

인공신경망-금융시계열 모형을 이용한 KOSPI 200 주가지수의 변동성 예측

노태협

한국과학기술원테크노경영연구소
(rohth@kgsm.kaist.ac.kr)

이택호

기업은행
(swingup@kiupbank.co.kr)

한인구

한국과학기술원테크노경영대학원
(ighan@kgsm.kaist.ac.kr)

주가지수를 이용한 펀드 및 변동성을 이용한 다양한 종류의 파생상품이 개발됨에 따라 은행 및 투신사를 중심으로 리스크 관리에 많은 관심이 집중되고 있다. 다양한 종류의 펀드에 대한 평가와 헷징, 그리고 투자 전략 수립을 위하여 정확한 변동성의 추정 및 예측은 리스크 관리에 있어서 핵심 사안이라고 할 수 있다. 변동성 예측을 위하여 전통적 금융 시계열 분석 기법이 주요 예측 기법으로 사용 되고 왔다. 이 논문에서는 KOSPI 200 지수를 이용하여 기존 선행 연구에서의 예측 방법론간의 비교 및 금융시계열모형과 인공신경망의 통합모형을 제시한다. 변동성의 방향성 예측면에서 금융시계열의 GARCH 모형이 인공신경망모형보다 우수한 성과를 나타내었으며, 반면 인공신경망 모형은 변동성의 예측정확성 면에서 GARCH 모형보다 높은 예측정확도를 보여주었다. 따라서 이 논문에서는 인공신경망 모형이 다양한 금융시계열 모형(EGARCH 모형, GARCH 모형 및 EWMA 모형)과의 통합을 통하여 변동성의 방향성 및 예측정확성의 동시적 추구 가능성을 제시하고 있다.

한글색인어: 변동성 예측, 금융시계열 분석, 인공신경망

1. 서론

KOSPI(Korea Composite Stock Price Index) 200 주가지수음션시장이 1997년 7월 7일 개설된 이래 주식시장의 성장과 함께 거래규모가 급속도로 성장하여 왔다. 이와 함께 단일상품거래량 기준으로 1999년부터 2002년까지 4년 연속 세계 1위를 차지함으로써 세계가 주목하는 파생상품시장으로 성장하였다(증권거래소자료). 시장의 확대에 의한 변동성의 증가와 시장에 참여하는 투자자들이 증가함

에 따라 투자자와 금융기관들이 관심을 갖고 있는 중요한 이슈 가운데 하나는 KOSPI 200 주가지수의 변동성이 커짐으로 인하여 발생하게 되는 리스크 관리의 문제일 것이다. 따라서 정확한 변동성 예측은 금융기관들이 리스크 관리를 하기 위하여 수행하는 파생상품의 가격결정과 각종 펀드의 성과 평가, 효율적인 자산배분 및 투자 전략 수립에 필수적인 요소라고 말할 수 있다.

미래 변동성을 예측하는 금융시계열 모형은 JP Morgan사의 RiskMetrics(JP Morgan and Reuters, 1996)에서 모형화한 지수적 이동가중평균법

(Exponentially Weighted Moving Average: EWMA) 모형과 최근에 많이 사용되는 모형으로서 Engle(1982)이 제안한 p-차 자기회귀 조건부 이분산(Autoregressive Conditional Heteroscedasticity: ARCH(p)) 모형, 이를 일반화하여 Bollerslev(1986)가 제안한 Generalized ARCH(GARCH(p,q)) 모형을 언급할 수 있다. 또한 GARCH 모형이 현재의 수익률과 미래 수익률 변동성간의 '부(-)의 상관관계를 고려하지 않는 단점을 수정하여 Nelson(1991)이 제안한 Exponential GARCH(EGARCH)모형 등 시계열의 특성을 반영한 다양한 종류의 통계적인 모형들이 제안되어 왔다. 이러한 금융시계열 모형들은 계량기법(Econometrics)으로써 정확한 분석이 가능하며 시장의 현상을 통계적인 논리를 바탕으로 체계적으로 설명 가능하다는 장점이 있다. 하지만 시장환경이 변화함에 따라 대부분의 시장 변수(market variable)들은 많은 잡음(noise)을 갖게 되었으며 변동성을 예측하기 위하여 고려하여야 할 정성적, 정량적 변수들이 점차로 증가하고 있는 현실 속에서 금융시계열모형 자체는 변수의 분포에 대한 엄격한 가정을 요구하고 있기 때문에 시장 변수들을 모형 속에 직접 반영하기가 어렵다는 단점을 가지고 있다. 이와 같은 금융시계열 모형의 단점들로 인한 대안으로서 인공신경망(Artificial Neural Network: ANN), 유전자알고리즘(Genetic Algorithm: GA) 등의 인공지능 기법을 이용한 금융시계열 예측에 많은 관심이 집중되고 있다.

인공신경망모형은 비모수적 기법(nonparametric methods)으로서 이론적 함수 형태(theoretical functional form)없이 시장에서 관찰되는 데이터들을 이용한 패턴 학습(pattern learning)을 통해 결과값을 추정하는 모형이다. 이와 같은 모형의

특성을 이용하여 Hamid(2002)는 인공신경망을 이용하여 S&P 500 지수의 변동성을 예측하여 인공신경망이 기존의 금융시계열모형에 비하여 뛰어난 예측력을 나타낸다는 실증 분석을 하였으며 Brooks(1998)등의 많은 학자들에 의하여 변동성 추정에 있어서 인공신경망 모형의 뛰어난 예측력을 입증한 바 있다.

본 연구에서는 기존의 금융시계열 변동성 예측 모델인 EWMA, GARCH, EGARCH 모형과 인공신경망을 통합하여 예측력을 향상시킬 수 있음을 실증분석을 통하여 알아 보고자 한다. 기존의 여러 연구 논문들이 모수적(parametric) 방법인 금융시계열 모형과 비모수적 방법인 인공신경망 모형을 효과적으로 결합함으로써 시계열모형의 예측력을 향상시킬 수 있다고 언급하고 있다(Armano, Marchesi, and Murru, 2005). 본 연구는 두 모형의 통합을 통한 예측력 향상에 주안점을 두고 연구를 진행한다.

본 연구의 구성은 다음과 같다. 2장에서는 기존의 변동성 예측모형 및 통합모형에 대하여 이론적인 고찰 및 문헌 연구를 하고 3장에서는 본 논문이 제안하게 되는 인공신경망-금융시계열 통합모형에 대하여 이론 및 통합 방법론에 대하여 알아본다. 4장, 5장에서는 KOSPI200 주가지수 시계열 데이터를 사용하여 각 모형을 통한 변동성을 예측하고 결과에 대하여 분석한다. 예측 도메인으로서 KOSPI 200 주가지수 시계열 특성에 대하여 분석한 후 개별 모형(인공신경망, GARCH(1, 1)) 및 통합모형(NN-GARCH)에 의한 예측 결과를 산출하고 방향성과 정확성 관점에서 예측력을 비교함으로써 통합모형에 의하여 예측력을 향상시킬 수 있음을 입증한다. 인공신경망-금융시계열통합모형 간의 예측력 비교로서 NN-GARCH 모형뿐만 아니라 EGARCH, EWMA 모형과 인공신경망모형의

통합모델인 NN-EGARCH, NN-EWMA 모형간의 예측력을 비교한다. 각각의 모형에 대하여 마찬가지로 방향성과 정확성 관점에서 예측력을 비교함으로써 가장 예측력이 뛰어난 통합모형에 대하여 알아보고 그 원인에 대하여 분석하며 6장에서 본 연구에 대한 결론을 요약한다.

II. 변동성 예측이론 선행 연구 및 연구 기법

2.1 변동성 예측모형 이론연구

2.1.1 통계적 시계열 모형

금융시계열의 변동성에 대한 정교한 추정과 예측은 금융경제학모형 분석 및 이론검정에 있어서 중요한 의미를 가지고 있으며, 선물, 옵션 등의 파생상품의 거래 행태를 파악하기 위해서 연구 되고 있다. 금융시장의 변동성은 일반적으로 불확실성으로 파악되고 있으며 위험의 측정 수단으로 간주된다. 이러한 위험을 파악하기 위하여 역사적 변동성, 상관관계, 조건부 및 비조건부 분산, 시변분산(Changing variance) 및 공분산을 모형화하여 시계열의 변동성을 예측하고 및 변화를 통계적으로 예측할 수 있다.

전통적인 통계학 접근으로 변동성 집중(volatility clustering) 또는 두꺼운 꼬리(fat tail)특성을 갖는 시계열을 조건부분산의 관점에서 모형화 하기 위하여 Engle(1982)은 다음과 같은 p-차 자기회귀 조건부분산모형(Autoregressive Conditional Heteroscedasticity model: ARCH(p)) 모형을

제안하였다. 그러나 ARCH(p)모형으로 변동성을 추정하는 경우 시차(lag) p를 크게 설정해야 하는 경향이 있으므로 대안으로 Bollerslev(1986)는 ARCH 모형을 일반화하는 GARCH(p,q)모형(generalized ARCH)을 제안 하였다. 일반적으로 GARCH모형은 현재수익률의 잔차항(residual)의 제곱이 미래 수익률의 변동성에 영향을 미치게 되어 조건부변동성에 대한 충격이 '정'(+)인지 '부'(-)인지에 관계없이 항상 대칭적인 효과를 가져오게 된다. 이러한 점들을 고려하여 Nelson(1991)은 EGARCH(generalized ARCH)모형을 제안하였다.

지수적 이동가중평균법(Exponentially Weighted Moving Average: EWMA)은 최근의 자료에 더 많은 의미를 부여하여 관찰기간에 포함된 과거 자료들에 각기 다른 가중치를 주는 방법이다. 이 접근법은 JP Morgan사의 RiskMetrics(JP Morgan and Reuters, 1996) 에서 모수적 접근 방법으로 위험을 모형화 한 것이다.

그러나, 이와 같은 금융시계열 모형에 통계학적 분석 방법론을 적용할 경우 시장 변화에 대한 적응이 힘들고, 분석자료가 가지는 분포에 대한 엄격한 가정이 요구되며, 계량적 변수와 정성적 변수가 혼합된 경우에는 성과가 좋지 못하다는 어려움이 있다(Blum and Langley, 1997; Liu and Modota, 1998).

2.1.2 인공신경망(Artificial Neural Network) 모형

인공신경망은 인공지능의 한 분야로서 인간 두뇌의 생물학적 작동형태를 모방, 컴퓨터로 하여금 지적인 능력을 갖추게 하는 방법론을 말한다. 1943년 맥컬러와 피츠에 의해 뉴런의 모형화가 시작되

었고(McCulloch and Pitts, 1943), 1958년 로젠블라트에 의해 최초의 신공 신경망 모형이 제시되었으며(Rosenblatt, 1958), 이후 많은 신경망 모델 알고리즘이 연구되었다(Hecht-Nielsen, 1990). 공학분야에서 시작되어 90년대부터 경영학에 도입되기 시작하였으며 인간의 사고능력, 인지능력을 모방하여 많은 예의 처리를 통하여 인식된 패턴을 이용하여 문제를 해결하고자 하는 방법이다. 인공신경망은 두 개의 유용한 특징을 가지고 있는데, 결점 포용성(fault tolerance)과 적응성(adaptability)이다. 인공신경망은 하나의 처리 장치가 아닌 다수의 노드(PE, Processing Element)들의 상호작용을 통해 처리 되므로 불완전한 자료로부터 학습과 의사 결정을 할 수 있으며, 이러한 적응성은 지속적인 학습을 통해 가중치를 변화시키면서 적합한 모델을 만든다. 따라서 이러한 특징들을 이용하여 최근 재무 분야의 변동성 예측 및 복잡한 파생상품의 가격결정에 있어서 활발한 연구가 진행되어오고 있으며 금융공학 분야의 리스크 관리 도구로서 그 유용성이 점차 입증 되고 있다.

인공신경망을 이용한 금융시계열 연구는 주가지수, 이자율, 옵션 시장 등에서 활발하게 진행되고 있다(Yao, Li, and Tan, 2002). 인공신경망 기법을 이용한 주식 시장 예측은 다양한 인공신경망 유형을 이용하여 정확한 주가지수 예측 및 이에 대한 방향성 변화에 대한 연구가 주를 이루고 있다(Kim and Han, 2000).

Kimoto, Asakawa, Yoda and Takeoka(1990)는 인공신경망의 학습 알고리즘들(modular neural network)을 이용하여 동경주가지수(TOPIX: Tokyo stock exchange prices index) 예측시스템을 개발하였으며, 이는 다양한 시장요인들 사이의 관계의 학습을 통한 예측방법을 이용하였다. Kamijo

and Tanigawa(1990)는 recurrent neural network을 이용하였으며 Ahmadi(1990)는 백프로퍼게이션 신경망을 일반화된 델타를 이용하여 주식 시장을 예측하였다. 이에 더하여 주가지수를 이용한 선물 시장 예측에 대한 연구도 함께 진행되어 왔다. Choi et al.,(1995)와 Trippi(1992)는 인공신경망을 이용하여 S&P 500의 일간 변화 방향을 예측하였으며, Duke and Long(1993)는 독일정부 발행 채권선물에 해당 일간 예측을 백프로퍼게이션 신경망을 이용한 결과를 발표하였다.

2.2 금융시계열 통합모형에 관한 기존 연구

최근의 연구들은 인공지능기법들간 및 인공지능기법 및 통계기법에 대한 통합 모형을 제안하고 있다. Hiemstra(1995)는 퍼지지능정보시스템을 이용하여 주식시장의 수익률 예측방법을 제안하였다. 그는 인공신경망과 퍼지 논리의 결합 모형이 퍼지함수근사에 대한 제한을 완화시키기 때문에 함수매핑의 복잡성을 줄여 줄 수 있음을 보여주었다. Tsaih, Hsu and Lai(1998)는 룰베이스 기법과 인공신경망을 이용하여 S&P 500 주가지수선물의 일간 변화 방향을 예측하였다. Kohara, Ishikawa, Fukuhara and Nakamura(1997)는 학습과정에 주식시장 예측의 성과를 향상시키기 위하여 사전지식을 첨가하는 방법론을 제시하기도 하였다. 그러나, 이러한 방법론들 또한 주식시장의 방대한 노이즈와 불안정한 특성에 기인하여 부분적인 성과 향상을 보여주었다. Lawrence, Tsoi and Giles(1996)는 신경망의 학습단계에서 높은 노이즈가 있는 경우 신경망은 항상 우등한 결과를 나타내기 어려움을 지적하였다.

인공신경망과 금융시계열 모형의 통합에 있어서

〈표 1〉 인공신경망의 금융변동성 예측 적용에 관한 주요 연구

연도	저자	연구내용 및 연구결과
1996	Bolland and Burgess	내재변동성과 시장변동성간의 차이를 이용하여 인공신경망 학습 선형적 모형에 의한 추정보다 우수한 성과를 보임
1996	Weigend and Shi	인공신경망과 GE, GARCH 모형을 이용하여 주가지수 변동성 예측 인공신경망의 예측력 우위 및 안정성 확인
1997	Donaldson and Kamstra	미국, 영국, 일본주식시장의 개별주식의 변동성을 측정하기 위해 GARCH, MA 등의 선형적 모형과 인공신경망 모형의 예측성과 비교 인공신경망의 비선형적 학습능력 및 성과 확인
1998	Tsaih, Hsu and Lai	롤베이스 기법과 인공신경망을 이용하여 S&P 500 주가지수선물의 일간 변화방향 예측
1998	Brooks	GARCH, EGARCH 등의 기존 변동성 모형과 인공신경망 모형 비교 인공신경망 입력변수로서 t-1, t-2기의 변동성 사용 인공신경망의 예측력 우위 확인 1987 미국증시 폭락 시 안정적인 성과 보임
1999	Hu and Tsoukalas	GARCH, EGARCH, IGARCH, MAV모형을 이용하여 EMS(European Monetary System)의 환율 변동성 예측 예측값을 인공신경망에 대입하여 변동성 예측 EGARCH, ANN모델의 예측력 우위 확인
2002	Hamid and Zahid	옵션모형, 선형모형, 인공신경망을 이용하여 S&P 500 지수 선물의 변동성 예측 인공신경망의 예측력 우위 확인
2005	Armano, Marchesi, and Murru	주가지수 예측을 위한 GA-신경망 결합모형 제시

중요한 것은 어떠한 방식으로 두 모형을 통합하느냐 하는 방법론이다. 기존의 인공신경망과 금융시계열모형에 적용한 논문들은 〈표 1〉에서 볼 수 있는 바와 같이 두 모형의 예측력 비교나 인공신경망을 이용하여 시장 변수를 예측하고 이 변수를 재무 모형의 입력변수로서 활용함으로써 얻게 되는 가격 결정능력이나 예측력(prediction accuracy)향상에 주안점을 두어 왔다.

기존의 연구들은 인공신경망모형을 이용한 예측력 상승을 실제 시장데이터를 이용한 실증분석을 통하여 입증하였으며(Hamid, 2002) 향후 중요한

연구분야로서 인공신경망과 금융시계열모형을 통합한 인공신경망-금융시계열통합모형 개발의 중요성을 언급 하였다. 특히 Hu와 Tsoukalas(1999)는 각각의 금융시계열모형에 의하여 예측된 변동성을 인공신경망으로 재학습시켜 변동성을 예측하는 통합모형을 제시하여 예측력을 향상 시켰으며 금융시계열모형에 의하여 도출된 예측값들이 인공신경망 모형에 의한 변동성 예측에 얼마만큼 기여하는가에 대한 연구가 필요함을 제시하였다.

인공신경망을 이용한 연구는 변동성 예측뿐만 아니라 주가지수(Kim and Han, 2000; Armano,

Marchesi, and Murru, 2005), 이자율의 방향성 예측(Oh and Han, 2000)등에 있어서도 다양하게 진행 되어 왔다. 이러한 다방면의 연구들은 인공지능경망을 기존의 재무 및 금융공학 분야에 활용할 수 있는 다양한 근거를 제시하여 주었으며 현재 재무모형으로 충분히 설명 할 수 없는 재무 및 예측 등의 분야에 있어서 다방면으로 활발한 연구가 진행 되고 있다.

III. 인공지능경망-금융시계열 통합모형

인공지능경망을 이용한 변동성 예측에 있어서 기존의 논문들의 과제 중 하나는 인공지능경망 자체가 계량경제학적으로 결과를 증명할 수 없다는 한계점에 있다. 또한 예측 결과에 가장 중요한 결과를 미치는 입력변수 선정 과정에 있어서 어떠한 변수를 선택하여야 할지 반복적 시행착오의 학습과정을 통하여 입력변수를 선정하기 때문에 사용자들로 하여금 변수 선택과정이나 목표값 산출 과정에 있어서 결과물에 대한 궁금증을 증가 시켜 온 것이 사실이다. 이러한 인공지능경망 학습과정의 난해함을 해결하고 예측력을 높이기 위한 방안으로 고안된 방법이 본 논문에서 제안하게 될 인공지능경망-금융시계열 통합모형이다.

본 논문에서 제안하는 인공지능경망-금융시계열 통합모형의 특징은 다음과 같다.

첫째, 기존 논문들이 예측력 있는 변수를 선정하기 위하여 사용했던 반복적 시행착오(repetitive trial and error)의 과정을 금융시계열모형을 이용하여 변수를 추출함으로써 학습 과정상의 효율성을 달성 하였다. 인공지능경망모형의 예측력에 주된

영향을 미치는 변수는 대개 1개~2개로 압축될 수 있는데 인공지능경망을 이용한 기존 연구에서는 이러한 변수들을 발견하고 조정하는 일이 반복적 시행착오 과정의 대부분을 이루었다. 본 연구는 금융시계열모형 중 GARCH(1,1) 모형이 변동성의 방향성(direction)예측에 있어서 우수하다는 점과 반복적 시행착오에 의한 변수조정을 거치지 않은 인공지능경망 모형(simplest neural network model)이 예측의 정확성(precision)에 있어서 우수하다는 점에 착안하여 두 모형을 결합시킴으로써 정확성과 예측성을 동시에 향상 시킬 수 있는 가능성을 입증하도록 하겠다. 이론적으로 인공지능경망은 어떠한 연속함수라도 근사할 수 있는 능력을 가지고 있으며 이러한 유연성(flexibility)을 이용하여 금융시계열모형을 충분히 근사할 수 있다. 따라서 변동성 예측모형인 GARCH(1,1) 모형을 근사할 수 있는 방안으로서 GARCH(1,1) 모형에 의하여 도출된 변수들을 인공지능경망에 대입함으로써 조건부 변동성의 패턴을 인공지능경망을 통하여 구현할 수 있으며 도출된 변수뿐만 아니라 변동성 예측 값에 영향을 미치는 시장변수들을 인공지능경망의 입력변수로서 대입하여 학습시킴으로써 예측값을 보다 현실적으로 재 조정 할 수 있게 된다. 따라서 GARCH(1,1)모형을 이용한 인공지능경망 입력변수 선정과 이를 통해 추출된 변수를 인공지능경망 모형에 학습시킴으로써 방향성과 정확성 관점에서 예측력을 향상시킬 수 있음을 실증분석을 통하여 확인한다.

둘째, 다양한 인공지능경망과-금융시계열통합모형(NN-GARCH, NN-EGARCH, NN-EWMA)과의 통합을 통하여 어떠한 통합모델이 가장 뛰어난 예측력을 나타내는지 제안 하고 예측력 향상의 원인에 대하여 통계적으로 분석한다.

셋째, 인공지능경망 학습과정에 있어서 도메인(KOSP

I200 주가지수)에 대한 금융시계열 분석을 통하여 변수 선정과정부터 예측 값 산출까지 기존의 통계 모형을 이용한 예측과 동일한 연구 절차를 적용함으로써 인공신경망의 Black Box 특성들로부터 비롯되는 예측 값에 대한 논리성 결여를 최대한 배제한다.

위와 같은 연구 목적에 의하여 인공신경망-금융시계열 통합모형을 제안하며 이론적인 제안모형들은 다음과 같다.

3.1 인공신경망 - GARCH 통합모형 (NN-GARCH Model)

인공신경망-GARCH 통합모형의 핵심은 GARCH 모형을 통하여 얻어진 금융시계열모형을 이용하여 예측력이 뛰어난 변수를 도출 하는데 있다. 대부분의 금융시계열모형은 GARCH(1,1)모형으로 잘 모형화 할 수 있다고 알려져 있으므로, 우선적으로 GARCH(1,1) 모형을 이용하여 변수를 도출하여 보고자 한다. 시계열자료로부터 구한 GARCH(1,1)모형의 관계식은 다음과 같다.

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

GARCH(1,1)모형은 작은 수의 파라미터(parameter)를 사용함에도 불구하고 긴 래그(lag)의 ARCH 모형을 추정하는 것과 유사한 효과를 가져온다. 따라서 KOSPI 200 지수와 같이 변동성 집중 또는 두꺼운 꼬리(fat tail)의 특성을 갖는 시계열을 조건부분산의 관점에서 모형화 하기 위해서 GARCH(1,1) 모형을 이용하는 것이 타당하다고 하겠다. σ_t^2 은 과거 자료를 바탕으로 추정된 one-period ahead forecast 조건부 분산이다. 이러한

조건부 변동성의 관계식은 다음과 같은 세 개의 변수들로 나타낼 수 있다.

- α_0 : 비 조건부 변동성 상수
- ε_{t-1}^2 : t-1 시점(최근시점)의 잔차(residual)
- σ_{t-1}^2 : t-1 시점(최근시점)의 변동성 제곱

따라서 인공신경망을 이용하여 t 시점의 변동성을 예측하는데 있어서 금융시계열 모형을 이용하여 조건부적인 연관성(relation)을 갖고 있는 두 개의 변수 ε_{t-1}^2 과 σ_{t-1}^2 을 추출할 수 있으며 이 변수들은 각각 α_1 과 β_1 에 의하여 조정된 후 입력 변수로서 인공신경망 모형에 포함되게 된다. 새로이 추출된 변수들은 다음과 같다.

- $\sigma_{t-1}^2 = \beta_1 \sigma_{t-1}^2$
- $\varepsilon_{t-1}^2 = \alpha_1 \varepsilon_{t-1}^2$

반복적 시행착오를 거치지 않고 단순히 이전시점의 변동성만을 그대로 입력변수로 대입한 인공신경망 모델의 경우 모델의 예측력을 개선하기 위하여 입력변수의 조정계수(α_1 , β_1), 즉 σ_{t-1}^2 의 가중치를 선정하기 위하여 경우의 수에 따라 수많은 시행착오를 거쳐 모형을 완성하게 된다. 하지만 NN-GARCH 모형의 경우는 금융시계열모형을 이용하여 통계적으로 가중치를 선정하고 이러한 가중치에 의하여 조정된 σ_{t-1}^2 를 입력변수로 대입하여 학습하기 때문에 학습과정에 있어서 효율성의 증대를 가져오게 된다. 또한 새로운 변수로서 ε_{t-1}^2 을 도출하여 입력변수로 대입함으로써 예측력을 향상시킬 수 있다. 이러한 과정에 의하여 얻게 될 효율성 및 예측력에 대한 결과를 알아보기 위하여 추출된

두 변수 σ_{t-1}^2 , ε_{t-1}^2 를 이용하여 기존의 입력변수 (시장변수)와 함께 학습 시켜 예측력의 변화 양상을 알아 보도록 한다.

3.2. 인공지능망 - EGARCH통합모형 (NN-EGARCH Model)

인공지능망-EGARCH 통합모형의 핵심은 GARCH 모형의 제약적인 조건부분산 과정의 단점을 개선하는데 있다. EGARCH 모형은 Nelson(1991)에 의하여 제안된 모형으로서 조건부분산의 관계식은 다음과 같다.

$$\ln \sigma_t^2 = \alpha + \beta \ln \sigma_{t-1}^2 + \gamma \left(\frac{\varepsilon_{t-1}}{\sigma_{t-1}} - \sqrt{\frac{2}{\pi}} \right) + \omega \frac{\varepsilon_{t-1}}{\sigma_{t-1}}$$

EGARCH 모형은 GARCH(1,1)에서 설명할 수 없었던 비대칭적인 정보효과(asymmetric shock) 즉, 수익률의 큰 폭의 하락이 다음 기의 수익률변동성을 크게 하는 레버리지 효과(leverage effect)를 설명할 수 있다. 위의 관계식의 $\frac{\varepsilon_{t-1}}{\sigma_{t-1}}$ 변수가 변동성이 시장 충격에 의하여 비대칭적으로 반응하는 것을 설명해 줄 수 있기 때문이다. 따라서 EGARCH모형으로 제약적인 조건부분산모형인 GARCH 모형에서 설명할 수 없었던 비대칭적인 정보효과를 통계적으로 설명할 수 있다. EGARCH 모형은 다음의 네 개의 변수들로 나타낼 수 있다.

- α : 비 조건부 변동성 상수
- $\ln \sigma_{t-1}^2$: t-1 시점(최근시점)의 분산의 로그값

- $\left(\frac{\varepsilon_{t-1}}{\sigma_{t-1}} - \sqrt{\frac{2}{\pi}} \right)$: 레버리지 효과에 의한 비대칭적인 충격 반응
- $\frac{\varepsilon_{t-1}}{\sigma_{t-1}}$: 레버리지 효과(leverage effect)

위의 변수들을 바탕으로 인공지능망의 3개의 새로운 입력변수를 도출할 수 있으며 각각의 변수들은 β, γ, ω 에 의하여 조정된 후 인공지능망 모형의 입력변수에 포함되게 된다. 새로이 추출된 변수들은 다음과 같다.

- $\ln \sigma_{t-1}^2 = \beta \ln \sigma_{t-1}^2$
- $LE (leverage - effect) = \gamma \left(\frac{\varepsilon_{t-1}}{\sigma_{t-1}} - \sqrt{\frac{2}{\pi}} \right)$
- $L (leverage) = \omega \frac{\varepsilon_{t-1}}{\sigma_{t-1}}$

기존 연구들에서는 인공지능망의 예측력에 가장 큰 영향을 미치는 입력변수로서 기존의 시장에서 관찰할 수 있는 데이터 외에 시장변수를 이용한 다양한 재무변수들이 이용되었다. NN-EGARCH모형에서는 EGARCH 모형을 이용하여 Leverage와 Leverage Effect를 설명할 수 있는 새로운 변수를 추출한 것이 기존의 인공지능망 모형들과 다른 점이라고 할 수 있겠다. 새로운 변수들에 의한 효율성 및 예측력에 대한 결과를 알아보기 위하여 추출된 세 변수 $\ln \sigma_{t-1}^2$, LE , L 를 이용하여 기존의 입력변수와 함께 학습 시켜 예측력 변화 양상을 알아 보도록 한다.

3.3 인공신경망 - EWMA 통합모형 (NN-EWMA Model)

인공신경망-EWMA 통합모형의 핵심은 변동성 시계열의 최근의 자료에 더 많은 가중치를 부여하여 변동성에 있어 단기적인 움직임을 포착하는 변수를 도출 하는데 있다. 지수적 이동가중평균(EWMA)에 의한 변동성 관계식은 다음과 같다.

$$\sigma_t^2 = \lambda \sigma_{t-1}^2 + (1 - \lambda) \varepsilon_{t-1}^2$$

EWMA는 과거보다는 현재 값에 더 많은 비중을 두으로써 과거변동성으로 인한 그림자 효과를 줄여 주는 효과를 나타내며 모형은 두 개의 변수로서 나타낼 수 있다.

- σ_{t-1}^2 : t-1 시점(최근 시점)의 변동성 제곱
- ε_{t-1}^2 : t-1 시점(최근 시점)의 잔차(residual) 제곱

위의 변수들을 바탕으로 인공신경망의 2개의 새로운 입력변수를 도출 할 수 있으며 각각의 변수들은 스무딩(smoothing) 상수 $\lambda, (1-\lambda)$ 에 의하여 조정된 후 인공신경망 모형의 입력변수에 포함되게 된다. 새로이 추출된 변수들은 다음과 같다.

- $\sigma_{t-1}^2 = \lambda \sigma_{t-1}^2$
- $\varepsilon_{t-1}^2 = (1 - \lambda) \varepsilon_{t-1}^2$

EWMA 모형에 의하여 추출된 변수 $\sigma_{t-1}^2, \varepsilon_{t-1}^2$ 들은 GARCH(1,1)모형에 의해 추출된 변수들과

비슷한 모습을 나타내고 있지만 두 모형은 조건부 분산 차원에서 서로 다른 개념으로부터 출발한 모형이다. 즉, GARCH(1,1)모형의 조정계수(금융시계열모형에 의하여 구하여진 각 변수들의 계수를 의미)는 조건부분산개념에 의하여 통계적으로 도출된 조정계수 이지만 EWMA모형은 스무딩 상수 λ 를 0.94, 0.97, 0.99등으로 임의로 조정하여 최적의 예측 값을 찾아내게 된다. 따라서 두 모형의 각 조정계수는 계산과정 및 시계열 모형에서 개념적으로 의미하는 바가 다르기 때문에 서로 다른 시계열 모형으로부터 도출된 변수들의 예측력을 비교하여 봄으로써 어떠한 모형이 학습력 있는 변수를 도출 할 수 있는지를 확인 할 수 있다. 그러므로 위에서 도출된 두 변수 $\sigma_{t-1}^2, \varepsilon_{t-1}^2$ 를 이용하여 기존의 입력변수와 함께 학습시켜 다른 모형들과 예측력의 차이를 비교해 보고자 한다.

IV. 실험

4.1 실험 데이터 자료

변동성 예측을 위하여 본 연구에 사용된 KOSPI 200 주가지수 데이터 및 옵션 일별 거래실적 자료는 한국증권거래소 KOSPI 200 주가지수 통계자료와 KOSPI 200 옵션 일별 거래실적 자료를 이용하였으며 기간은 1999년 1월 12일부터 2003년 6월 19일까지의 주가지수 시계열 1,090개를 대상으로 실험하였다. 국고채 수익률 데이터는 본드웹(www.bondweb.co.kr) database를 이용하였다. 각 모형의 시계열 예측을 위한 실험자료데이터는 <표 2>와 같다.

〈표 2〉 시계열 예측을 위한 실험자료데이터

데이터	표 본 자 료 셋
표본구간	• 1999.1.12~2002.10.25 KOSPI 200주가지수 시계열(930개)
예측구간	• 2002.10.28~2003.6.19 KOSPI 200주가지수 시계열(160개) 예측값: 익일 22거래일 KOSPI 200 주가지수변동성

4.2 실험 모형 및 과정

인공신경망-금융시계열모형의 예측력에 대한 실증 분석을 위하여 우선 KOSPI 200 주가지수 시계열 데이터에 대한 분석을 통하여 금융시계열모형의 타당성에 대하여 검증 한다. 다음으로 본 연구 목적인 통합모형을 이용한 예측력 상승에 대하여 인공신경망, GARCH(1,1) 모형, 그리고 인공신경망모형 및 두 모형을 통합한 NN-GARCH(1,1)의 예측력에 대하여 분석을 실시한다. 이 결과를 바탕으로 GARCH(1,1) 이외의 통합모형(EGARCH, EWMA)에 대하여 통합모형간 예측력 비교를 함으로써 가장 예측력이 뛰어난 통합모형을 제시하고자 한다. 〈표 3〉는 본 실증분석에서 수행하게 되는 실증 분석 모형들에 대하여 정리한 표이다.

실증분석 과정은 크게 두 가지로 나타낼 수 있다. 우선, 표본자료데이터를 이용하여 인공신경망, GARCH(1,1)모형, 인공신경망-GARCH통합모형

(NN-GARCH)의 예측력을 정확성(precision), 방향성(direction)차원에서 MAE, 적중률분석(hit ratio analysis)을 이용하여 비교 분석하여 보고, 통합모형을 통하여 정확성과 방향성차원에서 예측력을 향상시킬 수 있음을 알아 본다. 다음으로 NN-GARCH와 다른 인공신경망-금융시계열통합모형(NN-EGARCH, NN-EWMA)들간의 예측력 비교를 통하여 어떠한 통합모형이 가장 예측력이 뛰어난지에 대하여 알아보고 그 이유에 대하여 통계적 근거를 통하여 설명한다.

4.2.1 시계열의 사후변동성(Realized Volatility) 계산

변동성 추정 모형에 의하여 예측된 변동성의 실제 예측력을 비교하고 인공신경망의 학습을 위하여 예측구간인 22 거래일 동안의 실제 KOSPI200 주가지수의 로그수익을 표준편차(standard deviation)

〈표 3〉 실증분석 모형 요약

종 류	예 측 모 형
단일모형과 통합모형 간 예측력 비교	<ul style="list-style-type: none"> • GARCH(1,1) • 인공신경망 • 인공신경망-GARCH 통합모형(NN-GARCH)
통합모형간 예측력 비교	<ul style="list-style-type: none"> • 인공신경망-GARCH 통합모형(NN-GARCH) • 인공신경망-EGARCH 통합모형(NN-EGARCH) • 인공신경망-EWMA 통합모형(NN-EWMA)

를 사후적인 실현된 변동성으로 사용한다. 수익률의 사후적변동성을 계산하기 위한 공식은 다음과 같다.

$$TRV_{\tau} = \sqrt{\frac{1}{\tau} \sum_{k=1}^{\tau} (r_{t,k} - \bar{r}_t)^2}$$

TRV : True Realized Volatility, 사후적 변동성

τ_t : t 시점 이후의 잔존일수(22거래일)

$$\bar{r}_t = \frac{1}{\tau_t} \sum_{k=1}^{\tau_t} r_{t,k} : t \text{ 시점 이후 } 22 \text{ 거래일 동안}$$

실현된 지수 수익률의 평균

$r_{t,k}$: t월 k일의 KOSPI 200 지수의 수익률

계산된 사후적변동성은 추정된 22거래일의 변동성과 비교하기 위하여 $\sigma_{22 \text{ days}} = \sigma_{1 \text{ day}} \times \sqrt{22}$ 식을 이용하여 22거래일 변동성으로 나타내었다.

4.2.2 변동성 예측력 평가

- 정확도(accuracy) 분석: 서로 다른 변동성의 예측값의 정확도(accuracy)를 비교하기 위한 측정 도구로서 아래와 같은 계산방법에 의한 MAE(Mean Absolute Error)를 사용한다.

$$MAE = \frac{1}{T} \sum |\hat{\sigma}_t - \sigma_t|$$

단, $\hat{\sigma}_t$ 는 모형에 의하여 예측된 22거래일 예측 변동성, σ_t 는 실제 미래 22거래일 동안 시장에서 실현된 변동성, T 는 예측치의 총 개수를 나타낸다.

- 방향성(적중률, Hit ratio) 분석: 변동성 예

측에 있어서 가격결정을 위한 예측치의 정확도뿐만 아니라 거래전략을 위한 방향성 고려되어야 한다. 따라서 본 연구에서는 예측 구간 동안 실현변동성의 변동성 증감 방향과 예측변동성의 증감방향을 서로 비교하는 적중률 분석(Hit ratio Analysis)을 실시한다. 방법은 아래와 같다.

$$if(sign(\sigma_t - \sigma_{t-1}) = sign(\hat{\sigma}_t - \hat{\sigma}_{t-1}), 1, 0)$$

예측변동성과 실현변동성의 차이의 부호가 서로 같으면 1을 반환하고 다르면 0을 반환하여 전체 예측 데이터 개수로 나누어 줌으로써 예측 구간의 Hit ratio를 구할 수 있다. 또한 one-period ahead forecast와 같이 시간에 따라 데이터 샘플의 윈도우(window)를 지속적으로 갱신하면서 다음 기의 변동성을 예측하는 경우의 방향성 비교는 예측시점 이전의 실현변동성과 예측시점의 실현변동성, 그리고 예측시점이전의 실현변동성과 예측시점의 예측변동성의 방향성을 서로 비교하는 것이므로 위의 식은 다음과 같이 수정된다.

$$if(sign(\sigma_t - \sigma_{t-1}) = sign(\hat{\sigma}_t - \sigma_{t-1}), 1, 0)$$

4.3 KOSPI 200 주가지수의 시계열적 특성분석

변동성 예측을 위한 시계열 모형 선택의 적정성 여부를 알아보기 위하여 KOSPI 200 주가지수 930개의 데이터(1999.1.12~2002.10.25)를 표본데이터로 정하고, ADF 검정 및 ARCH LM 검정을 통하여 시계열 특성을 분석하였다.

4.3.1 ADF 검정

ADF(Augmented Dickey-Fuller)검정은 시계열의 안정성 여부를 평가하는 방법으로 널리 쓰이는 것으로 KOSPI 200 주가지수의 일별 자료에 대한 안정성 검사를 실시한다. <그림 1>는 KOSPI 200 주가지수 일별 자료를 보여주고 있다.

ADF(Augmented Dickey-Fuller)검정결과 <표 4>와 같이 단위근(unit root)이 존재하므로 차분이 필요한 불안정한(nonstationary) 시계열임을 알 수 있다. 따라서 불안정한 시계열을 안정한 시계열로 변환하기 위하여 널리 쓰이는 방법중의 하나인 원 계열에 대한 자연대수 값의 차분을 취하는 KOSPI200 지수 수익률 시계열을 이용하기로 한

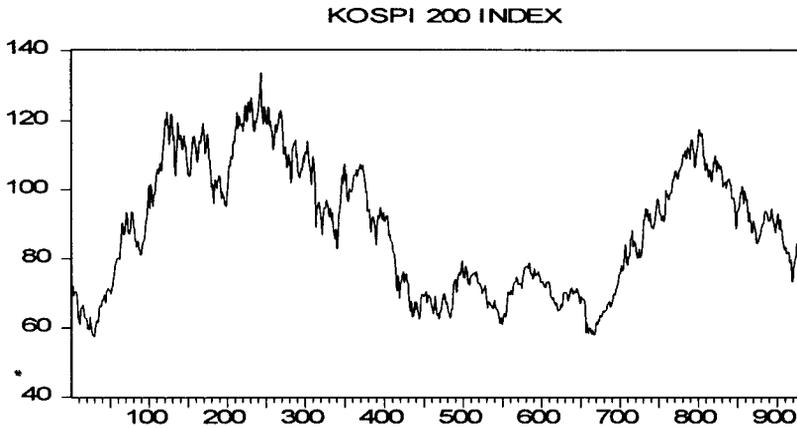
다. 지수수익률의 자연대수 값은 다음과 같다.

$$r_t = \ln \left(\frac{S_t}{S_{t-1}} \right)$$

<그림 2>는 표본구간의 지수수익률의 자연대수 시계열을 나타낸 것이다.

<표 5>의 ADF 테스트 결과 및 <그림 2>에서 볼 수 있는 것과 같이 평균을 중심으로 맴도는 안정적인(stationary) 시계열임을 알 수 있다.

<그림 1> KOSPI 200 주가지수 시계열

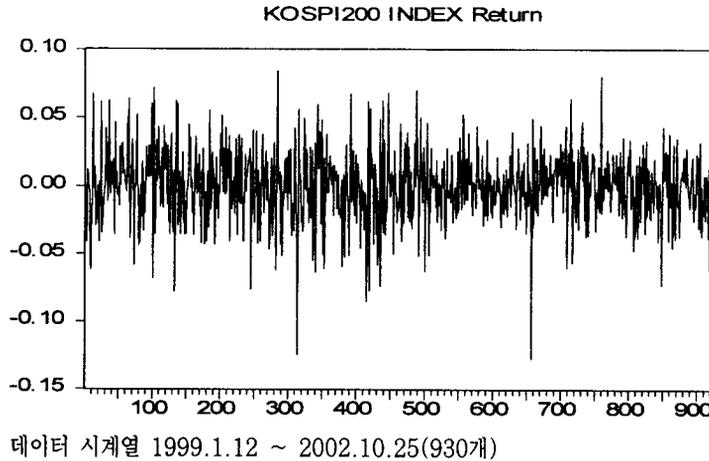


* 데이터 시계열 1999.1.12 ~ 2002.10.25(930개)

<표 4> KOSPI200지수의 시계열 안정성 검증

ADF Test Statistic	-1.929573	1% Critical Value*	-3.4401
		5% Critical Value	-2.8651
		10% Critical Value	-2.5687

〈그림 2〉 KOSPI 200 주가지수 수익률 자연대수 시계열



〈표 5〉 KOSPI200지수 수익률 시계열 안정성 검증

ADF Test Statistic	-29.15477	1% Critical Value*	-2.5679
		5% Critical Value	-1.9397
		10% Critical Value	-1.6158

4.3.2 ARCH LM 검정

시계열에 이분산성이 있는지를 테스트하기 위하여 ARCH LM 검정(Autoregressive Conditional Heteroscedasticity Lagrange Multiplier test)을 실시한다.

〈표 6〉의 결과에서 알 수 있듯이 ARCH-LM검정

의 귀무가설인 5시차까지 이분산성이 없다는 가설은 5%의 유의 수준으로 기각되므로 5시차까지 이분산성이 존재하며 5시차까지 모든 lagged squared residual의 joint significance 또한 F 통계량에 의하여 유의함을 알 수 있다. 따라서 KOSPI200 지수 시계열의 변동성은 ARCH 모형이 적합함을 알 수 있으며 본 논문에서 사용하는 GARCH(1,1)

〈표 6〉 5-lag ARCH-LM 검정 결과

ARCH Test: 5-lag			
F-statistic	2.3453	p-value	0.0396
Obs*R-squared	11.6543	p-value	0.0398

주) F-statistic: omitted variable test for the joint significance of all lagged squared residuals.

Obs*R-squared: Engle's LM test statistic, computed as the number of observation times the R square from the test regression.

모형은 반복적 대입과정을 통하여 ARCH(∞)모형으로 나타낼 수 있으므로 GARCH(1,1)으로 변동성을 추정하는 것이 보다 타당하다고 할 수 있다.

4.4 인공지능경망 전처리 및 학습과정

금융시계열모형에서 도출되는 변수를 제외한 시장 입력변수(market variables)는 증권거래소에서 제공하는 통계데이터를 중심으로 선정 하였으며 실제로 변동성 예측을 위한 지표로 사용되는 데이터들만을 선정 하였다. 인공지능경망에서는 입력변수가 많아 질수록 학습하는데 소요되는 시간이 증가하게 되며 데이터가 인공지능경망에 의하여 결정되는 모델을 지나치게 과적합(overfit)하게 될 뿐만 아니라 중요하지 않은 시장 변수의 움직임에 의하여 목표값이 영향을 받게 되는 역효과를 나타내지만 본 연구의 입력변수 개수는 Kean(1993)이 제안한 관측 자료수(시계열데이터셋 수)의 10% 미만 이므로 고려 하지 않았다.

시장 입력변수를 대상으로 상관분석을 실시하여 보면 모든 변수의 실현변동성과의 상관계수가 -5% ~5%의 구간을 벗어나는 범위(Hamid, 2002)에

있으므로 위의 변수들이 실현변동성과 상관관계가 있다고 추정 할 수 있다. 또한 변수의 유의성을 판단하기 위하여 t값을 이용하여 변수의 공헌도(contribution)를 판단하여 보면 p-value가 0.05 보다 큰 변수는 프리미엄평균, KOSPI200 주가지수 수익률, KOSPI200 주가지수, 과거1시차 KOSPI200 주가지수 인 것을 알 수 있다. 하지만 인공지능경망의 학습을 위하여 유효한 변수를 간과할 위험성을 적게 하기 위하여 위의 변수를 모두 입력변수에 포함 시키기로 한다. 또한 국고채 수익률뿐만 아니라 패턴 학습을 위하여 국고채 가격도 입력변수에 포함시켜 학습 하도록 한다. 따라서 위의 두 과정은 일반적인 입력변수의 선정과정으로 보면 되겠다.

데이터 전처리는 데이터 변환(Transformation), 데이터 정규화(Normalization), 이상잡음제거(Smoothing)의 순서로 진행된다. 본 연구에서는 입력변수들에 대하여 통계적으로 동일한 분포를 갖도록 변형 시키고 인공지능경망이 학습하기 쉬운 동일한 수준의 변수들로 변환시키기 위하여 데이터 정규화를 실시 하였다. 이상잡음 제거에 관하여는 입력변수에 대하여 관찰기간 중 IMF 충격에 의한 이상

(표 7) 입력변수 상관관계 분석 및 중회귀 분석

입력변수	실현변동성과 상관계수	t	p-value of t
과거 1시차 KOSPI200주가지수	0.1956	-0.8212	0.4116
국고채1년 수익률	0.5108	-2.6764	0.0075
국고채3개월 수익률	0.5477	7.7487	0
미결제약정수량	-0.3935	2.8942	0.0038
약정금액	-0.3867	2.1194	0.0342
약정수량	-0.3892	-2.1888	0.0288
프리미엄평균	0.3469	1.6703	0.0951
KOSPI200주가지수	0.1868	0.8305	0.4064
KOSPI200주가지수 수익률	-0.0767	-1.1632	0.2449
KOSPI200주가지수 수익률 제곱	0.2474	5.4709	0

변동성과 같은 특이한 잡음이 관찰 되지 않았으므로 본 과정에서는 생략하여도 무방하다고 가정 하였다.

본 연구에 사용하는 back-propagation network는 일반적인 3 layer 모형을 사용하며 은닉층 neuron의 개수를 각 모형 별로 입력변수의 1/2n, n, 3/2n, 2n+1(n: 입력변수의 개수)로 조정해 가며 실험군 중 가장 예측력이 뛰어난 것으로 선택하였다.

인공신경망 실험을 위하여 Neuroshell II Ver. 4.0을 실험 소프트웨어로 사용하였다.

4.5 금융시계열모형을 이용한 입력변수의 추정

4.5.1 인공신경망-GARCH 통합모형(NN-GARCH model) 입력변수

<표 8>는 1999년 1월 12일부터 2002년 10월 25일까지 KOSPI200 주가지수의 일별 시계열 자료를 기초로 계산된 GARCH(1,1) 모형의 추정 결과이다.

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

$$\sigma_t^2 = 0.0000605 + 0.064785 \varepsilon_{t-1}^2 + 0.836611 \sigma_{t-1}^2$$

GARCH(1,1)에 의하여 도출된 입력변수는 다

음과 같다.

- $\sigma_{t-1}^2 = 0.836611 \sigma_{t-1}^2$
- $\varepsilon_{t-1}^2 = 0.064785 \varepsilon_{t-1}^2$

4.5.2 인공신경망-EGARCH 통합모형 (NN-EGARCH model)의 입력변수

<표 9>는 EGARCH(1,1) 모형의 추정 결과이다.

$$\ln \sigma_t^2 = \alpha + \beta \ln \sigma_{t-1}^2 + \gamma \left(\frac{\varepsilon_{t-1}}{\sigma_{t-1}} - \sqrt{\frac{2}{\pi}} \right) + \omega \frac{\varepsilon_{t-1}}{\sigma_{t-1}}$$

$$\ln \sigma_t^2 = -0.842489 + 0.900850 \ln \sigma_{t-1}^2$$

$$+ 0.138036 \left(\frac{\varepsilon_{t-1}}{\sigma_{t-1}} - \sqrt{\frac{2}{\pi}} \right) - 0.062328 \frac{\varepsilon_{t-1}}{\sigma_{t-1}}$$

EGARCH에 의하여 도출된 입력변수는 다음과 같다.

- $\ln \sigma_{t-1}^2 = 0.900850 \ln \sigma_{t-1}^2$
- $LE(\text{leverage-effect})$
 $= 0.138036 \left(\frac{\varepsilon_{t-1}}{\sigma_{t-1}} - \sqrt{\frac{2}{\pi}} \right)$
- $L(\text{leverage}) = -0.062328 \frac{\varepsilon_{t-1}}{\sigma_{t-1}}$

<표 8> 변동성 예측을 위한 GARCH(1,1) 모형 추정결과

Variables	Coefficient	Std. Error	z-Statistic	Prob
C	0.000415	0.000738	0.561778	0.5743
α_0	0.000061	0.000025	2.454428	0.0141
α_1	0.064785	0.018685	3.467262	0.0005
β_1	0.836611	0.056275	14.86659	0.0000

(기간 : 1999.1.12~2002.10.25)

〈표 9〉 변동성 예측을 위한 EGARCH 모형 추정결과

Variables	Coefficient	Std. Error	z-Statistic	Prob.
α	-0.842489	0.270755	-3.111630	0.0019
γ	0.138036	0.035777	3.858272	0.0001
ω	-0.062328	0.016104	-3.870452	0.0001
β	0.900850	0.033850	26.61323	0.0000

(기간 : 1999.1.12~2002.10.25)

4.5.3 인공신경망-EWMA 통합모형
(NN-EWMA)의 입력변수

- $\sigma_{t-1}^2 = 0.97\sigma_{t-1}^2$
- $\varepsilon_{t-1}^2 = 0.03\varepsilon_{t-1}^2$

EWMA 모형 추정을 위하여 λ (스무딩상수)를 0.97로 정한다. 따라서 EWMA는 다음과 같이 나타낼 수 있다.

$$\sigma_t^2 = 0.97\sigma_{t-1}^2 + (1-0.97)\varepsilon_{t-1}^2$$

EWMA에 의하여 도출된 입력변수는 다음과 같다.

4.5.4 모형별 입력변수 학습 예상 효과

모형들에 의하여 도출된 학습 예상효과를 정리하여 보면 〈표 10〉과 같다. 도출된 입력변수를 이용한 학습효과를 비교분석 하기 위하여 기존의 논문에서 사용하였던 NN(일반 인공신경망모형)모형을

〈표 10〉 모형별 도출변수 및 예상 학습효과

모형	도출변수 및 학습 예상효과
NN	• σ_{t-1}^2 : 반복적 시행착오 없이 단순 이전시점의 변동성 학습
NN-GARCH	• $\sigma_{t-1}^2 = 0.836611\sigma_{t-1}^2$: 이전시점과의 조건부 변동성 관계 학습
	• $\varepsilon_{t-1}^2 = 0.064785\varepsilon_{t-1}^2$: 조건부변동성 학습을 위한 이전 시점의 잔차 효과 학습
NN-EGARCH	• $\ln \sigma_{t-1}^2 = 0.900850 \ln \sigma_{t-1}^2$: 이전시점과의 조건부 변동성 관계 학습
	• $L(\text{leverage}) = -0.062328 \frac{\varepsilon_{t-1}}{\sigma_{t-1}}$: 레버리지 효과 학습
	• $LE(\text{leverage-effect}) = 0.138036 \left(\frac{\varepsilon_{t-1}}{\sigma_{t-1}} - \sqrt{\frac{2}{\pi}} \right)$: 레버리지 효과에 의한 비대칭적인 충격반응 학습
NN-EWMA	• $\sigma_{t-1}^2 = 0.97\sigma_{t-1}^2$: 이전시점 변동성 영향의 가중치 조정 학습
	• $\varepsilon_{t-1}^2 = 0.03\varepsilon_{t-1}^2$: 이전시점 잔차 영향의 가중치 조정 학습

추가 시켰으며 NN 모형은 모형간 예측력 비교를 위하여 이 후의 실증분석에 있어서 계속 사용하기로 한다.

V. 결과

5.1 단일 모형과 통합모형간 비교

본 과정은 인공신경망, GARCH(1,1), 인공신경망-GARCH(1,1)(NN-GARCH)모형의 예측력 비교를 통하여 정확성, 방향성 관점에서 인공신경망모형과 GARCH(1,1)모형의 장점들을 NN-GARCH 모형을 통하여 구현 할 수 있음을 확인 한다. 이를 위하여 <표 2>의 예측구간데이터를 이용하여 우선 60일 예측구간에 대하여 예측력 비교분석을 실시한다. 이 후 통합모형간 비교시에는 예측구간을 160일로 확장하여 결과에 대한 신뢰도를 높이기로 한다.

5.1.1 방향성 비교(direction comparison)

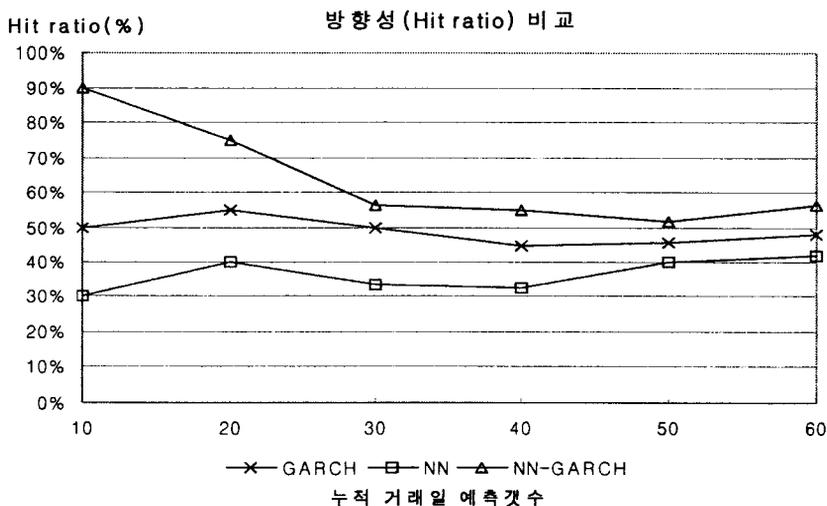
<그림 3>은 2002년 10월 28일부터 2003년 1월 23일까지 60일간의 방향성 예측력을 비교하였다.

예측구간이 짧을수록 통합모형인 NN-GARCH 모형의 방향성 예측력이 가장 뛰어나며 누적 거래일 예측갯수가 커짐에 따라 최종적으로 NN대비 36%, GARCH대비 17%의 예측력 상승을 나타낸다. 따라서 NN-GARCH, GARCH, NN 순서로 방향성의 예측력이 있다고 말 할 수 있다. 그러므로 NN보다 GARCH모형의 방향성 예측이 뛰어나며 두 모형의 통합을 통해 NN-GARCH 모형은 NN모형의 방향성 예측력을 GARCH 모형 이상으로 상승시켰다고 결론 내릴 수 있다.

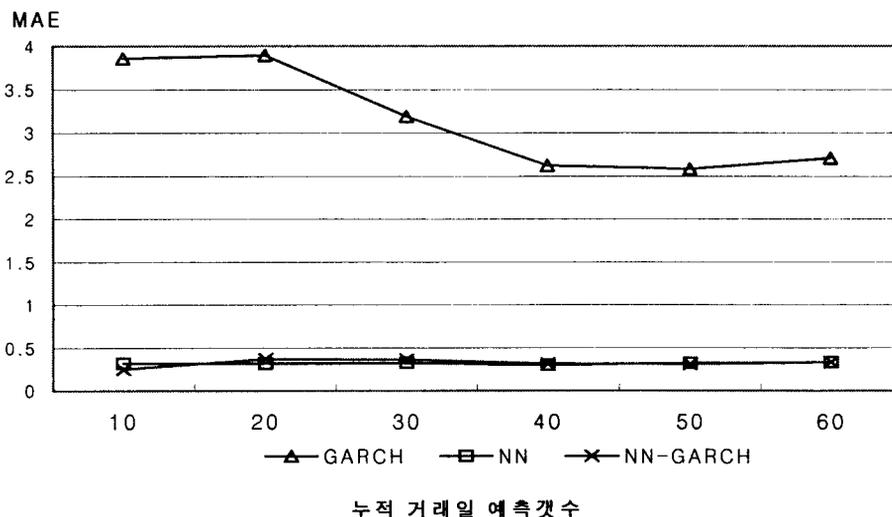
5.1.2 정확성 비교(precision comparison)

<그림 4>는 2002년 10월 28일부터 2003년 1월 23일까지 60일간의 예측값의 정확도를 비교하

<그림 3> 모형간 방향성 예측력 비교



〈그림 4〉 예측 구간별 MAE 비교



였다. GARCH모형의 예측값에 대한 MAE가 다른 모형에 비하여 매우 큰 것을 알 수 있으며 NN 모형에 비하여 NN-GARCH모형은 큰 정확성의 상승은 가져 올 수 없지만 GARCH 모형에 비하여는 상당한 수준의 정확도를 향상 시킬 수 있음을 알 수 있다.

따라서 위의 모형간 방향성, 정확성 분석을 통하여 NN-GARCH 모형이 NN 모형의 정확도와 GARCH모형의 방향성 예측력을 동시에 충족 시키는 모형임을 알 수 있다. 이 결과를 정리하면 〈표 11〉과 같다.

그러므로 본 연구의 다음 과제로서 GARCH의 금융시계열모형(EGARCH, EWMA)과 인공지능

망 모형과의 통합을 통하여 금융시계열모형 중 어떠한 모형과 통합한 인공지능망 모형의 예측력이 가장 우수한 지에 대하여 알아보고 그 원인에 대하여 분석해 보고자 한다.

5.2 통합모형간 비교

본 과정은 인공지능망-금융시계열 통합모형간 예측력을 비교함으로써 어떠한 통합모형이 예측력이 가장 우수한지에 대하여 알아보고 그 원인에 대하여 분석하고자 한다. 분석하고자 하는 통합모형은 앞서 언급한 NN-GARCH모형과 NN-EGARCH, NN-EWMA 모형으로서 정확도 및 방향성 예측력

〈표 11〉 모형간 예측력 비교

예측력	NN	GARCH	NN-GARCH
방향성(Hit ratio)	41%	48%	56%
정확도(MAE)	0.33	2.7	0.33

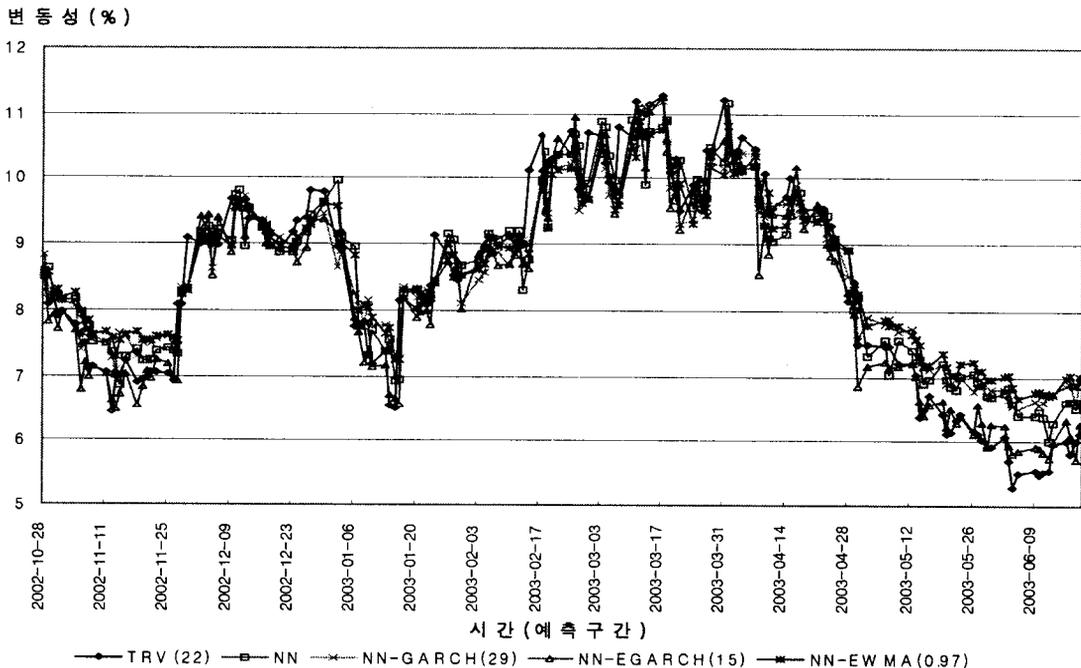
비교를 통하여 분석을 실시 한다.

각 모형의 예측력을 비교하기 위하여 실현변동성과의 MAE 및 Hit ratio를 계산하여 모형들의 예측력을 평가하기로 한다. <그림 5>는 각 모형의 변동성 예측결과를 나타낸 그래프로 각 변동성 모형에 의한 예측값들이 실현변동성의 움직임을 비교적 잘 따라가고 있음을 알 수 있다. 따라서 금융시계열 모형에서 도출한 입력변수들이 인공신경망을 이용하여 변동성을 예측하는데 있어서 예측력 있는 학습효과를 나타내고 있음을 알 수 있다. 실제로 인공신경망 학습을 통하여 얻어진 각 변수들의 상대

가중치 값(relative contribution factor)들은 이러한 사실을 입증하여준다. <표 12>는 인공신경망 학습을 통하여 구하여진 상대가중치 값을 나타낸다.

<표 12>를 보면 각 금융시계열모형에 의하여 도출된 입력변수들의 가중치들이 입력변수로 사용된 그 밖의 시장변수들 보다 가중치가 평균 4배 이상 높다. 또한 NN에서 NN-EWMA - NN-GARCH - NN-EGARCH 모형으로 갈수록 도출된 입력변수들의 가중치 값이 금융시계열 모형으로 표현되는 각 변수들의 계수비율과 유사한 비율로 가중치가 조정되는 것을 볼 수 있다. 이러한 결과로써 금융

<그림 5> 모형별 변동성예측 결과 그래프



- 주) TRV(22) : 22 거래일 실현변동성(true realized volatility)
- NN : 인공신경망 모형(Artificial Neural Network Model)
- NN-GARCH(29) : 인공신경망-GARCH(1,1) 모형(노드수:29개)
- NN-EGARCH(15) : 인공신경망-EGARCH 모형(노드수:15개)
- NN-EWMA(0.97) : 인공신경망-EWMA 모형(Decay factor λ : 0.97)

〈표 12〉 상대 가중 연결 강도

입력(학습)변수	NN	NN-EWMA	NN-GARCH	NN-EGARCH
KOSPI200 주가지수 수익률 제곱	0.0518	0.0532	0.0567	0.0393
약정수량	0.0545	0.0452	0.0421	0.0422
과거1시차 KOSPI200 주가지수	0.0568	0.0489	0.0504	0.0516
KOSPI200 주가지수 수익률	0.0583	0.0626	0.0602	0.0534
국고채 3개월 가격	0.0596	0.0555	0.0567	0.0614
국고채 1년 수익률	0.0605	0.0519	0.0561	0.0489
미결제 약정수량	0.0633	0.0555	0.0564	0.0528
프리미엄 평균	0.0654	0.0623	0.0693	0.0606
약정금액	0.0667	0.0591	0.0593	0.0566
국고채1년가격	0.0674	0.0593	0.0623	0.0576
국고채 3개월 수익률	0.0685	0.0556	0.0549	0.0558
KOSPI 200 주가지수	0.0731	0.0722	0.0648	0.0680
σ_{t-1}^2	0.2542			
$\sigma_{t-1}^{\prime 2} = 0.97\sigma_{t-1}^2$		0.2244		
$\varepsilon_{t-1}^{\prime 2} = 0.03\varepsilon_{t-1}^2$		0.0946		
$\sigma_{t-1}^{\prime 2} = 0.836611\sigma_{t-1}^2$			0.2144	
$\varepsilon_{t-1}^{\prime 2} = 0.064785\varepsilon_{t-1}^2$			0.0963	
$\ln \sigma_{t-1}^{\prime 2} = 0.900850 \ln \sigma_{t-1}^2$				0.2176
<i>LE(leverag e-effect)</i>				0.0778
<i>L(leverag e)</i>				0.0565
합 계	1.0000	1.0000	1.0000	1.0000

시계열모형에 의하여 도출된 입력변수들의 통계적인 의미가 학습 후에도 상대가중치배분(relative contribution allocation)에 의하여 유사하게 나타나고 있음을 알 수 있다. 또한 상대가중치 배분 결과에 의하여 새로운 변수 추출을 통한 통합모형을 제시 할 수 있는 근거로 활용 가능하다.

통합모형과 금융시계열모형과의 중요한 차이점이

자 특징은 다음과 같이 논할 수 있다. 인공신경망 학습 이전에 금융시계열모형에 의하여 도출된 입력 변수들이 변동성에 영향을 미치는 다양한 시장변수와 함께 인공신경망을 통해 학습되어 시장변수들에 의한 실제 실현변동성(realized volatility)의 패턴에 맞게 현실적으로 재조정 된 것으로 해석할 수 있다. 따라서 금융시계열모형에서 얻을 수 있는 도

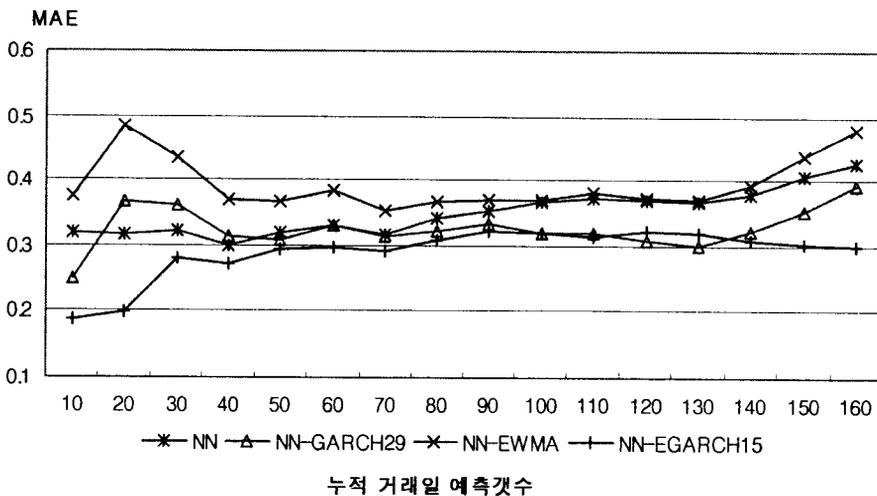
출 입력변수들의 계수(가중치)가 현실적으로 재 조정됨으로써 예측력 향상에 기여하게 되는 것이다.

〈그림 5〉를 보면 NN 모형과 NN-EWMA 모형은 실현변동성을 그림자처럼 1시차 후행 하는 모습을 나타내고 있으며 이에 반해 NN-GARCH, NN-EGARCH 모형은 실현변동성의 움직임을 크기와 방향성 관점에서 잘 따라가고 있음을 확인할 수 있다. 이와 같은 변동성 예측이 파생상품의 가격 결정뿐만 아니라 거래전략을 위하여 진정한 의미를 갖기 위해서는 예측치의 정확성(Precision) 뿐만 아니라 방향성(Direction)도 동시에 만족시켜야 한다. 그러므로 그래프를 통한 시각적인 판단과 함께 각 모형의 예측치 결과에 대한 정확성(precision)을 MAE(Mean Absolute Error)를 통하여 분석하고 방향성(direction)을 적중률 분석(Hit ratio analysis)을 통하여 알아보도록 하겠다.

〈그림 6〉에서 160일 MAE의 값은 NN-EWMA > NN > NN-GARCH > NN-EGARCH의 순서를 나타내고 있다. NN-EWMA는 NN보다도 오히려

MAE가 크게 관찰 되었는데 금융시계열모형 자체에서도 입증된 것처럼 λ (decay factor)에 의한 과거 변동성의 조정은 시계열모형 뿐만 아니라 인공신경망 입력변수로서도 성공적이지 않다는 것을 위의 결과를 통하여 확인할 수 있다. 따라서 금융시계열모형으로서 예측효과가 성공적이지 않은 모델에 의해 도출된 입력변수는 인공신경망의 학습효과에 있어서도 성공적이지 않다는 것을 간접적으로 알 수 있다. 이러한 사실은 금융시계열모형으로서 예측력이 우수하다고 입증된(Hu, 1999) EGARCH 모형에 의하여 변수를 도출한 NN-EGARCH 모형이 가장 MAE가 작은 결과를 나타내는 사실로서도 알 수 있다. NN-EGARCH모형은 NN-GARCH모형에 Leverage-Effect 변수를 추가시켜 예측력을 높인 시계열모형으로서 레버리지(leverage), 레버리지효과(leverage-effect) 학습변수의 사용과 조건부변동성을 나타내는 이전시점 변동성 제곱의 대수 로그값을 입력변수로 대입하여 학습시킨 통합모형이다. 그 결과 EGARCH 모형뿐만 아니라 NN-EGARCH 모형에

〈그림 6〉 모형별 MAE 비교



서도 뛰어난 예측 성과를 나타내고 있으며, 이러한 결과는 <표 13>과 같이 NN모형에 대비하여 인공신경망-금융시계열 통합모형이 얼마만큼의 예측력을 상승시킬 수 있는지 알아봄으로써 명백하게 알 수 있다.

<그림 6>과 <표 13>의 결과로서 NN-GARCH와 NN-EGARCH모형이 NN모형에 비하여 MAE관점에서 예측력을 크게 향상시킬 수 있음을 추정할 수 있다. 특히 NN-GARCH 모형(7.67% 상승)에 비하여 NN-EGARCH모형(29.43% 상승)이 정확성(precision)관점에서 예측력이 월등하게 뛰어난 모형이라는 것을 알 수 있으며 이러한 예측력의 상승은 EGARCH에 의하여 도출된 입력변수(레버리지변수, 레버리지효과변수)가 뛰어난 예측력을 발휘

하였기 때문에 추정할 수 있다. NN-EGARCH 모형의 예측력 상승에 대한 통계적 유의성을 살펴보기 위하여 모형간 일원분산분석(One-way ANOVA)을 통하여 살펴본다.

<표 14>를 보면 NN과 NN-EGARCH, NN-EWMA와 NN-EGARCH 모형의 MAE가 1% 유의 수준에서 서로 다르다는 것을 알 수 있다. 따라서 NN-EGARCH 모형에 의하여 NN, NN-EWMA 보다 MAE를 감소시킬 수 있다는 것을 통계적으로 입증할 수 있다. 또한 NN-GARCH 모형과 NN-EGARCH 모형의 MAE의 차이는 10% 유의수준에서 유의하므로 NN-EGARCH모형의 정확성 예측력이 10% 유의수준에서는 우수하다고 할 수 있

<표 13> NN 대비 통합모형의 예측력 상승효과(MAE)

누적거래일예측갯수	NN-EWMA	NN-GARCH	NN-EGARCH
20	-52.53%	-15.87%	36.94%
40	-23.61%	-5.15%	8.70%
60	-16.00%	-0.19%	9.99%
80	-7.26%	5.45%	9.42%
100	-0.96%	13.03%	12.57%
120	-0.51%	16.91%	13.16%
140	-4.16%	14.86%	18.21%
160(전체구간)	-12.42%	7.67%	29.43%
예측력 상승 순위	NN-EWMA	< NN-GARCH29	< NN-EGARCH15
계산식	$\text{예측력 상승} = \frac{(MAE_{NN} - MAE_{\text{비교모형}})}{MAE_{NN}}$		

<표 14> 절대오차평균 비교를 위한 일원분산분석

	NN	NN-EWMA	NN-GARCH	NN-EGARCH
NN		0.5638	0.8543	***0.0098
NN-EWMA	0.5638		0.1492	***0.0000
NN-GARCH	0.8543	0.1492		*0.1000
NN-EGARCH	***0.0098	***0.0000	*0.1000	

*** 1% significance level ** 5% significance level * 10% significance level

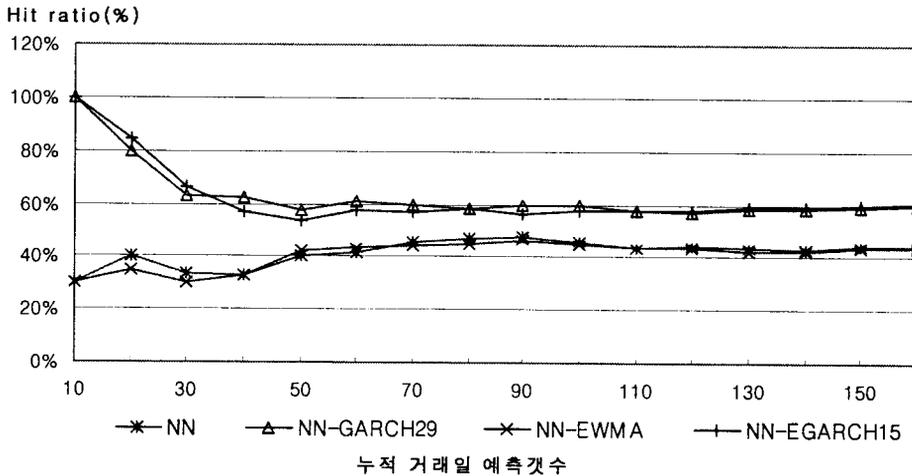
지만 그 이하의 유의수준에서는 두 모형간 예측력의 차이가 없음을 확인할 수 있다.

다음은 각 모형들의 방향성(Direction) 예측력을 비교하여 보도록 한다. 방향성 예측력은 <그림 7>의 적중률 분석(hit ratio analysis)을 통하여 비교할 수 있으며, NN-GARCH, NN-EGARCH 모형에 의하여 NN모형의 Hit ratio를 크게 향상시킬 수 있다. NN모형은 실현변동성을 그림자처

럼 후행하는 모습을 나타내고 있으며 이러한 이유로 실현변동성의 방향성 예측에 있어서도 이전 시점의 방향성을 변동성 예측에 그대로 반영하는 결과를 나타냄으로써 Hit ratio는 감소하고 결과적으로 방향성 관점에서의 예측력은 떨어지게 된 것이다. 이러한 NN모형의 단점은 NN-GARCH, NN-EGARCH 모형에 의하여 해결 할 수 있다.

<그림 7>과 <표 15>를 보면 NN모형(43.75%)에

<그림 7> 모형별 방향성(Hit ratio) 비교



<표 15> 모형별 방향성(Hit ratio) 데이터

누적거래일 예측일수	NN	NN-EWMA	NN-GARCH29	NN-EGARCH15
10	30.00%	30.00%	100.00%	100.00%
20	40.00%	35.00%	80.00%	85.00%
30	33.33%	30.00%	63.33%	66.67%
40	32.50%	32.50%	62.50%	57.50%
60	41.67%	43.33%	61.67%	58.33%
80	47.50%	45.00%	58.75%	58.75%
100	46.00%	45.00%	60.00%	58.00%
120	44.17%	43.33%	57.50%	58.33%
140	42.86%	42.14%	58.57%	59.29%
160	43.75%	43.13%	60.00%	60.63%

비하여 NN-GARCH모형(60.00%), NN-EGARCH 모형(60.63%)의 Hit ratio가 크게 상승된 것을 볼 수 있으며 특히 누적거래일 예측일수 초기에 두 드러진 상승현상을 나타낸다. 따라서 단기변동성에 축(누적거래일갯수 30일 미만)에서 통합모형의 방향성 예측력이 더 우수함을 확인 할 수 있다. 아래의 <표 16>은 통합모형의 NN대비 예측력 상승효과를 나타낸 것이다.

<표 16>을 보면 NN-GARCH(37.14%), NN-EGARCH(38.57%) 모형에 의하여 큰 폭으로 방향

성 예측력이 상승된 것을 알 수 있다. NN-GARCH, NN-EGARCH모형에 의한 방향성 예측력 상승이 통계적으로 유의 한지 검증하기 위하여 예측모형간의 McNemar Test를 실시해 보면 <표 17>과 같다.

<표 17>에서 보면 NN모형과 NN-GARCH, NN 모형과 NN-EGARCH, NN-EWMA와 NN-GARCH, NN-EWMA와 NN-EGARCH모형이 1% 유의 수준에서 Hit ratio에 차이가 있으며 따라서 통합모형 중 NN-GARCH모형과 NN-EGARCH모형이 NN, NN-EWMA모형에 비하여 우수한 방향성 예

<표 16> NN 대비 통합모형의 예측력 상승효과(Hit ratio)

누적거래일예측갯수	NN-EWMA	NN-GARCH29	NN-EGARCH15
20	-12.50%	100.00%	112.50%
40	-0.00%	92.31%	76.92%
60	-4.00%	48.00%	40.00%
80	5.26%	23.68%	23.68%
100	-2.17%	30.43%	26.09%
120	-1.89%	30.19%	32.08%
140	-1.67%	36.67%	38.33%
160(전체구간)	-1.43%	37.14%	38.57%
예측력 상승 순위	NN-EWMA	< NN-GARCH29	< NN-EGARCH15
계산식	$\text{예측력 상승} = \frac{(\text{HitRatio}_{\text{비교모형}} - \text{HitRatio}_{\text{NN}})}{\text{HitRatio}_{\text{NN}}}$		

<표 17> 예측모형간의 McNemar Test

	NN & NN-EWMA	NN & NN-GARCH	NN & NN-EGARCH	NN-EWMA & NN-GARCH	NN-EWMA & NN-EGARCH	NN-GARCH & NN-EGARCH
N(예측일수)	160	160	160	160	160	160
Chi-Square		8.2236	11.4576	11.4576	12.5689	0
Asymp. Sig.		***0.0041	***0.0007	***0.0007	***0.0003	1
Exact Sig. (2-tailed)	1					

*** 1% significance level

측을 나타내고 있음을 검증 할 수 있다. 또한 NN-GARCH와 NN-EGARCH간에 Hit ratio의 차이는 유의하지 않다는 사실을 통해 두 모형은 방향성 예측에 있어서 큰 성과 차이를 나타내지 않는 것으로 확인되었다.

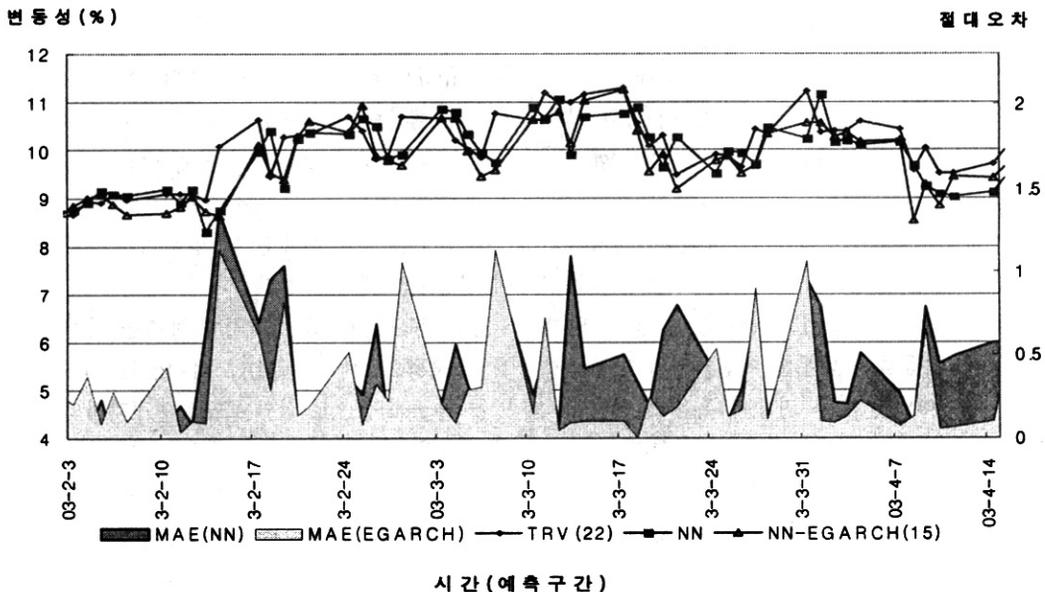
MAE, Hit ratio 분석을 통하여 NN-GARCH 모형과 NN-EGARCH모형이 정확성뿐만 아니라 방향성 예측에 있어서도 NN 모형에 비하여 뛰어난 성과를 나타낸다는 것을 알아보았다. 이러한 논리로서 금융시계열모형에 의한 변수도출을 통하여 입력변수를 조정하고 Leverage-Effect와 같은 새로운 변수를 만들어냄으로써 모형의 전체적인 예측력 상승을 기대 할 수 있다. <그림 8>은 시각적으로 예측력의 변화를 확인 하기 위하여 단기예측구간을 나타낸 그래프이다. NN는 실현변동성(True Realized Volatility: TRV)에 1시차 후행 하는

모습을 나타내고 있으며 NN-EGARCH모형은 NN에 비하여 정확성과 방향성 면에서 실현변동성을 유사한 수준으로 예측하고 있음을 알 수 있다. 특히 아래 부분의 절대오차 비교그래프를 보면 NN모형이 그림자특성으로 인하여 방향성을 정확하게 예측하지 못한 결과 발생한 MAE를 NN-EGARCH모형이 큰 폭으로 감소 시키고 있는 것을 확인할 수 있다.

VI. 결론

본 연구에서는 KOSPI200 주가지수의 변동성을 예측하기 위하여 금융시계열모형과 인공신경망모형을 통합한 통합모형을 제시하였다. 우선 단일 모형

<그림 8> 확대구간 비교 그래프



의 통합을 통한 예측력 향상이 실제로 가능한지에 대하여 GARCH(1,1)모형과 인공신경망 모형, 인공신경망-GARCH(1,1) 통합모형간에 정확성, 방향성 차원에서 예측력을 비교함으로써 통합모형에 의하여 예측력을 향상시킬 수 있음을 확인할 수 있었다. 또한 이 결과를 바탕으로 통합모형간 예측력 비교로서 금융시계열모형인 EWMA, GARCH, EGARCH 모형을 바탕으로 인공신경망 학습을 위한 입력변수를 도출하고, 이를 학습시킴으로써 얻게 된 인공신경망-금융시계열 통합모형들간의 예측력 비교를 통하여 가장 예측력이 우수한 통합모형으로서 NN-EGARCH 모형을 제시 할 수 있었다. 이러한 연구결과를 요약하면 다음과 같다.

첫째, 인공신경망-금융시계열통합모형을 통하여 모형의 예측력을 향상 시킬 수 있다. 인공신경망 모형을 위한 입력변수를 도출함에 있어서 금융시계열모형을 바탕으로 예측하고자 하는 도메인(KOSPI200 주가지수 시계열)에 대한 통계적인 분석과 이를 통하여 추정된 시계열모형을 통해서 학습력이 뛰어난 입력변수를 도출할 수 있었다. 또한 도출된 입력변수를 인공신경망 모형에 대입하여 학습시킴으로써 금융시계열모형(방향성 예측)과 인공신경망모형(예측 정확도)의 장점을 결합한 예측력 상승을 얻을 수 있었다.

둘째, 통합모형으로써 기존의 단일인공신경망의 단점인 시행착오를 통한 최적 예측값 추정의 반복적인 과정(repetitive trial error)을 대폭 줄일 수 있다. 기존 논문들은 대부분 이전시점의 변동성을 입력변수로 대입할 경우 가중치 혹은 입력변수 선택에 있어서 계속적인 반복적 학습을 통하여 최적의 예측값을 위한 조정계수(혹은 가중치)를 도출하였다. 본 연구에서는 입력변수 선정에 있어서 통계적방법론에 근거한 예측도메인(KOSPI200 주가

지수 시계열)의 분석과 시계열모형의 추정을 통하여, 입력변수 선정 및 입력변수의 가중치 조정계수를 반복적 시행착오 없이 금융시계열 모형에 의하여 선정함으로써 입력변수 선정 및 학습과정에 있어서 효율성 및 통계적 근거를 마련하였다. 또한 이 방법 외의 입력변수들(시장변수)은 통계적으로 도출된 변수들을 현실적으로 조정하여주는 역할로 가정함으로써 금융시계열모형에 의하여 도출된 변수들이 설명할 수 없는 다양한 시장현상들을 모형 내에 반영하기 위한 현실적인 조정과 함께 체계적인 인공신경망 입력변수 선정과 학습과정의 단축을 실현하였다.

셋째, 금융시계열모형의 장점과 인공신경망의 장점을 현실적으로 결합하여 가장 예측력이 우수한 인공신경망-금융시계열통합모형을 제시하였다. 통합에 의하여 예측력이 향상될 수 있음을 실증분석을 통하여 알 수 있었으며 이러한 사실을 바탕으로 다양한 금융시계열모형(GARCH, EGARCH, EWMA)들과 인공신경망과의 통합을 통하여 정확도와 방향성 예측관점에서 가장 예측력이 뛰어난 모형(NN-EGARCH)을 제시 할 수 있었다. NN-EGARCH 모형의 예측력이 우수한 원인에 대하여 통계적인 분석을 실시 하였으며 그 원인에 대하여 실증 분석을 하였다.

본 연구가 갖는 한계점 및 향후 연구방향에 대하여 언급하면 다음과 같다.

첫째, KOSPI200 주가지수 예측을 위한 금융시계열 모형으로써 EWMA, GARCH, EGARCH만을 연구 대상으로 삼았으므로 연구과정의 일반적인 적용을 위하여 이 외의 시계열모형에 대한 검증이 필요하다. 실제로 KOSPI200 주가지수의 특성이 장기기억(long term memory)을 잘 설명할 수 있는 ARFIMA(Autoregressive fractionally

integrated moving average)를 바탕으로 한 NN-ARFIMA 모형에 대한 예측력 상승 분석에 대한 연구가 필요하다. 향후 ARFIMA를 이용한 도메인 분석과 통합모형의 예측결과 분석을 통하여 본 연구의 결과들을 재 입증할 필요가 있다.

둘째, 인공신경망과 같은 범주로서 예측도메인의 장기기억 및 입력변수의 다중스케일 효과(Multiscale effect)를 잘 설명하는 것으로 알려진(Gavrishchaka, 2003) SVM(Support Vector Machine)과 금융시계열모형에 대한 통합의 시도가 필요하다(Kim, 2003). 금융시계열모형 뿐만 아니라 학습 모형도 마찬가지로 예측 도메인을 잘 반영하는 모형을 통해 예측력을 향상시킬 수 있으므로 향후 SVM과 같은 새로운 학습 모형을 이용하여 예측을 하는 것이 본 연구의 논리상 필요하다고 하겠다.

셋째, 인공신경망의 다양한 장점에도 불구하고 인공신경망을 현실적으로 적용하는데 있어서 논리적으로 부딪히는 한계점으로서, 모형 자체가 논리적으로 블랙박스(black box)라는 특성과 입력변수 선정의 어려움, 오랜 학습시간, 과적합(overfitting) 및 반복적 시행착오(repetitive trial and error)로 인한 시간소요 등의 문제 또한 이 연구의 문제점으로 지적될 수 있다.

참고문헌

- Ahmadi, H. (1990). "Testability of the arbitrage pricing theory by neural networks," Proceedings of the International Conference on Neural Networks, San Diego, CA. 385 - 393.
- Armano, G., Marchesi, M., and Murru, A. (2005). "A hybrid genetic-neural architecture for stock indexes forecasting," *Information Sciences*, 170, 3-33.
- Blum, A., and Langley, P. (1997). "Selection of relevant features and examples in machine learning," *Artificial Intelligence*, 97(1-2), 245-271.
- Bolland, P. J., and Burgess, A. N. (1996). "Forecasting volatility mispricing," *Decision technology for Financial Engineering*, NNCM96, 214-224.
- Bollerslev, T. (1986). "Generalized autoregressive conditional heteroscedasticity," *Journal of Econometrics*, 31, 307-327.
- Brooks, C. (1998). "Predicting stock index volatility: Can market volume help?" *Journal of Forecasting*, 17, 59 - 80.
- Choi, J.H., Lee, M.K., and Rhee, M.W. (1995). "Trading S&P 500 stock index futures using a neural network," Proceedings of the Third Annual International Conference on Artificial Intelligence Applications on Wall Street, New York. 63 - 72.
- Donaldson, R. G., and Kamstra, M. (1997). "An artificial neural network-GARCH model for international stock return volatility," *Journal of Empirical Finance*, 4, 17-46.
- Duke, L.S. and Long, J.A. (1993). "Neural network futures trading-a feasibility study: Society for Worldwide Inter-bank Financial Telecommunications," *Adaptive intelligent systems*, Elsevier, Amsterdam, 121 - 132.
- Engle, R. F. (1982). "Autoregressive conditional heteroscedasticity with estimator of the variance of United Kingdom inflation," *Econometrica*, Vol.50(4), 987-1008.
- Gavrishchaka, V., and Ganguli, S. B. (2003).

- "Volatility forecasting from multi-scale and high dimensional market data," *Neurocomputing*, 55, 285-305.
- Hamid, S. A., and Zahid, I. (2002). "Using neural networks for forecasting volatility of S&P 500 Index futures prices," *Journal of Business Research*, 5881, 1-10.
- Hecht-Nielsen, R. (1990). *Neurocomputing*. MA: Addison-Wesley.
- Hiemstra, Y. (1995). "Modeling structured nonlinear knowledge to predict stock market returns", In: Trippi, R.R., Editor, 1995. *Chaos and nonlinear dynamics in the financial markets: theory, evidence and applications*, Irwin, Chicago, IL, 163 - 175.
- Hu, M. Y., and Tsoukalas, C. (1999), "Combining conditional volatility forecasts using neural networks: an application to the EMS exchange rates," *Journal of International Financial Markets, Institution and Money*, 9, 407-422.
- JP Morgan and Reuters. (1996). "RiskMetrics - Technical document," Fourth Edition, New York.
- Kamijo, K., and Tanigawa, T. (1990). "Stock price pattern recognition: a recurrent neural network approach," Proceedings of the International Joint Conference on Neural Networks, San Diego, CA. 215 - 221.
- Kean, J. (1993). "Neural nets and stocks: training a predictive system," *PC AI*, 7, 45-47.
- Kim, K. (2003). "Financial time series forecasting using support vector machines," *Neurocomputing*, 55, 307-319.
- Kim, K. and Han, I. (2000). "Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index," *Expert Systems with Applications*, 19(2), 125-132.
- Kimoto, T., Asakawa, K., Yoda, M., and Takeoka, M. (1990). "Stock market prediction system with modular neural network," Proceedings of the International Joint Conference on Neural Networks, San Diego, California. 1 - 6.
- Kohara, K., Ishikawa, T., Fukuhara, Y., and Nakamura, Y. (1997). "Stock price prediction using prior knowledge and neural networks," *International Journal of Intelligent Systems in Accounting, Finance and Management*, 6(1), 11 - 22.
- Lawrence, S., Tsoi, A. C., and Giles, C. L. (1996). "Noisy time series prediction using symbolic representation and recurrent neural network grammatical inference," Institute for Advanced computer Studies, Technical report UMIACS-TR-96-27 and CS-TR-3625. University of Maryland.
- Liu, H., and Motoda, H. (1998). "Feature transformation and subset selection," *IEEE Intelligent Systems and Their Application*, 13(2), 26-28.
- McCulloch, W.S., and Pitts, W. (1943). "A logical calculus of the idea immanent in nervous activity," *Bulletin of Mathematical Biophysics*, 5, 115-133.
- Nelson, D. B. (1991). "Conditional heterosdasticity in asset returns: A new approach," *Econometrica*, 59(2), 347-370.
- Oh, K.J. and Han, I. (2000). "Using change-point detection to support artificial neural networks for interest rates forecasting," *Expert Systems with Applications*, 19(2), 105-115.
- Rosenblatt, F. (1958). "The perception: A probabilistic model for information storage and

- organization in the brain," *Psychological Review*, 65, 386-408.
- Trippi, R.R. and DeSieno, D. (1992). "Trading equity index futures with a neural network," *The Journal of Portfolio Management*, 19, 27 - 33.
- Tsaih, R., Hsu, Y., and Lai, C.C. (1998). "Forecasting S&P 500 stock index futures with a hybrid AI system," *Decision Support Systems*, 23(2), 161 - 174.
- Yao, J. T., Li, Y., and Tan, C. L. (2002). "Option price forecasting using neural networks," *Omega*, 28, 455-466.

Forecasting the volatility of KOSPI 200 Using Neural Network-financial Time Series Model

Tae Hyup Roh* · Taeck-ho Lee** · Ingoo Han***

Abstract

As various funds and derivatives are developed using KOSPI 200 index, many investment banks and investment trust get interests on risk management of KOSPI 200 index. Accurate volatility estimation and prediction is the core in risk management in which various portfolio's pricing, hedging, and option strategy is exercised by estimating volatilities. Up to now, many financial institutions give more values on risk management, but the methodologies of it are not established systematically. Many researchers have tried to forecast volatilities more accurately using financial time series models. Historically, many papers for volatility forecasting have concentrated on the comparison between forecasting models, but these researches focus on improving the predictive power of models by integrating ANN and financial time series models.

In this paper, we first show that financial time series models, GARCH, outperforms existing ANN in forecasting the direction of volatility and that ANN model excels GARCH in reducing the precision error of the forecasted volatility by analyzing KOSPI 200 index time series data. Based on these results, this study propose the integrated model between ANN model and financial time series model to forecast volatilities of KOSPI 200 index time series. For selecting input variables for ANN model, new variable can be extracted by the financial time series models through analyzing the KOSPI 200 domain time series statistically. Then, these newly selected input variables can enhance the predictive power in the perspectives of precision error and direction accuracy through ANN learning process. The ANN-financial time series integrated model can enhance the predictive power by comparing the forecasted

* KAIST Techno Management Research Center.

** Industrial Bank of Korea.

*** KAIST Graduate School of Management.

volatilities by single models in the framework of precision error(MAE) and direction accuracy(hit ratio). Especially, the integrated NN-EGARCH model is proposed as most predictive integrated model in forecasting volatilities in the perspectives of precision error and hit ratio simultaneously.

In addition to prediction power, the integrated models can reduce time which it takes to adjust input variables by repetitive trial and error. Most of existing studies have adjusted the weight of raw volatilities by repetitive trial and error of learning process and found the optimal coefficient of input variables to produce the best results. This study finds the coefficients of input variables by financial time series process at once and extracts new variables that greatly influence the results through analyzing KOSPI 200 domain statistically without time consumption. At the same time, we consider market variables as those that adjust extracted variables to reflect true market behaviors. Therefore, integrated models can adjust variables realistically by ANN process and reduce time consumption by financial time series models.

Key words: Volatility Prediction, Financial Time Series Analysis, Artificial Neural Network.