 위해 후처리기에 입력되어 출력이 0.5 값 미만에 있을 때에는 '0' 값으로 설정하고 0.5 값 이상일 경우에는 '1' 값

으로 설정한 후 세 개의 데이터(과거 데이터, 현재 데이터, 미래 데이터)를 비교하여 과거 데이터가 '1', 현재 데이터가 '0', 미래 데이터가 '0'인 경우에는 강세 매도 신호를 출력하고 과거 데이터가 '1', 현재 데이터가 '1', 미래 데이터가 '0'인 경우에는 약세 매도 신호를 출력한다. 과거 데이터가 '0', 현재 데이터가 '0', 미래 데이터가 '1'인 경우에는 강세 매수 신호를 출력하고 과거 데이터가 '0', 현재 데이터가 '1', 미래 데이터가 '1'인 경우에는 약세 매수 신호를 출력한다. 과거 데이터가 '0', 현재 데이터가 '1', 미래 데이터가 '0'인 경우에는 강세 중립 신호를 출력하고 과거 데이터가 '0', 현재 데이터가 '0', 미래 데이터가 '0'인 경우에는 약세 중립 신호를 출력한다. 과거 데이터가 '1', 현재 데이터가 '0', 미래 데이터가 '1'인 경우와 과거 데이터가 '1', 현재 데이터가 '1', 미래 데이터가 '1'인 경우에는 불가 신호를 출력한다.

#### IV. 모의 실험 및 검증

본 논문에서 제안된 신경망 금융지표지수 예측 시스템의 정확성을 검증하기 위해 대우건설의 일 단위 주식을 실질적으로 적용하여 모의 실험을 수행하였다. <그림 7>은 실험 데이터에 대해 표 1에 정의된 방법에 따라 컴퓨터에서 발생시킨 정확한 매도, 중립, 매수 시점의 출력 패턴 그래프를 나타낸다.

<그림 7>에서 나타낸 바와 같이 2002년 5월 3일부터 2003년 3월 3일까지의 205일 데이터가 금융지표지수의 매도, 중립 및 매수 시점의 예측 모델을 만들기 위한 학습 샘플로 사용되었고 2003년 3월 4일부터 2003년 6월 12일까지의 69일 데이터가 금융지표지수의 매도, 중립 및 매수 시점의 평가를 위한 예측 샘플로 사용되었다. 개별 금융지표지수의 종기를 기반으로 식 (4), 식 (5), 식 (6)에서 계산된 기술적 지수인 MACD 값과 투자 심리선 값이 입력 패턴을 형성하기 위해 사용된다. 차후 더욱 정확한 예측을 위해 RSI(Relative Strength Index), OBV(On Balance Volume), Momentum, VR(Volume Ratio) 등과 같은 더 많은 기술 지수가 첨가될 예정이다. <그림 7>의 모의 실험에서 발생된 대우 건설 주식에 대한 출력 패턴은 <표 2>와 같다.

표 2. 모의 실험 결과 발생된 정확한 출력 패턴  
Table. 2 The produced correct output pattern of simulation result

출 력	샘 풀	학습 샘풀	예측 샘풀
매 도	37(28.03%)	6(31.58%)	
중 립	66(50%)	9(47.37%)	
매 수	29(21.97%)	4(21.05%)	
총 합	132	19	

본 논문에서 제안한 균등다층연산 기법을 적용한 신경망 금융지표지수 예측 시스템은 대우건설의 모의 실험 데이터에 대해 균등 단계에서 중요도 계수를 매도 신호에 대해서

는 23, 중립 신호에 대해서는 13, 매수 신호에 대해서는 20으로 설정하여 곱하였다. 신경망의 네트워크에 대해 입력 층에는 4개의 유니트, 은닉층에는 12개의 유니트, 출력층에는 3개의 유니트로 구성하였으며 시그모이드 함수는 하이퍼볼릭 탄젠트 함수로, 학습 반복 수는 10,000번으로 설정하였다. 또한 후처리기에서 매도 신호, 중립 신호, 매수 신호를 결정하기 위해 신경망의 0 ~ 1 사이의 범위 내에 있는 아날로그 출력을 '0' 또는 '1'의 디지털 값으로 변환하기 위해 기준값을 '0.5'로 설정하였다. 기존의 일반적인 방법의 신경망 금융지표지수 예측 시스템과 본 논문에서 제안한 신경망 금융 지표지수 예측 시스템의 학습 및 예측 결과를 비교한 것이 (표 3)과 같다.

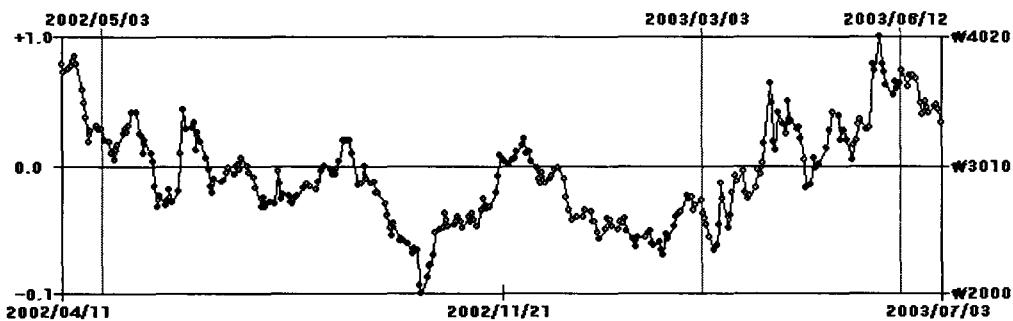


그림 7. 출력 패턴 그래프(대우건설의 일 단위 주식)  
Fig. 7 The output pattern graph(the per day stock price of Daewoo construction)

표 3. 기존의 방법과 제안된 방법의 결과 비교  
Table. 3 The output compare of the conventional method and the proposed method

	기존방법(학습)			기존방법(예측)			제안방법(학습)			제안방법(예측)		
	매도	중립	매수									
매도	37	2	4	6	13	6	40	19	3	20	17	7
중립	10	66	20	0	9	7	7	47	6	2	7	6
매수	1	15	29	0	1	4	3	20	42	0	2	4
불가	3	11	7	17	5	1	1	8	9	1	2	1
총합	51	94	60	23	28	18	51	94	60	23	28	18

기존의 방법을 갖는 신경망 금융지표지수 예측 시스템은 표 3에 나타난 바와 같이 학습에서는 매도 신호에 대한 정확성 비율이 72.55%이고 중립 신호에 대한 정확성 비율이 70.21%이고 매수 신호에 대한 정확성 비율이 48.33%이다.

또한 학습에 대한 총 정확성 비율은 64.39%이다. 예측에서는 매도 신호에 대한 정확성 비율이 26.09%이고 중립 신호에 대한 정확성 비율이 32.14%이고 매수 신호에 대한 정확성 비율이 22.22%이다. 또한 예측에 대한 총 정확성 비율은 27.54%이다. 여기서, 학습에서 매수 신호에 대한 정확성 비율은 총 정확성 비율에 비해 16.06% 낮게 나타나고 예측에서 매수 신호에 대한 정확성 비율은 총 정확성 비율에 5.32% 낮게 나타난다. 그 이유는 신경망이 중립 신호에 대해서만 비중을 가지고 학습을 수행하기 때문이다.

이와 같은 문제점을 해결하기 위해 제안된 신경망 금융지표지수 예측 시스템은 표 3에 나타난 바와 같이 학습에서는 매도 신호에 대한 정확성 비율이 78.43%이고 중립 신호에 대한 정확성 비율이 50%이고 매수 신호에 대한 정확성 비율이 70%이다. 또한 학습에 대한 총 정확성 비율은 62.93%이다. 예측에서는 매도 신호에 대한 정확성 비율이 86.96%이고 중립 신호에 대한 정확성 비율이 25%

이고 매수 신호에 대한 정확성 비율이 22.22%이다. 또한 예측에 대한 총 정확성 비율은 44.93%이다. 여기서, 학습에서 매수 신호에 대한 정확성 비율은 총 정확성 비율에 비해 7.07% 높게 나타나고 예측에서 매수 신호에 대한 정확성 비율은 총 정확성 비율에 비해 22.71% 낮게 나타난다. 따라서 두 방법의 결과를 비교하면 학습에 대해서는 제안된 방법이 기존의 방법에 비해 매도 신호와 매수 신호가 5.88%와 21.67% 상승하였고 중립 신호는 20.21% 하락하였으며, 예측에 대해서는 제안된 방법이 기존의 방법에 비해 매도 신호가 60.87% 상승하였고 중립 신호는 7.14% 하락하였으며 매수 신호에 대해서는 현 상태를 유지하였다. 또한 학습에 대해서는 총 정확성 비율을 비교해 보면 제안된 방법이 기존의 방법에 비해 1.46% 하락하였으며, 예측에 대해서는 총 정확성 비율을 비교해 보면 제안된 방법이 기존의 방법에 비해 17.39% 상승하였다. 이와 같이 시뮬레이션 결과를 전체적으로 살펴보면 제안된 방법이 기존의 방법에 비해 훨씬 성능이 뛰어남을 알 수 있다. 이에 대해 기존의 신경망 금융지표지수 예측 시스템과 제안된 신경망 금융지표지수 예측 시스템의 매도, 중립 및 매수 신호에 대한 시뮬레이션 결과를 <그림 8>과 <그림 9>에 나타낸다. 여기에서 적색 점은 매도 신호, 녹색 점은 중립 신호, 청색 점은 매수 신호를 나타낸다.

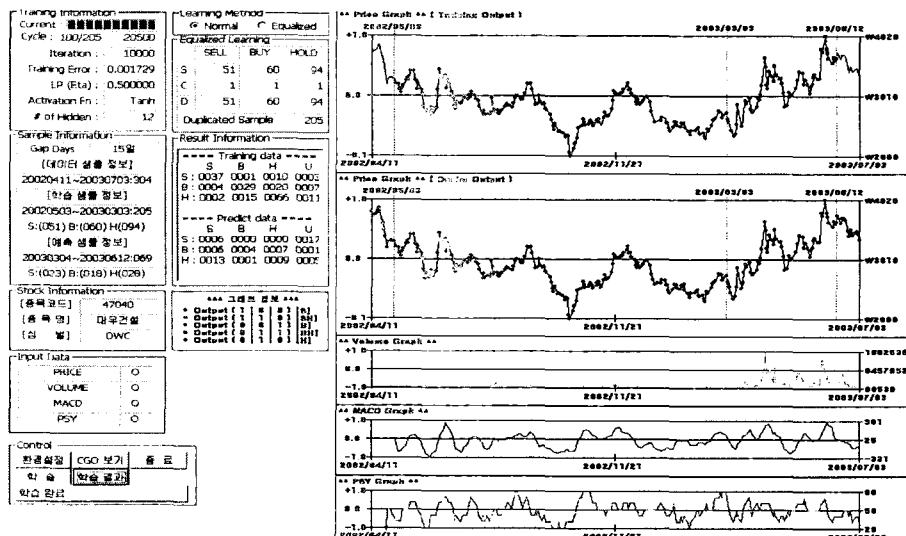


그림 8. 기존의 신경망 금융지표지수 예측 시스템의 시뮬레이션 결과  
Fig. 8 The simulation result of the prediction system of the conventional neural network financial index

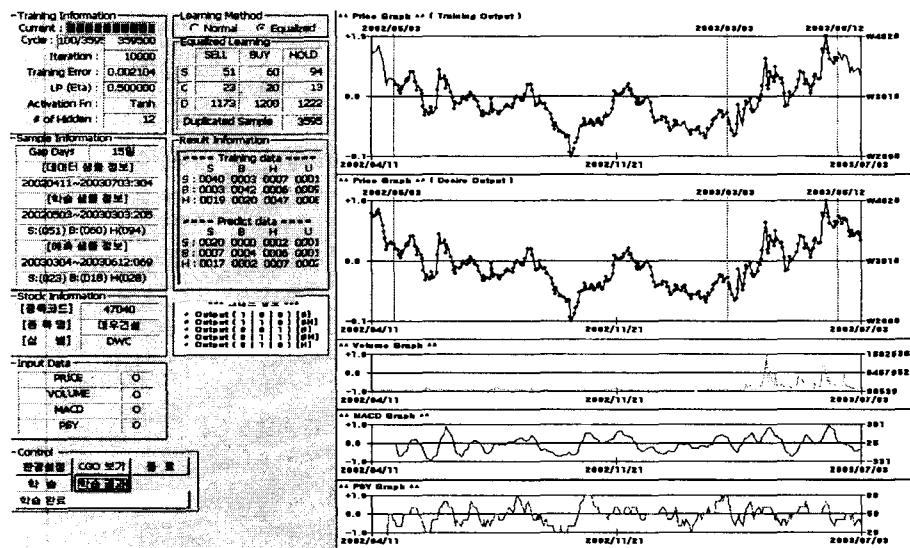


그림 9. 제안된 신경망 금융지표지수 예측 시뮬레이션 결과  
Fig. 9 The simulation result of the prediction system of the neural network financial index

본 논문은 더 중요한 범주의 예측 정확성을 향상시키기 위한 학습 방법을 제안한다. 이 방법은 학습 샘플의 수가 각 범주의 중요성에 대한 정보를 이용함으로써 조절된다.

4장에서 모의실험을 위한 실질적인 데이터로 2002년 5월 3일부터 2003년 3월 3일까지의 금융지표지수 자료를 학습 샘플로 사용하고, 2003년 3월 4일부터 2003년 6월 12일까지의 자료를 예측 샘플로 사용한 시뮬레이션 결과를 살펴보면 학습에 대해서는 제안된 방법이 기존의 방법에 비해 매도 신호와 매수 신호가 5.88%와 21.67% 상승하였고 중립 신호는 20.21% 하락하였으며, 예측에 대해서는 제안된 방법이 기존의 방법에 비해 매도 신호가 60.87% 상승하였고 중립 신호는 7.14% 하락하였으며 매수 신호에 대해서는 현 상태를 유지하였다. 또한 학습에 대해서는 총 정확성 비율을 비교해 보면 제안된 방법이 기존의 방법에 비해 1.46% 하락하였으며, 예측에 대해서는 총 정확성 비율을 비교해 보면 제안된 방법이 기존의 방법에 비해 17.39% 상승하였다. 이와 같이 시뮬레이션 결과를 전체적으로 비교해 보면 적절한 시점에서 매도 및 매수 신호를 발생시킨다는 것을 검증하였으며 기존의 방법에 비해 더 높은 정확성 비율을 만들어 개별 금융지표지수에 대해 매도, 중립, 매수 시점에 대한 예측 정확성을 향상시켰다는 것을 알 수 있다.

## V. 결 론

본 논문에서는 균등다층연산 신경망을 이용하여 개별 금융지표지수에 대해 매도, 중립, 매수 시점을 예측하는 기법을 제안하였다. 여기서 말하는 균등다층연산 신경망이란 학습 샘플이 신경망에 제공되기 전에 분류 단계, 균등 단계, 랜덤 단계, 출력 단계 네 단계를 수행한 후 세 범주(매도, 중립, 매수) 신호를 균일하게 분포하여 가장 우세한 중립 신호의 예측 정확성만을 향상시키지 않고 적절한 시점에서 매도와 매수 신호를 더 많이 발생시켜 예측 정확성을 향상시키는 방법이다. 본 논문에서는 입력 패턴으로 시가, 고가, 저가, 종가, 거래량을 사용하였으며, 종가를 기반으로 하여 기술적 지표인 MACD 값과 투자 심리선 값을 구하여 이 값들 또한 입력 패턴으로 사용하였다. 학습 샘플의 수가 세 범주 내에 균일하게 분포되어 있지 않은 경우에 기존의 학습 방법을 갖는 신경망 모델은 가장 우세한 범주의 정확성만을 향상시키기 위해 시도하는 경향이 있다.

## 참고문헌

- [1] Alianna J., Craig T.& Robert M., *Handbook of Neural Computing Applications*, Academic Press, Inc., San Diego, 1990.
- [2] Laurence Fausett, *Fundamentals of Neural Networks*, Prentice-Hall, Inc., New Jersey,
- [3] Laura I., "Neural Networks and Operations Research : An Overview," *Computers & Operations research*, Vol. 19, No.3/4, pp. 179-189, 1992.
- [4] Wong, B.K., Bonovich, T.A., Selvi, Y., *Neural Networks Applications in Business: A Review and Analysis of the literature (1988-95)*, *Decision Support Systems*, vol. 19, pp. 301-320, 1997.
- [5] Kamijo, K., & Tanigawa, T. (1990). Stock price pattern recognition : A recurrent neural network approach.  
Proceedings of the International Joint Conference on Neural Networks (pp. 215-221).  
San Diego, California .
- [6] Kitaek Kwon, "Forecasting Using Internal Neural Networks : Application to Demand Forecasting," *Journal of the Korean Institute of Industrial Engineers*, Vol. 20, No. 4, pp. 135-149.
- [7] Sharda, R. & Patail, R.B., "Neural networks as forecasting experts : an empirical test," *International Joint Conference on Neural Networks*, II, pp. 3-34, 1989.
- [8] Werbos, P.J., "Generalization of back-propagation with application to a recurrent gas market model," *Neural Networks*, 1, pp. 339-356, 1988.
- [9] Li, E.Y., *Artificial Neural Networks and Their Business Applications*, *Information & Management*, vol. 27, pp. 303-313, 1994.
- [10] Schoeneburg, E., *Stock Price Prediction Using Neural Networks: A Project Report*, *Neurocomputing*, VOL. 2, pp. 17-27, 1990.
- [11] Kimoto, T., Asakawa, K., Yoda, M., & Takeoka, M.(1990). Stock market prediction system with modular neural network. *Proceedings of the International Joint Conference on Neural Networks*(pp. 1 - 6). San Diego, California.

## 저자소개



**김 성 곤**  
 1991. 2 원광대학교 전자공학과  
 (공학사)  
 1996. 2 원광대학교 대학원 전자  
 공학과(공학석사)  
 1999. 2 원광대학교 대학원 전자  
 공학과(박사수료)  
 1997. 2 ~ 현재  
 인천기능대학 정보통신시  
 스템과 조교수  
 <관심분야> 신호처리, 멀티미디어  
 통신, 신경망

**김 환 용**  
 1974. 2 전북대학교 전자공학과  
 (공학사)  
 1978. 2 전북대학교 대학원 전자  
 공학과(공학석사)  
 1984. 2 전북대학교 대학원 전자  
 공학과(공학박사)  
 1979. 3 ~ 현재  
 원광대학교 전기전자 및  
 정보공학부 교수  
 2003. 3 ~ 현재  
 원광대학교 공과대학장  
 <관심분야> 신호처리, 이동통신