

# 인공신경망 앙상블을 이용한 옵션 투자예측 시스템

이재식<sup>†</sup> · 송영균<sup>†</sup> · 허성희<sup>‡</sup>

<sup>†</sup>아주대학교 경영대학 교수,

(Tel) 031-219-2719, (Fax) 031-219-2190, (E-mail) leejsk@madang.ajou.ac.kr

<sup>‡</sup>현대정보기술 SM본부 정보기술 1실

## A Forecasting System for KOSPI 200 Option Trading using Artificial Neural Network Ensemble

Jae Sik Lee<sup>†</sup> · Young Kyun Song<sup>†</sup> · Soung Hoi Heo<sup>‡</sup>

### 요 약

After IMF situation, the money market environment is changing rapidly. Therefore, many companies including financial institutions and many individual investors are concerned about forecasting the money market, and they make an effort to insure the various profit and hedge methods using derivatives like option, futures and swap. In this research, we developed a prototype of forecasting system for KOSPI 200 option, especially call option, trading using artificial neural networks(ANN). To avoid the overfitting problem and the problem involved in the choice of ANN structure and parameters, we employed the ANN ensemble approach. We conducted two types of simulation. One is conducted with the hold signals taken into account, and the other is conducted without hold signals. Even though our models show low accuracy for the sample set extracted from the data collected in the early stage of IMF situation, they perform better in terms of profit and stability than the model that uses only the theoretical price.

Key words : Option Trading, Neural Network Ensemble, Forecasting

### 1. 서 론

국제자본시장은 1980년대 이래로 그 기능과 규모가 급속히 확대되고, 국내외적으로 경제의 운용을 시장경제에 맡김으로써 효율성을 제고시킬 수 있다는 논리에 따라 국내에서도 시장 자율화와 개방화가 급속도로 진행되고 있으며 무엇보다도 IMF 체제 이후 정부규제의 전면적인 철폐는 불가피하게 되었다. 이러한 국내외적인 변화의 물결 속에서 옵션, 선물, 스왑과 같은 파생상품의 거래가 증가하면서 금융시장의 변혁이 본격화되고 있다. 옵션이나 선물, 스왑과 같은 파생금융상품의 거래는 위험에 대한 효율적인 헤지(Hedge)수단이라는 측면에서 반드시 필요하며, 적절한 매매거래를 통한 매매차익으로 인하여 새로운 수익원으로 기대할 수 있다. 특히 주식이나 채권과 같은 본원 증권과는 달리 상대적으로 적은 금액으로 많은 양의 거래가 가능한 레버리지(Leverage) 기능이 큰 상품이므로 큰 위험이 존재하지만 이익도 큰 상품이라 할 수 있다.

이러한 상황에서 금융기관을 비롯한 기업이나 개인투자자들은 미래상황의 예측에 대해 매우

큰 관심을 보이고 있으며 재무분야에 있어서 전통적인 통계학적 접근 방법 외에 전문가 시스템과 인공신경망과 같은 다양한 인공지능 기법을 이용하려는 연구들이 활발히 수행되었다. 전문가 시스템에 있어서 재무시장에서 주가 및 환율의 예측분야와 효과적인 포트폴리오 구성문제에 많은 연구 [Essinger, 1990; Lee *et al.*, 1990]가 수행되어 왔는데 시장의 정보로부터 효과적인 지식을 추출하는데 있어 많은 어려움을 겪고 있다. 반면 인공신경망의 경우 저 수준의 지식을 이용하여 불확실한 상황을 예측하려는 연구 [Kimoto *et al.*, 1990; Goleman *et al.*, 1991; Medsker *et al.*, 1993]가 이루어지고 있다.

본 연구의 목적은 파생상품 중 국내에 도입한 지 얼마 되지 않아 아직은 활발한 연구가 이루어지지 않는 점차 관심의 대상이 되는 옵션에 대해 투자함에 있어 인공신경망을 이용한 옵션의 가격변동을 예측하는 옵션투자예측시스템의 프로토타입을 개발하는데 있다. 물론 옵션에 대한 투자의 경우 투자목적과 전략에 따라 실제 보다 복잡하고 다양할 수 있지만 옵션의 가격 패턴을 분석하고 인공신경망을 이용하여 간단한 프로토타입 시스템을 개발

함으로써 보다 효과적인 투자 의사결정에 도움을 주고자한다.

본 논문은 다음과 같이 구성되어 있다. 제 2절에서는 옵션에 대한 일반적 소개 및 이론 가격 산출모델에 대하여 설명한다. 제 3절에서는 본 연구에서 사용할 예측 기법인 인공지능망 앙상블에 대하여 소개한다. 제 4절에서는 옵션투자예측 시스템의 구축 과정을 기술한다. 제 5절에서는 본 연구에서 개발한 모델과 기존의 이론가격 산출 모델의 성능 비교를 하고, 마지막으로 제 6절에서 연구에 대한 요약 및 결론을 제시한다.

## 2. 옵션 (Option)

### 2.1 옵션의 기본개념

옵션이란 특정자산(기초자산 : KOSPI 200)을 사권에 정한 가격(행사가격)으로 지정된 날짜(만기일) 또는 그 이전에 매수하거나(콜옵션 : Call Option) 매도할 수 있는(풋옵션 : Put Option) 권리를 말하며, 옵션거래란 이러한 권리를 매매하는 거래를 지칭한다[차명준, 1992; 박정식과 박종원 1999; 이필상 외, 1999].

이러한 옵션 거래는 다음과 같은 목적으로 이용되고 있다.

첫째, 옵션은 레버리지(Leverage) 기능이 있다. 옵션은 주식 투자보다 적은 비용으로 주식 투자와 동일한 포지션을 취할 수 있어 거래 비용을 절감하는 효과가 있으며 옵션거래의 매수자는 기초자산의 가격보다 훨씬 적은 금액의 프리미엄으로 그 기초자산을 거래하는 것과 유사한 효과를 얻을 수 있다.

둘째, 옵션은 헤지(Hedge) 기능을 갖고 있다. 특정 옵션에만 투자하거나, 옵션과 옵션을 적절히 결합하거나, 또는 옵션과 다른 금융상품을 결합함으로써 다른 금융상품에 투자할 때에 비하여 위험을 감소시킬 수 있는 기능이다. 즉 여러 가지 옵션과 주식을 결합하면 위험이 전혀 없는 포트폴리오도 만들 수 있다.

셋째, 옵션은 새로운 금융상품(Financial Assets)을 창조하는 기능을 갖고 있다. 즉, 옵션의 다양한 결합으로 투자자가 원하는 새로운 금융상품을 만들 수 있다. 기초주식의 가격이 오르면 이익을 볼 수 있는 것은 물론, 오히려 기초주식의 가격이 내리면 이익을 볼 수 있는 결합, 기초주식의 가격이 작은 쪽으로 변화할 때 이익을 볼 수 있는 결합 등 현재 존재하는 금융상품으로는 기대할 수 없는 수많은 새로운 상품형태를 만들 수 있다. 새로운 금융상품을 개발하는 데는 옵션이론을 많이 이용하는데 이를 재무공학(Financial Engineering)이라고 하여 현재 학계나 실무에서 관심의 대상이 되고 있다.

옵션의 가격을 결정하는 요소는 다섯 가지, 즉 기초자산 가격, 행사가격, 변동성, 잔존만기, 이자율 등으로 분류된다. 이 다섯 가지 요소를 여러 종류의 이론가 산출 모형(블랙-숄츠 또는 이항모형)에 입력시킨 후 옵션의 이론가격을 계산한다. 이렇게 계산된 이론가격을 실제 시장에서 옵션을 매매하는데 기준으로 사용하게 된다. 그런데 이론가격은 같

은 모형을 쓰더라도 계산하는 사람마다 차이가 나타나게 된다. 그 이유는 다섯 가지 요소 중 변동성이 다를 수 있기 때문이다. 변동성은 구하는 방법마다 다르게 도출되며 또한 그 구하는 방법마저도 정확한 것이 없다. 어떤 사람은 과거의 기초자산을 가지고 변동성을 산출하기도 하고 또 어떤 사람은 수학적으로 정립된 모델을 사용하기도 한다. 하지만 어떤 방법도 정확한 기초자산의 변동성을 계산할 수 있다고는 말할 수는 없다. 그 이유는 구하려는 기초자산의 변동성이 미래에 일어날 변동성이기 때문이다. 그러므로 변동성을 정확하게 예측하는 것이 옵션거래에 있어서 매우 중요하다.

### 2.2 우리 나라의 옵션거래제도

우리 나라에서는 1997년 7월 7일에 KOSPI (Korea Stock Price Index) 200 지수를 대상으로 주가지수 옵션거래가 시작되었다. 종합주가지수를 산정하는 방식과 동일하게 시가총액식으로 산출되며 상장주식 중 200개의 대표적인 주식들만으로 구성되는데, 시가총액을 기준으로 할 때 이 종목들의 비중은 약 70%에 달한다. 옵션의 가격은 1990년 1월 3일의 가격을 100.00포인트로 하여 계산한다. KOSPI 200 옵션거래는 지수를 이용하여 옵션거래의 조건을 정하고, 옵션에 따른 권리를 매매 대상으로 하는 거래이다. 따라서 직접적인 매매대상이 주가지수가 아니라 주가지수를 이용한 옵션인 점이 주가지수를 직접적인 매매 대상으로 하는 주가지수 선물거래와 다르다.

옵션거래의 대상은 선물의 만기월인 3, 6, 9, 12월의 만기 중 가장 가까운 만기 1개와 근월물 3개 종목을 합하여 모두 4개의 종목이 상장되며 각 결제월별로 5개의 권리행사가격(행사가격간의 간격은 100포인트를 기준으로 하여 상하 2.5포인트)이 상장된다. 예를 들어 현재 시점이 2000년 5월 25일이라면 옵션의 만기별 상장 종목은 2000년 6월, 2000년 7월, 2000년 8월, 그리고 선물의 만기월인 2000년 9월이 된다. 옵션이 처음 시작되었을 때에는 최근 3개월과 3월, 6월, 9월, 12월의 6개 만기를 두었으나 원월물의 거래 부진으로 1998년 하반기부터는 만기를 가장 가까운 만기 4개로 축소하였다.

5개의 권리행사가격은 신규종목이 상장되는 경우 전일 KOSPI 200 지수 정산가(KOSPI 200지수 전일종가)를 기준으로 가장 근접한 권리행사가격인 등가격옵션 1종목, 유리한 행사가격인 내가격옵션(In-The-Money : ITM : 콜옵션의 경우 등가격 행사가격보다 낮은, 그리고 풋옵션의 경우 등가격 행사가격보다 높은) 2종목 그리고 불리한 행사가격인 외가격 옵션(Out-of-The-Money : OTM : 콜옵션의 경우 등가격 행사가격보다 높은, 그리고 풋옵션의 경우 등가격 행사가격보다 낮은) 2종목 등 총 5개이다. 등가격옵션(At-The-Money : ATM)은 전일 최종주가지수와 가장 가까운 행사가격으로 정하며 상장기간동안 KOSPI 200 지수가 변동하는 경우 등가격옵션 기준으로 각각 최소한 2개씩의 내가격옵션과 외가격옵션이 존재하도록 행사가격을 추가로 설정한다. 단, 매매거래 최종일이 속한 주에는 당해 만료월 종목에 대해서는 권리행사가격을 추가로 상장하지는 않는다.

옵션 거래단위 및 기준가격 산출시 1계약의 크기는 지수 1포인트당 10만원이며 호가가격단위(가격변동폭)는 옵션가격이 3포인트 이상이면 0.05포인트, 즉 5,000원(10만원×0.05=5,000원)이고 3포인트 미만이면 0.01포인트에 해당하는 1,000원 단위이다. 거래단위는 주가지수 선물이나 옵션 모두 1계약을 최소거래단위로 거래하고 한 주문 당 최대 주문가능수량은 4,999계약이다. 선물의 경우 KOSPI 200 지수에 500,000원을 곱한 금액을 1계약당 약정금액으로 하지만 옵션의 경우 개인투자자의 참여 유도와 시장의 유동성 확보라는 측면에서 옵션가격에 100,000원을 곱한 금액을 옵션 1계약당 약정금액으로 한다.

기준가격의 산출은 전일의 최종가격이 있는 경우에는 전일의 옵션 종가를 기준가격으로 한다. 전일에 기세가 있는 경우 전일의 기세가격을 기준가격으로 한다. 그러나 전일의 기준 가격이 기준가격 적용 최대이론가격(5% 상승 콜옵션 이론가격 및 5% 하락 풋옵션 이론가격)보다 높거나 기준가격 적용 최소이론가격(5% 하락 콜옵션 이론가격 및 5% 상승 풋옵션 이론가격)보다 낮은 때에는 옵션 이론 가격으로 한다.

매매계약 체결 방식은 대량주문의 신속한 매매체결, 착오매매의 최소화 및 차익거래의 원활화 등을 고려하여 주식시장과 동일하게 전산시스템에 의한 개별 경쟁매매 방식으로 한다. 개별 경쟁매매방식이란 가격 우선의 원칙, 시간 우선의 원칙, 수량 우선의 원칙, 위탁매매 우선의 원칙을 말한다. 호가공개방법에 있어서는 원활한 차익거래가 가능하게 하기 위해서는 가능한 한 많은 호가 정보를 공개할 필요가 있으나 호가 수량이 적거나 호가분포가 고르지 못할 경우 시장 조작 등 불공정거래 가능성이 상존하고 특히 만료일 및 행사가격으로 종목별 구분하는 옵션 거래는 Deep ITM(In The Money) 또는 OTM(Out of The Money) 종목의 경우 거래량이 극히 미미할 것이라 예상되므로 옵션시장에서는 이 같은 호가공개의 장, 단점을 고려하여 유동성이 어느 정도 확보된 종목인 최근 월물과 차근월물 종목에 한해 등가격옵션 및 등가격옵션의 상, 하 1개의 권리행사가격대 옵션에 대해서는 매도, 매수별 3개 우선 호가의 가격 및 수량, 그리고 호가수량이 공개된다. 그 외 다른 종목의 경우에는 최우선 호가의 가격 및 수량 그리고 총호가수량이 공개된다.

### 2.3 블랙-숄츠(Black-Scholes) 옵션 가격 결정 모델

블랙(Fisher Black)과 숄츠(Myron Scholes)는 유럽형 옵션가격결정모델을 발표하였다(Black and Scholes, 1979). 그들은 첫째, 기초자산의 가격이 로그정규분포(Lognormal Distribution)에 따르고, 둘째, 만기일에만 권리를 행사할 수 있는 유럽형 옵션이며, 셋째, 만기일까지 무위험이자율과 기초자산 가격의 변동성은 변하지 않으며, 넷째, 옵션의 잔존 기간동안 기초자산인 주식에 대한 배당 등 자본 분배가 이루어지지 않고, 다섯째, 거래비용, 세금 및 공매도 제약이 없는 완전자본시장(Perfect Capital Market)이라는 가정 하에서 다음과 같은 콜옵션의 가격결정식을 유도하였다.

$$C = S_0 N(d_1) - X e^{-rT} N(d_2)$$

여기서,

$$d_1 = \frac{\ln(S_0/X) + (\gamma + 0.5 \sigma^2) T}{\sigma \sqrt{T}}$$

$$d_2 = d_1 - \sigma \sqrt{T}$$

단, C = 현재 옵션가격

S<sub>0</sub> = 현재주가

N(d) = 표준정규분포에서 d값보다 작을 확률

X = 행사가격

e = 자연로그(Natural Log)의 밑(Base) = 2.7183

r = 무위험 이자율(연속복리 연 이자율)

T = 만기까지의 기간으로서 연으로 표시

(예 : 6개월 = 0.5년)

ln = 자연로그

σ = 기준주식 연간 수익률의 표준편차


이 식은 자주 사용되고 있는 공식으로서, 이해를 돕기 위해 N(d)를 중심으로 설명하면 다음과 같다. 첫째, N(d)는 콜옵션이 가치 있는 상태(In-The-Money)로 만기를 맞게 되는 확률을 의미한다. 극단적으로 N(d)가 1로 접근하면 이는 옵션이 행사될 가능성이 매우 높은 것으로서, 이 경우 콜옵션 가치는 C = S<sub>0</sub>Xe<sup>-rT</sup> = S<sub>0</sub> - (X의 현재가치)로서 콜옵션의 내재가치와 같다. 둘째, N(d)가 0으로 접근하면 옵션은 거의 행사될 확률이 없다. 이 경우 C는 0에 가깝다. 셋째, 대개 N(d)는 0과 1 사이에 있는데, 콜옵션이 가치 있는 상태일수록 커진다. 넷째, d<sub>1</sub>과 d<sub>2</sub>의 분자 ln(S<sub>0</sub>/X)은 콜옵션이 가치 있을 확률 또는 가치 없을 확률을 나타낸다.

## 3. 옵션 투자예측 시스템

### 3.1 사용된 자료

본 연구에서는 우리 나라 옵션시장에서 거래되고 있는 KOSPI 200 지수 옵션을 연구의 자료로 사용하였다. 이러한 KOSPI 200지수의 월평균의 분포는 <그림 3.1>과 같다. 본 연구는 콜옵션을 대상으로 하였으며 실제 거래가 이루어지지 않은 날의 데이터는 제외하였다. 본 연구는 옵션의 당일 증가변동에 대한 실험이므로 시가와 종가가 동일한 데이터는 실험대상에서 제외하였으며 만기일에 따른 데이터의 수집은 일반적으로 옵션거래가 근월물에 집중되어 거래되므로 근월물을 만기로 가지는 데이터만 사용하였다. 데이터는 1997년 7월 7일부터 1999 8월 31일까지의 모든 거래 실적을 수집하였으나, 이 데이터 중 일부를 샘플로 추출하여 실험하였다.

인공신경망에서의 데이터는 훈련을 위한 데이터와 테스트를 위한 데이터로 나누어진다. 본 연구에서 사용하고자 하는 데이터는 시계열 데이터이기 때문에 미래에 일어날 지수변동이 과거와 비슷한 패턴을 따라 이루어질 것이라는 가정에서 출발한다. 하지만 과거의 어느 특정 기간이 미래의 패턴을 대표할 것이라는 보장은 없다. 따라서 훈련용 데이터가 한 기간에 고정됨으로써 생길 수 있는 편향(bias)을 제거하기 위하여 수집한 자료에 대하여 전처리 후에 여러 개



<그림 3.1> 월평균 KOSPI 200 지수의 변화

의 데이터 집합으로 나누어서 실험하였다.

우선 1999년 6월 데이터를 사용하여 기본적인 인공신경망의 구조를 설정하였는데, 설정된 모델의 안정성 및 일반성을 검증하기 위해 전월인 1999년 5월 데이터와 IMF 외환위기로 인하여 KOSPI 200 지수가 30포인트대로 급격히 변화한 1998년 6월 데이터를 사용하여 확인하였다. 훈련을 위한 데이터는 테스트를 위한 데이터의 이전 3개월 동안의 데이터를 사용하였으며 그 내용은 <표 3.1>과 같다.

<표 3.1> 훈련용 데이터와 테스트용 데이터의 구분

분 류	용도	기 간	데이터의 수
샘플 1	훈련	1999.3~1999.5	488
	테스트	1999.6	208
샘플 2	훈련	1999.2~1999.4	469
	테스트	1999.5	174
샘플 3	훈련	1998.3~1998.5	645
	테스트	1998.6	211

### 3.2 인공신경망의 설계

인공신경망은 패턴인식과 분류 문제에 탁월한 능력을 보인다[Hansen et al., 1991; Nelson and Illingworth, 1991]. 이러한 능력을 기반으로 인공신경망은 재무와 관련된 영역의 문제, 예를 들어 신용평가, 도산예측[이재식과 한재홍, 1995], 주가예측[박종엽과 한인구, 1995] 등에 적용되었다..

본 연구에서 사용하는 인공신경망은 입력층, 은닉층, 그리고 출력층의 세 개의 층을 갖고 있다. 은

닉층의 개수는 하나로 하여 처리요소의 개수를 변화시키고 학습 회수를 증가시키며 실험하였으며, 앙상블 기법을 적용하여 상호 비교하는 방법을 택하였다. 본 연구에서는 <표 3.1>의 각각의 샘플에 대하여 최적의 모델을 찾기 위해 실험하기보다는, 우선 샘플 1을 통하여 인공신경망의 기본적인 구조와 학습회수를 결정하고 이를 샘플 2와 3에 적용해 봄으로써 모델에 대한 일반성을 확인해 보았다.

학습방법으로는 감독학습방법(Supervised Learning) 중에서 가장 일반적으로 사용되며 비교적 우수한 성능을 보이고있는 백프로퍼게이션(Backpropagation) 알고리즘을 사용하였으며, 전이함수는 백프로퍼게이션 알고리즘에서 일반적으로 택하고 있는 시그모이드(Sigmoid) 함수를 사용하였다.

입력변수는 0.2와 0.8사이의 값을 갖도록 정규화 하였다. 입력자료의 정규화 단계가 끝나면 학습을 시작한다. 각 처리요소들 간의 연결가중치는 -0.1에서 0.1사이에서 무작위로 생성시켰고, 학습회수는 250,000번부터 시작하여 점차로 증가시켰다. 우선 샘플 1을 대하여 기본적인 인공신경망의 구조를 설정하기 위한 실험을 하고, 기본적인 인공신경망의 구조가 설정되면 각 샘플에 대하여 학습을 시작한다. 각 샘플에 대하여 학습이 완료되면 각 샘플의 테스트용 데이터를 가지고 테스트를 한다. 본 논문에서는 기본적인 인공신경망에 대한 테스트뿐만 아니라 학습 데이터에 대한 적응률을 기준으로 앙상블 기법을 적용하여 그 결과를 비교한다. 구체적인 학습방법과 테스트는 제 4 절에서 기술한다.

### 3.3 인공신경망 앙상블

인공신경망이 주어진 훈련용 데이터에 대한 적합 능력이 뛰어난 것은 사실이지만, 훈련용 데이터에 대한 설명에 너무 충실하다 보면 여기에 포함된

본질적이지 못한 불필요한 임의 변동 요소까지 학습할 위험이 있으므로 과잉학습(Overfitting)의 문제도 생긴다[Lawrence et al., 1997]. 이러한 과잉학습을 회피하는 전략으로 학습과정의 초기단계에서 학습을 중단하는 방법을 채택할 수 있다[Sarle, 1995]. 하지만, 학습과정 초기에 훈련을 멈춘 인공신경망은 불안정하여 데이터의 분리 또는 초기 연결가중치에 적은 변화가 있어도 예측치에는 커다란 변화가 있을 수 있게 된다[이영찬과 박수환, 1999]. 이러한 문제점을 해결하기 위한 방안으로 인공신경망 앙상블(Ensemble)이 제시되고 있다[Opitz and Shavlik, 1996].

하나의 문제를 해결하기 위해 다중 모델(Multiple Models)을 사용하는 것을 앙상블이라고 하는데 각 모델의 결과값을 조합하기 위한 기법을 간략히 살펴보면 다음과 같다[Heskes, 1996].


- (1) Bumping : 학습용 데이터에 대하여 가장 낮은 오차를 갖는 모델의 결과값만 사용하고 나머지 다른 모델의 결과는 사용하지 않는다.
- (2) Bagging : 모든 모델에서 나온 결과값의 평균을 사용하는 것이다. 개별 모델의 성능을 전혀 고려하지 않고 각 결과값에 동일한 가중치를 부여한다.
- (3) Balancing : Balancing 기법은 Bagging과 Bumping의 중간 형태로서, 개별 모델의 성능을 고려하여 각 결과값에 가중치를 부여하여 평균한다.

본 논문에서는 동일한 훈련용 데이터에 대하여 서로 다른 인공신경망 모델들을 적용하였고, 각 인공신경망의 결과값에 대해서는 위의 세 가지 조합 방법을 전부 적용하여 그 결과들을 비교하였다.

## 4. 옵션 투자예측 시스템의 구축

### 4.1 인공신경망 기본 구조에 대한 실험

먼저 <표 3.1>의 샘플 1(1999년 6월)의 데이터를 사용하여 초기 학습회수와 인공신경망의 구조를 설정하였다. 개별 인공신경망은 <그림 4.1>과 같이, 입력 변수로는 옵션거래 데이터에서 그 종목의 행사가격, 당일 시가, 전일 KOSPI 200지수와 행사가격과의 차이, 이론가격을 사용하였으며, 출력 변수로는 매도/매수(Sell/Buy)를 의미하는 하나의 출력 노드로 구성하였다. 즉, t일의 시가보다 t일의 증가가 높을 경우에는 출력의 기대값(Desired Value)을 매수(Buy)를 의미하는 1로 설정하였으며 반대의 경우는 매도(Sell)를 나타내는 0으로 설정하였다.



<그림 4.1> 개별 인공신경망의 구조

각각의 모델은 동일한 데이터를 사용하며, 그 출력값을 조합하여 최종 결과값을 취하는 형태로 실험하였다. 이러한 결과값은 분석을 위해 두 가지의 범주로 분류하여 실험하였다. 즉, 투자 결정에 있어서 보류라는 결정을 가정한 경우와 그렇지 않은 경우로 구분하여 그 결과값을 각각 분석하였다. 인공신경망의 출력값은 0과 1사이의 값을 가지므로 우선 0~0.3, 0.3~0.5, 0.5~0.7, 그리고 0.7~1의 범주로 값을 나누었다. 분류판정이 있는 경우 0~0.3의 경우는 0에 근사하다고 판단하여 매도 결정으로, 0.3~0.7은 그 신호가 미약하다고 생각하여 보류 결정을, 그리고 0.7~1은 1에 근사하다고 판단하여 매수 결정으로 분류하였다. 이와 달리 분류판정이 없는 경우에는 무조건 0.5를 기준으로 0.5보다 작은 경우에는 매도 결정으로, 0.5 이상일 경우에는 매수 결정으로 분류하였다. 이를 그림으로 나타내면 <그림 4.2>와 같다. 이러한 의사결정의 시점은 항상 당일의 개장시점으로 하였다.

인공신경망 출력값	0	0.3	0.5	0.7	1
분류판정이 있는 경우	매도	보류	매수		
분류판정이 없는 경우	매도		매수		

<그림 4.2> 인공신경망의 출력값에 대한 해석

전술한 바와 같이 샘플 1(1999년 6월)의 데이터를 사용하여 인공신경망의 기본구조를 설정하였다. 우선 인공신경망의 기본 구조를 설정하기 위한 실험은 보류판정이 있는 경우만 하였으나, 이후 앙상블 적용과 제 5절의 시뮬레이션에서는 보류판정이 있는 경우와 없는 경우를 구분하여 실험하였다. 앙상블은 모두 5개로 구성되었는데, 실험을 수행한 5개의 인공신경망 모델의 구조는 <표 4.1>과 같다. 즉, 첫 번째 인공신경망 모델인 NN1은 은닉층의 노드 개수가 3개인 모델이며 NN2는 5개, NN3은 7개, NN4는 9개, NN5는 11개인 모델이다.

학습 회수는 25만 번에서 시작하여 150만 번까지 회수를 증가하여 실험하였다. 샘플 1에 대한 기본 인공신경망의 실험결과는 <표 4.2>와 같다.

<표 4.1> 인공신경망 모델의 구조

입력층의 노드수	4	
출력층의 노드수	1	
은닉층의 수	1	
은닉층의 노드수	NN1	3
	NN2	5
	NN3	7
	NN4	9
	NN5	11

<표 4.3>에서 보면 샘플 2에 대한 적응률이 샘플 1에 대한 적응률보다는 다소 떨어진다. 이는 샘플 2에 대한 가장 최적의 인공신경망 구조를 찾아 실험한 결과가 아니라 샘플 1에 대하여 고정된 기본 모델에 적용한 결과이기 때문이라 할 수 있다. 또한 IMF로 인하여 KOSPI 200지수가 30포인트대로 떨어진 샘플 3에 대한 데이터는 이론가격만을 사용한 결과보다 매우 좋지 않게 나왔다. 이러한 결과는 IMF로 인한 급격한 시장변화로 인하여 적응률이 떨어지는 것으로 보이며 특히 보류결정이 있는 경우의 실험이므로 보류결정을 오류로 인식하였기 때문이라 할 수 있다. 하지만 본 연구의 목적이 옵션투자예측 시스템의 개발이므로, 적응률의 단순한 비교보다는 실제로 옵션을 사고 파는 시뮬레이션을 통하여 그 결과를 비교하여야 할 것이다.

<표 4.2> 샘플 1에 대한 학습 회수에 따른 인공신경망의 적응률 (단위 : %)

인공신경망		학습회수	25만	50만	75만	100만	125만	150만
NN1	학습		70.90	78.07	77.87	80.74	81.35	77.25
	테스트		81.25	83.65	86.05	100	84.62	86.05
NN2	학습		71.31	78.28	77.87	80.53	84.43	84.43
	테스트		83.65	87.02	82.69	85.10	88.47	87.50
NN3	학습		67.01	77.87	75.82	82.99	82.99	77.66
	테스트		80.77	83.17	85.58	86.54	88.94	85.10
NN4	학습		66.39	79.30	76.84	84.02	84.63	82.99
	테스트		81.73	84.13	86.06	87.02	89.42	86.54
NN5	학습		67.83	75.61	80.94	79.92	83.20	80.12
	테스트		81.73	75.96	83.65	83.17	87.50	87.98

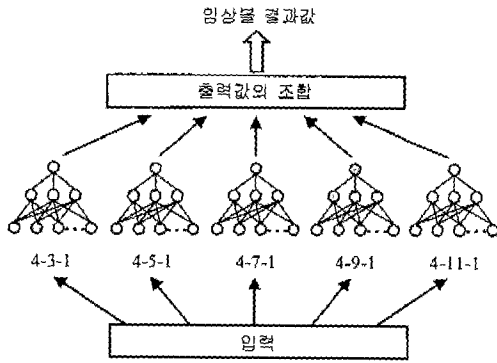
<표 4.2>에서 보듯이 각각의 모델에서의 학습 회수에 따른 결과가 조금씩은 차이가 있지만 대부분 125만 번의 학습에서 좋은 결과를 보여 주었다. 다른 학습회수에서 최고의 적응률을 보인 모델도 있지만 기본적인 인공신경망 구조에 대한 학습회수는 125만 번으로 고정시켰다. <표 4.3>은 세 개의 샘플에 대해서 125만번의 학습을 한 인공신경망의 적응률과 이론가격을 사용하여 예측한 경우의 적응률을 보여주고 있다.

<표 4.3> 각 샘플에 대한 인공신경망의 적응률(단위 %)

		이론가	NN1	NN2	NN3	NN4	NN5
샘플1	학습	80.53	81.35	84.43	82.99	84.63	83.20
	테스트	83.17	84.62	88.47	88.94	89.42	87.50
샘플2	학습	82.94	73.56	83.80	81.66	75.26	83.15
	테스트	81.03	68.39	85.63	86.78	81.03	85.63
샘플3	학습	82.48	79.07	80.00	80.62	78.60	80.93
	테스트	75.82	63.98	65.88	67.78	66.35	66.35

## 4.2 인공신경망 앙상블 기법의 적용

인공신경망의 안정된 모델을 만들기 위하여 기본적인 인공신경망의 구조를 기본 모델로 하여 각 모델의 출력값을 조합하여 투자예측에 대한 신호로 변환한다. 인공신경망 앙상블의 구조는 <그림 4.3>과 같다.



<그림 4.3> 인공신경망 앙상블의 구조

각 모델의 출력값을 조합하는 방법은 기본적으로 제 3 절에서 설명한 기법들을 적용하였는데, Balancing 기법은 좀더 확장하여 적용하였다. 즉, 기본적인 세 가지 기법(Bagging, Bumping, Balancing)과 Balancing 기법을 확장한 Bal\_4(학습 데이터에 대하여 적중률이 높은 인공신경망 4개를 사용한 기법), Bal\_3(학습 데이터에 대하여 적중률이 높은 인공신경망 3개를 사용), Bal\_2(학습 데이터에 대하여 적중률이 높은 인공신경망 2개를 사용) 등 총 6가지의 기법을 적용하여 비교 실험하였다. 각각의 기법은 각 샘플의 학습결과에 따라 사용되는 인공신경망 구조의 순서가 달라지게 된다. 예를 들면 Bumping 기법을 적용할 경우 샘플 1은 학습에 있어서 가장 좋은 결과를 보여준 NN5(4-11-1구조)의 인공신경망을 사용하지만 샘플 2는 NN2(4-5-1)구조의 인공신경망을, 샘플 3은 NN4(4-9-1구조)의 인공신경망을 사용하게 된다. 이렇게 인공신경망 구조의 우선 순위가 바뀌는 것이 Bagging 기법에 있어서는 별다른 영향이 없다. 특히 Balancing 기법의 경우에는 적용되는 인공신경망 구조뿐만 아니라 각각의 인공신경망 결과값의 조합에 사용되는 가중치가 달라지게 된다. 5개의 인공신경망을 모두 사용하는 Balancing 기법에서 사용되는 가중치는 우선 순위에 따라 각각  $\frac{5}{15}, \frac{4}{15}, \frac{3}{15}, \frac{2}{15}, \frac{1}{15}$  을 사용하였으며, Bal\_4의 가중치는 각각  $\frac{4}{10}, \frac{3}{10}, \frac{2}{10}, \frac{1}{10}$  을, Bal\_3의 가중치는 각각  $\frac{3}{6}, \frac{2}{6}, \frac{1}{6}$  을, 그리고, Bal\_2의 가중치는 각각  $\frac{2}{3}, \frac{1}{3}$  을 사용하였다. 이러한 가중치 설정은 사용하는 인공신경망의 개수가 작아질 수로 적중률이 높은 인공신경망에 대한 가중치가 커지게 한 것이다. 가중치 설정은 Balancing 기법에 있어서의

연구 과제가 될 수 있지만 본 논문의 주제에는 포함하지 않았다. 각 기법의 결과는 시뮬레이션 결과와 함께 다음절에서 기술한다.

## 5. 옵션 투자 시뮬레이션 결과

### 5.1 옵션 투자예측 시스템 검증을 위한 시뮬레이션 방법

앞의 절에서 설명하였듯이 각각의 인공신경망에서 나온 출력값을 조합한 앙상블 결과값을 이용하여 시뮬레이션을 하였다. 시뮬레이션의 신호는 매도, 매수, 보류의 세 가지로 구분하였으며 시뮬레이션을 위한 의사결정은 당일의 개장 시점에 하고, 당일에 그 의사결정에 대한 투자를 결정하는 것으로 하였다. 따라서 의사결정을 위한 결과값이 매도 신호인 경우 시가 기준으로 매도를 하고, 매도한 것을 증가 기준으로 다시 매수하여 결정하는 방식으로 매일 각 종목별로 실험하였다. 매수 신호의 경우 매도와 반대의 투자 결정으로 하였으며 보류 신호는 해당 종목에 대하여 매도나 매수의 어떤 투자 결정도 취하지 않는 것으로 하고 각각의 기법에 대하여 실험하였다.

시뮬레이션은 크게 옵션투자결정에 있어서 보류 결정이 있는 경우와 없는 경우의 두 가지로 나누어 실험하였는데, 그 절차는 다음과 같다.

- 1) 각 종목에 대한 인공신경망의 결과값을 저장한다. (인공신경망의 결과값은 0과 1사이의 값으로 나타나는데, 0에 가까울수록 시가가 증가에 비하여 높다는 것을 의미한다)
- 2) 저장된 결과값을 미리 설정한 기준에 따라 매도와 매수 시그널로 변환한다.
  - ▶보류결정이 있는 경우 : 0~0.3은 Sell, 0.3~0.7은 Hold, 0.7~1은 Buy 시그널로 변환.
  - ▶보류결정이 없는 경우 : 0~0.5는 Sell, 0.5~1은 Buy 시그널로 변환.
- 3) 시그널에 따라 투자 시뮬레이션을 한다.
  - ▶Sell 시그널 : 해당종목을 시가로 매도하고 증가로 매수한다. (해당종목에 대하여 시가가 증가에 비하여 높을 것이라고 예측)
  - ▶Buy 시그널 : 해당종목을 시가로 매수하고 증가로 매도한다. (해당종목에 대하여 시가가 증가에 비하여 낮을 것이라고 예측)
  - ▶Hold 시그널 : 해당종목에 대하여 아무런 투자 포지션도 취하지 않는다.
- 4) 해당종목의 매도가에서 매수가를 뺀 값에 100,000원을 곱하여(옵션의 가격은 1 포인트당 100,000원) 투자결과값으로 한다(투자예측이 맞았다면 투자결과값은 +가 되고, 틀렸다면 -가 된다).
  - ▶Sell 시그널 투자결과값 : (시가-증가) \* 100,000원
  - ▶Buy 시그널 투자결과값 : (증가-시가) \* 100,000원
  - ▶Hold 시그널 투자결과값 : 투자에 대하여 아무런 포지션을 취하지 않았으므로 0원

본 논문에서는 지면의 제약상 보류 결정이 없는 경우의 시물레이션 결과만을 제시한다.

## 5.2 보류결정이 없는 경우의 시물레이션 결과

보류 결정이 없는 경우, 즉 앙상블의 결과값이 0~0.5이면 매도를, 0.5~1이면 매수를 하는 경우에 각 모델의 결과를 조합하는 기법별 월별 결과는 <표 5.1>과 같다. <표 5.1>에서 적중률의 경우에 '최상과의 차이'는 각 적중률에서 최상의 적중률을 뺀 것이며, 누적이익의 경우에 '최상과의 대비'는 각 누적이익의 최상의 누적이익에 대한 백분율을 보여주는 것이다.

각각의 결과를 살펴보면 샘플 1에서 적중률의 경우는 Bal\_3이, 누적이익의 경우는 Bumping이 최상의 결과를 보였으며, 샘플 2에서는 적중률과 누적이익 모두에서 Bagging이 최상의 결과를 보였다. 샘플 3에서는 적중률과 누적이익 모두에서 Bumping이 최상의 결과를 보였다.

중률은 이론가에 비하여 낮았지만 실제 투자 시물레이션에서는 오히려 누적수익이 높은 결과를 보였다. 한편, 보류 결정을 고려하지 않은 실험에서는 적중률과 누적이익에 있어서 모두 이론가를 사용한 투자예측보다 좋은 결과를 제시하였으며 보류 결정이 있을 때의 결과보다도 좋은 결과를 보였다.

본 연구가 가지는 몇 가지 문제점과 한계점은 다음과 같다. 첫째, 데이터 구성상의 문제이다. 보다 명확한 결론을 도출하기 위해서는 다양한 샘플을 통한 실험을 하여야 하고, 근월말 이외의 데이터는 물론 시가와 종가가 변동하지 않는 데이터를 포함한 실험이 병행되어야 할 것이다. 둘째, 입력변수의 다양성을 시도하지 못했다. 본 논문은 기본적인 옵션의 가격정보와 이론가만을 입력변수로 사용하였는데 보다 다양한 경제 지표 및 기술적 분석 지표 등, 다양한 변수를 반영하여 실험을 해야 하며 이를 통하여 시스템의 개선을 시도해야 할 것이다. 셋째, 투자예측실험에 있어서 옵션거래시장의 상황을 정확히 반영하지 못했다. 시스템에 의해 결정된 투자예측 신호에 따라 투자를 시가 기준으로 하고 이를 증가 기준으로 결제하는 것으로 단순화하였지만 실제거래에 있어서는 투자자의 호가대로

<표 5.1> 보류결정이 없는 경우의 실험 및 시물레이션 결과

		이론가	Bumping	Bagging	Balancing	Bal_4	Bal_3	Bal_2
샘플 1	적중률(%)	83.17	91.83	91.35	91.35	91.35	92.31	90.87
	최상과의 차이	9.13	0.48	0.96	0.96	0.96	0	1.44
	누적이익(원)	31815000	35735000	35413000	35413000	35413000	35473000	35394000
	최상과의 대비	89.03	100	99.10	99.10	99.10	99.27	99.05
샘플 2	적중률(%)	81.03	90.80	91.95	91.38	90.80	91.38	90.80
	최상과의 차이	10.92	1.15	0	0.57	1.15	0.57	1.15
	누적이익(원)	11217000	14731000	14827000	14801000	14779000	14789000	14781000
	최상과의 대비	75.65	99.35	100	99.82	99.68	99.74	99.69
샘플 3	적중률(%)	75.83	76.78	71.36	72.77	74.16	71.36	76.06
	최상과의 차이	0.95	0	5.42	4.01	2.60	5.42	0.72
	누적이익(원)	3634000	5208000	4806000	4812000	4920000	4806000	5078000
	최상과의 대비	69.78	100	92.28	92.40	94.47	92.28	97.50

## 6. 결 론

본 연구에서는 파생상품 중 국내에 도입된 지 얼마 되지 않아 활발한 연구가 이루어지지 않는 점차 관심의 대상이 되며 활발한 거래가 이루어지고 있는 옵션에 대해 투자함에 있어 인공지능영향을 이용한 예측 시스템의 프로토타입을 개발하였다.

연구결과 인공지능영향을 이용한 예측결과가 이론가격만을 사용한 예측결과에 비하여 좋은 결과를 보였다. 본 연구에서는 투자 보류 결정을 고려하는 경우와 고려하지 않는 경우로 나누어서 실험을 하였지만, 지면 제약상 후자의 결과만을 제시하였다. 투자 보류 결정을 고려하는 경우의 결과에서는 적

거래가 이루어지리라는 보장은 없다. 넷째, 앙상블의 조합된 결과를 해석하는데 나타날 수 있는 문제점이 있다. 본 연구에서는 조합된 결과값의 임계치를 2가지로 구분하여 실험을 하였는데, 임계치의 설정에 따라 그 예측력이 달라질 수 있다.



## [참 고 문 헌]

1. 박정식, 현대재무관리, 다산출판사,1996.
2. 박종엽, 한인구, "인공신경망을 이용한 한국 종합주가지수의 방향성 예측", 한국전문가시스템학회지, 제2호, 1995.
3. 이영찬, 박수환, "신경망 학습양상불에 관한 연구", 한국지능정보시스템학회논문지, 5권, 1호, 1999.
4. 이재식, 한재홍, "인공신경망을 이용한 중소기업도산 예측에 있어서의 비재무정보의 유용성 검증," 한국전문가시스템학회지, 창간호, 1995, pp.123-134.
5. 이필상, 정은호, 조한용, 선물 옵션, 법문사, 1999.
6. 차명준. 옵션거래 -이론과 실제-, 증권서적출판부,1992.
7. Black, F. and M. Scholes, "The Pricing of Options and Corporate Liabilities," *Journal of Political Economics*, May-June, pp258-282, 1979.
8. Essinger, J. "Artificial Intelligence : Applications in Financial Trading and Investment Management", Euromoney Publications PLC, 1990.
9. Goleman, K. G., T. J. Graettinger, and W. F. Lawrence, "Neural Networks for Bankruptcy Prediction : The Power to Solve Financial Problems", *AI Review*, July/August, pp48-50, 1991.
10. Hansen, J. V., F. William and J. R. Messier, "Artificial Neural Networks : Foundations and Application to Decision Problem", *Expert System with Applications*, Vol. 3, pp.135-141, 1991.
11. Heskes, T., "Balancing between Bagging and Bumping", In Mozer, M. C., M. I. Jordan, and T. Petsche, (eds.) *Advances in Neural Information Processing Systems 9*, The MIT Press, 1996.
12. Kimoto, T., K. Asakawa, M. Yoda and M. Takeoka, "Stock Market Prediction with Modular Neural Networks", *International Joint Conference on Neural Networks*, IJCNN, 11-6,1990.
13. Lawrence, S., C. L. Giles, and Ah Chung Tsoi, "Lesson in Neural Network Training: Overfitting May be harder than Expected", *Proceeding of the Fourteenth National Conference on Artificial Intelligence*, AAAI-97, AAAI Press, 1997.
14. Lee, J. K., R. R. Trippi, S. C. Chu and H. S. Kim, "K-FOLO: Integrating the Markowitz Model with a Knowledge-based System", *The Journal of Portfolio Management*, Fall, pp89-93, 1990.
15. Medsker, L., E. Turban, and R. R. Trippi, "Neural Network Fundamentals for Financial Analysts", *Neural Networks in Finance and Investing*, Brobus Publishing Company, pp3-26, 1993.
16. Nelson, M. M. and W. T. Illingworth, "A Practical Guide to Neural Nets", Addison-Wesley Publishing Company, Inc., pp.61, 1991.
17. Opitz, D. W. and J. W. Shavlik, "Generating Accurate and Diverse Members of a Neural-Network Ensemble", In Mozer, M. C., M. I. Jordan, and T. Petsche, (eds.) *Advances in Neural Information Processing Systems 8*, The MIT Press, 1996.
18. Sarle, W. S., "Stopped Training and Other Remedies for Overfitting", *Proceedings of the 27th Symposium on the Interface of Computing Science and Statistics*, 1995.