

웨이블릿 변환과 퍼지 신경망을 이용한 단기 KOSPI 예측

Forecasting Short-Term KOSPI using Wavelet Transforms and Fuzzy Neural Network

신동근*, 정경용**
삼육대학교 컴퓨터학부*, 상지대학교 컴퓨터정보공학부**

Dong-Kun Shin(dkshin@syu.ac.kr)*, Kyung-Yong Chung(dragonhci@hanmail.net)**

요약

KOSPI는 정치 및 경제를 포함한 다양한 요소에 영향을 받는 관계로 정확한 단기 KOSPI 예측 방법론 개발은 매우 어려운 문제로 여겨지고 있다. 본 논문에서는 가중 퍼지소속함수 기반 신경망(NEWFM; neural network with weighted fuzzy membership functions)의 특징 추출기법을 사용하여 5일 동안의 주가 단기추세를 예측하는 방안을 제안한다. 비중복면적 분산 측정법에 의해 중요도가 가장 낮은 특징입력을 하나씩 제거하면서 최소의 특징입력을 선택한다. 특징입력으로써 기술지표를 이용하여 얻은 데이터를 웨이블릿 변환을 이용하여 39개의 계수들을 추출한다. 이들 39개의 특징입력 중 비중복면적 분산측정법에 의해서 추출된 12개의 계수가 사용된다. 제안된 방법에서는 민감도가 72.79%, 특이도가 74.76%, 정확도가 73.84%를 나타낸다.

■ 중심어 : | 단기추세 | 퍼지신경망 | 웨이블릿 변환 | 특징선택 |

Abstract

The methodology of KOSPI forecast has been considered as one of the most difficult problem to develop accurately since short-term KOSPI is correlated with various factors including politics and economics. In this paper, we presents a methodology for forecasting short-term trends of stock price for five days using the feature selection method based on a neural network with weighted fuzzy membership functions (NEWFM). The distributed non-overlap area measurement method selects the minimized number of input features by removing the worst input features one by one. A technical indicator are selected for preprocessing KOSPI data in the first step. In the second step, thirty-nine numbers of input features are produced by wavelet transforms. Twelve numbers of input features are selected as the minimized numbers of input features from thirty-nine numbers of input features using the non-overlap area distribution measurement method. The proposed method shows that sensitivity, specificity, and accuracy rates are 72.79%, 74.76%, and 73.84%, respectively.

■ keyword : | Short-Term Trend | Fuzzy Neural Networks | Wavelet Transforms | Feature Selection |

* 이 논문은 2010년도 삼육대학교 학술연구비 지원에 의한 결과임.

접수번호 : #110329-007

접수일자 : 2011년 03월 29일

심사완료일 : 2011년 04월 07일

교신저자 : 신동근, e-mail : dkshin@syu.ac.kr

I. 서론

금융 예측을 위해서 과거의 통계적 지표를 기반으로 금융추세를 예측하는 비선형 시계열 예측 방법[4], 손익 결정 시스템을 이용한 주식거래[1], 경기전환점 예측 [3][9] 등이 연구되었다. 하지만 최근에는 주가 예측을 위해 신경망이나 신경망과 퍼지집합 이론을 결합한 퍼지신경망(fuzzy neural network, FNN)이 제안되어 왔다[6-8][11][17][18]. 하지만 이러한 주가 예측 방법들은 주로 1일 후의 주가를 예측하기 위한 방법으로 제안되었다. 주성분 분석을 이용하여 기술 지표로부터 추출한 특징을 신경 회로망을 이용하여 종합주가지수 예측 모형의 개발하였다[17]. 또한 웨이블릿 변환을 이용하여 기술 지표로부터 웨이블릿 계수들을 추출하여 1일 후의 주가를 예측하였다[18]. 일반적으로 1일 후의 주가를 예측하는 경우에 있어서 60%이하의 낮은 정확도를 나타내고 있다[6][11]. 이러한 낮은 정확도를 실제의 주식 예측에 적용하는 것은 위험 요소가 있다. 따라서 실제 주식시장에서는 1일 후의 주가 예측과 더불어 통산 6일 미만의 단기적 주가 움직임인 단기 추세나 6일 이상의 장기적 주가 움직임인 장기 추세를 결합하여 주가 예측에 활용하고 있다[13]. 본 논문에서도 1일 후의 주가 예측에 도움이 되고자 5일간의 주가 단기추세 예측을 위한 방안을 제안한다.

본 논문은 가중 퍼지소속함수를 이용한 신경망(NEWFM: neural network with weighted fuzzy membership functions)[2][10]을 이용한 5일간의 주가 단기추세 예측을 위하여 비중복면적 분산측정법을 사용하여 여러 개의 특징입력 중에서 중요도가 가장 낮은 특징입력을 자동적으로 하나씩 제거하면서, 최소화된 특징입력으로 최대값의 예측성능을 구하는 방안을 제안하고 있다. NEWFM은 각 입력에 대해 퍼지이론의 경계합[2][10]을 이용하여 예측 또는 분류를 위한 가중 퍼지소속함수들을 생성한다. 또한 비중복면적 분산측정법[12]을 이용하여 중요도가 가장 낮은 특징입력을 하나씩 제거하면서 최소화된 특징입력을 찾을 수 있다. 이와 같이 단순화된 최소의 특징입력에 대한 가중 퍼지소속함수들로 간단한 퍼지규칙을 만들 수 있으며 예측

이나 분류의 효율을 낮추는 특징입력을 제거함으로써 더욱 효과적인 결과를 줄 수 있다.

본 논문은 NEWFM 기반의 비중복면적 분산측정법을 사용하여 Haar 웨이블릿 변환을 통하여 생성된 39개의 특징입력으로부터 중요도가 가장 낮은 특징입력을 자동적으로 하나씩 제거해가면서 가장 높은 분류성능을 구하는 실험을 하였다. 이러한 실험을 통해 12개의 최소 특징입력을 추출하고, 이 최소 특징입력들에 대한 학습된 가중 퍼지소속함수를 제시하고 있다. 자동 추출된 12개의 최소 특징입력이 실험군에 적용될 수 있음을 검증하기 위해[11]에서 사용한 KOSPI 실험군을 활용하였다. 또한 NEWFM의 5일간의 주가 단기추세 예측 성능을 평가하기 위해서 역전파 알고리즘[14], SVM[16]과의 비교를 시도하였다.

II. 주가 단기추세 예측 모델의 설계

[그림 1]은 주가 단기추세 예측 모델 다이어그램으로써 KOSPI 데이터를 입력 값으로 하여 기술지표를 선택하여 전처리 과정을 수행한다. 전처리 과정 후에 웨이블릿 변환을 이용하여 초기 특징입력을 추출하고 NEWFM기반의 비중복면적 분산측정법[12]을 이용하여 분류성능이 가장 좋은 최소의 특징입력을 추출하게 된다.




그림 1. 주가 단기추세 예측 모델 다이어그램

2.1 전처리 과정

[그림 1]에서 설명하고 있는 전처리 과정을 하기 위해서 본 논문에서는 Lee[7]가 새로운 기술 지표로써 제안한 CPPn,m(current price position of the day n)을 사용하였다. CPPn,5는 기준일 n의 종가(closing price)가

n-1일부터 n-5일까지의 이동평균에 대해 어느 위치에 있는지를 나타내는 기술지표이다. 또한 5일 동안의 주가 단기추세를 예측하기 위해서 내일부터 5일 동안의 KOSPI 평균값이 과거부터 오늘까지의 5일 동안의 KOSPI 평균값보다 높으면 2인 클래스로 분류하고 낮으면 1인 클래스로 분류한다.

2.2 웨이블릿 변환

Haar 웨이블릿 변환은 [그림 2]와 같이 수행되어진다 [15]. [그림 2]는 이분 비연속 Haar 웨이블릿 분리 구현을 위한 필터뱅크를 보여주고 있으며 d_i 와 a_i 는 각각 스케일 레벨 i 의 detail과 approximation 계수들을 의미한다.

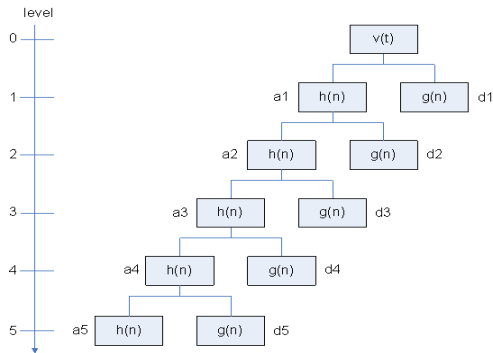


그림 2. 스케일 레벨 5인 이분 비연속 웨이블릿 변환

본 논문에서는 초기 특징입력을 추출하기 위해 [그림 1]의 전처리 과정에서 $CPP_{n,5}$ 로부터 31일 전인 $CPP_{n-31,5}$ 까지의 32개 $CPP_{n,5}$ 를 하나의 윈도우로 정한다. 하나의 윈도우는 [그림 2]에서와 같이 스케일 레벨 5인 이분 비연속 Haar 웨이블릿 변환을 수행하여 [표 1]에서처럼 순번 2부터 39번까지 38개의 웨이블릿 계수를 생성한다. [그림 3]은 38개의 웨이블릿 계수들을 구하는 방법에 대해 기술한다. 하나의 윈도우는 32개의 $CPP_{n,5}$ 로 구성되어 있는데 하나의 윈도우와 다음의 윈도우는 [그림 3]에서처럼 31개의 $CPP_{n,5}$ 가 겹치도록 하나씩 이동시키면서 웨이블릿 변환을 수행된다.

본 논문에서는 웨이블릿 변환된 계수들을 0부터 1까지의 값으로 정규화하기 위하여 식(1)의 시그모이드 함수를 사용한다.

$$f(s) = \frac{1}{1 + e^{-s}}, \quad s \text{는 웨이블릿 변환값} \quad (1)$$




그림 3. 웨이블릿 변환을 위한 윈도우 사이즈 설정

III. 단기 KOSPI 예측을 위해 사용한 퍼지 신경망

3.1 가중 퍼지소속함수 기반 신경망

NEWFM[2][10]은 입력으로부터 학습된 가중 퍼지소속함수의 경계함을 이용하여 클래스 분류를 하는 지도 학습 퍼지 신경망이다. 가중 퍼지소속함수의 경계함을 가중치를 갖는 대, 중, 소의 3개 퍼지소속함수의 경계함을 하나의 퍼지소속함수로 합성한 것이다. NEWFM의 구조는 [그림 4]에서 보는 바와 같이 입력, 하이퍼박스, 클래스의 3개 계층으로 구성되어 있다. 입력 계층에는 n 개의 입력노드들로 구성되며 각 입력노드는 하나의 특징입력을 입력받게 된다. 하이퍼박스 계층은 m 개의 하이퍼박스 노드로 구성되고, 1번째 하이퍼박스 노드 B_1 은 단 하나의 클래스 노드에 연결되며 n 개의 퍼지집합을 갖는다.

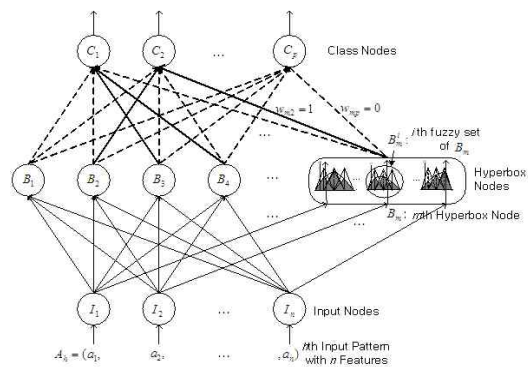


그림 4. 가중 퍼지소속함수 신경망의 구조

[그림 4]의 특징 추출 과정에서 웨이블릿 변환된 계수들이 n개의 특징입력을 갖는 h번째 입력 $A_h = (a_1, a_2, \dots, a_n)$ 에 대한 NEWFM의 입력값으로 사용된다.

3.2 비중복면적 분산 측정법을 이용한 특징 선택

퍼지규칙이나 중요한 특징입력을 선택하는 것은 최근 연구에서 언급되어지고 있다[5][12]. [그림 1]의 웨이블릿 변환으로부터 생성된 39개의 초기 특징입력 중 중요도가 가장 낮은 특징입력을 자동적으로 하나씩 제거하면서 예측성능이 가장 높은 12개의 최소 특징입력을 추출한다. 이는 i번째 특징입력에 대해 식(2)에 의해 그 중요도를 측정한다. 여기서 $Area_U$ 와 $Area_L$ 은 각각 상승 및 하락에 대해 더 우세한 퍼지함수의 면적을 의미한다.

$$f(i) = (Area_U^i + Area_L^i)^2 / \left(\frac{1}{1 + e^{-|Area_U^i - Area_L^i|}} \right) \quad (2)$$

[그림 5]는 주가 단기추세의 상승과 하락의 예측을 위한 39개의 초기 특징입력으로부터 식(2)에 의해 측정된 중요도가 가장 높은 것과 가장 낮은 것에 대한 가중 퍼지소속함수의 경계합(BSWFM: bounded sum of weighted fuzzy membership functions)[2][10]의 예를 보여주고 있다. 흰 부분과 검은 부분의 면적이 각각 $Area_U$ 와 $Area_L$ 을 나타내고 있다. $Area_U + Area_L$ 면적이 넓으면서 $Area_U$ 와 $Area_L$ 의 넓이가 균등히 분산되어 있으면 두 클래스를 분류할 수 있는 특징을 더 많이 가지고 있다고 볼 수 있다.

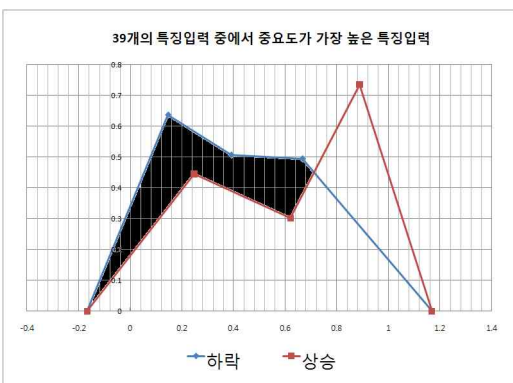


그림 5. 가중 퍼지소속함수의 경계합(BSWFM)

[그림 5]는 39개의 초기 특징입력 중에서 중요도가 가장 높은 것과 가장 낮은 가중 퍼지소속함수의 경계합(BSWFM)을 나타낸다. [그림 6]은 가중 퍼지소속함수의 경계합(BSWFM)에 대한 비중복면적 분산측정법을 이용한 특징입력 순위 누적의 예를 나타낸다.

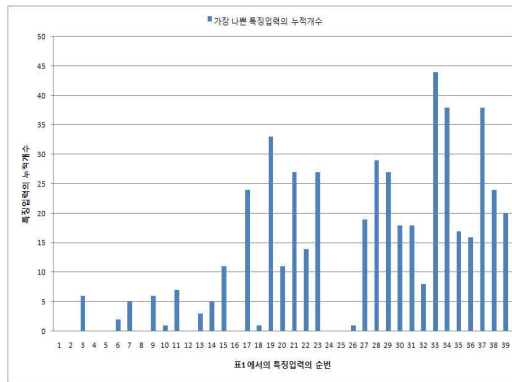


그림 6. 특징입력 순위 누적의 예

[그림 6]은 비중복면적 분산측정법 알고리즘에 의해서 [그림 5]에서 특징입력이 39개 일 때 가장 좋은 특징입력과 가장 나쁜 특징입력의 누적개수를 구한 것이다. 이는 500회의 훈련과 테스트로 얻은 것으로서, 39개의 특징입력 중에서 33번째 특징입력(d1의 열 번째 계수)이 가장 나쁜 특징입력으로 나타난다. 따라서 다음 실험에서는 33번째의 특징입력을 삭제한 후에 실험을 하게 된다. [표 1]은 초기 특징입력으로 사용한 39개의 웨이블릿 계수를 나타내었고 중요도가 높아 최종 선택된

12개의 최소 특징입력을 "√"로 표시하였다.

표 1. 웨이블릿을 통해 생성된 특징입력

순번	웨이블릿 계수	선택	순번	웨이블릿 계수	선택
1	CPPn,5	√	21	여섯 번째 계수	
2	a5 첫 번째 계수	√	22	일곱 번째 계수	
3	d5 첫 번째 계수	√	23	여덟 번째 계수	
4	a4 첫 번째 계수	√	24	첫 번째 계수	√
5	a4 두 번째 계수	√	25	두 번째 계수	√
6	d4 첫 번째 계수	√	26	세 번째 계수	
7	d4 두 번째 계수		27	네 번째 계수	
8	a3 첫 번째 계수	√	28	다섯 번째 계수	
9	a3 두 번째 계수		29	여섯 번째 계수	
10	a3 세 번째 계수	√	30	일곱 번째 계수	
11	d3 네 번째 계수		31	여덟 번째 계수	
12	d3 첫 번째 계수	√	32	아홉 번째 계수	
13	d3 두 번째 계수		33	열 번째 계수	
14	d3 세 번째 계수		34	열한 번째 계수	
15	d3 네 번째 계수		35	열두 번째 계수	
16	d2 첫 번째 계수	√	36	열세 번째 계수	
17	d2 두 번째 계수		37	열네 번째 계수	
18	d2 세 번째 계수		38	열다섯 번째 계수	
19	d2 네 번째 계수		39	열여섯 번째 계수	
20	다섯 번째 계수		40		

추세의 하락으로 분류되는 것을 의미한다. 민감도, 특이도, 정확도는 식(3)과 같이 정의된다.

$$\begin{aligned} \text{민감도} &= \frac{TP}{TP+FN} \times 100 \\ \text{특이도} &= \frac{TN}{TN+FP} \times 100 \\ \text{정확도} &= \frac{TP+TN}{TP+FN+TN+FP} \times 100 \end{aligned} \quad (3)$$

표 2. KOSPI 실험군

Training Instances	Test Instances	Total Instances
2347개	581개	2928개

표 3. BP의 성능평가 (학습율 : 0.01, 운동량 : 0.7)

Epochs	은닉층 노드의 개수	정확도(%)	특이도(%)	민감도(%)
20000	2	64.89	65.93	63.64
	4	66.78	68.54	64.87
	6	66.78	68.06	65.31
30000	2	62.82	64.04	61.36
	4	67.99	69.26	66.54
	6	65.92	66.56	65.12
40000	2	63.86	65.08	62.41
	4	65.92	67.54	64.13
	6	65.23	66.78	63.5

IV. 실험 결과

본 논문에서는 5일간의 주가 단기추세 예측을 위해서 KIM[11]이 1일 후의 KOSPI 예측을 위해서 사용한 2928개의 KOSPI 실험군을 사용하였다. [표 2]에서 설명하고 있듯이 2928개의 전체 실험군에서 훈련집합을 위해 2347개의 KOSPI 실험군이 사용되었고, 테스트 집합을 위해 581개의 KOSPI 실험군이 사용되었음을 보여주고 있다. 이러한 실험군은 Kim이 1일 후의 주가 예측에 사용한 KOSPI 실험군과 동일하다[11]. 식(3)은 분류 성능 평가를 위해 사용되었으며 사용된 식들의 의미는 다음과 같다. TP(True Positive)는 5일간의 주가 단기추세의 상승이 5일간의 주가 단기추세의 상승으로 분류되는 것을, FP(False Positive)는 5일간의 주가 단기추세의 하락이 5일간의 주가 단기추세의 상승으로 분류 되는 것을 의미한다. TN(True Negative)은 5일간의 주가 단기추세의 하락이 5일간의 주가 단기추세의 하락으로 분류되는 것을 의미하며 FN(False Negative)은 5일간의 주가 단기추세의 상승이 5일간의 주가 단기

표 4. SVM의 성능평가

커널	차수	정확도(%)	특이도(%)	민감도(%)
Polynomial	1	71.43	72.79	69.93
	2	63.51	65.55	61.35
	3	71.95	72.61	71.16
	4	64.54	68.54	61.15
	5	69.36	70.82	67.75
	6	63.86	67.66	60.58
	7	66.95	69.15	64.69
	8	60.76	64.31	57.69
	9	67.3	69.9	64.73
Dot		71.43	72.79	69.93

표 5. NEWFM, SVM, BP간의 성능평가

	정확도(%)	특이도(%)	민감도(%)
NEWFM	73.84	74.76	72.79
SVM	71.95	72.61	71.16
BP	67.99	69.26	66.54

[표 3]과 [표 4]에서는 5일간의 주가 단기추세 예측을 위한 NEWFM의 성능을 평가하기 위해서 BP[14],

SVM[16]과의 비교를 시도한다. [표 5]에서 NEWFM, SVM, BP는 각각 73.84%, 71.95%, 67.99%라는 정확도를 보여주고 있다. BP의 경우는 [표 3]에서 epochs, 은닉층 노드의 개수에 따른 실험결과를 나타낸다. BP의 실험에서는 학습율은 0.01, 운동량은 0.7로 설정한다. [표 3]의 BP 실험결과에서 epoch가 30000, 은닉층 노드의 개수가 4개일 때 가장 높은 정확도를 나타낸다. BP에는 최소의 특징입력 추출을 위한 방법이 없기 때문에 39개의 특징입력을 이용한 결과이다.

SVM의 경우는 [표 4]에서 커널과 차수에 따른 실험결과를 정리하였다. SVM의 실험결과에서 알 수 있듯이 커널이 polynomial이고 차수가 3일 때 가장 높은 정확도를 나타내었다. SVM도 BP와 마찬가지로 최소의 특징입력 추출을 위한 방법이 없기 때문에 39개의 특징입력을 이용하여 구한 결과 값이다. NEWFM 분류성능에 있어서는 비중복면적 분산 측정법을 이용하여 선택한 12개의 최소 특징입력을 이용하여 구한 결과 값이다.

V. 결 론

본 논문에서는 NEWFM과 비중복면적 분산측정법을 이용하여 중요도가 가장 낮은 특징입력을 자동적으로 하나씩 제거하면서 5일 간의 주가 단기추세 예측을 위한 최소의 특징입력을 선택하는 방안을 제안하였다. 이는 자동적으로 구한 최소의 특징입력을 이용하여 5일 간의 주가 단기추세의 상승과 하락에 대한 최고의 예측 성능을 구하는 방안을 기술하였다. 최소의 특징 선택을 위해 비중복면적 분산측정법을 이용하여, 최근 32일간의 CPPn,5값을 웨이블릿 변환한 38개 계수와 CPPn,5값 중 12개의 최소 특징입력을 추출하였다. 비중복면적 분산측정법은 불필요하거나 예측결과에 악영향을 주는 특징입력을 제거함으로써 특징입력의 수를 최소화 시켜주고 가장 높은 예측성능을 구할 수 있게 해준다. NEWFM과 비중복면적 분산측정법을 이용한 실험한 결과에서 5일 간의 주가 단기추세의 상승과 하락에 대한 73.84%의 정확도를 보여주었다.

향후 연구에서는 상승과 하락의 반환점을 정확히 예

측하는 연구가 필요하다. 일정 기간 동안 주가가 상승하는 과정에서도 특정 시점에서는 상승과 하락이 발생하게 된다. 이에 따른 구체적인 예측 알고리즘이 필요하다.

참 고 문 헌

- [1] K. K. Ang and C. Quek, "Stock Trading Using RSPOP: A Novel Rough Set-Based Neuro-Fuzzy Approach," *IEEE Trans. Neural Networks*, Vol.17, No.5, pp.790-802, 2006.
- [2] J. S. Lim, "Finding Features for Real-Time Premature Ventricular Contraction Detection Using a Fuzzy Neural Network System," *IEEE Trans. Neural Networks*, Vol.20, Issue 3, pp.522-527, 2009.
- [3] S. H. Chai and J. S. Lim, "Economic Turning Point Forecasting Using Fuzzy Neural Network and Non-Overlap Area Distribution Measurement Method," *The Korean Economic Association*, Vol.23, No.1, pp.111-130, 2007.
- [4] T. V. Gestel, "Financial Time Series Prediction Using Least Squares Support Vector Machines Within the Evidence Framework," *IEEE Trans. Neural Networks*, Vol.12, No.4, pp.809-821, 2001.
- [5] S-M Zhou and J. Q. Gan, "Constructing L2-SVM- Based Fuzzy Classifiers in High-Dimensional Space With Automatic Model Selection and Fuzzy Rule Ranking," *IEEE Trans. on Fuzzy Systems*, Vol.15, No.3, pp.398-409, 2007.
- [6] T. Ray, H. Yenshan, and C. Charles, "Forecasting S&P 500 Stock Index Futures with a Hybrid AI System," *Decision Support Systems*, Vol.23, Issue 2, pp.161-174, 1998.
- [7] S. H. Lee, J. S. Lim, "KOSPI Time Series

Analysis Using Neural Network with Weighted Fuzzy Membership Functions," LNAI 4953, pp.53-62, 2008.

[8] K. J. Kim, "Artificial Neural Networks with Evolutionary Instance Selection for Financial Forecasting," Expert Systems with Applications, Vol.30, Issue 3, pp.519-526, 2006.

[9] Q. Min "Predicting US Recession with Leading Indicators via Neural Network Models," International Journal of Forecasting, Vol.17, Issue 3, pp.383-401, 2001.

[10] J. S. Lim, "Finding Fuzzy Rules by Neural Network with Weighted Fuzzy Membership Function," International Journal of Fuzzy Logic and Intelligent Systems, Vol.4, No.2, pp.211-216, 2004.

[11] K. J. Kim, "Financial Time Series Forecasting using Support Vector Machines," Neurocomputing, Vol.55, Issues 1-2, pp.307-309, 2003.

[12] J. S. Lim, S. Gupta, "Feature Selection Using Weighted Neuro-Fuzzy Membership Functions," The International Conference on Artificial Intelligence, Vol.1, pp.1301-1315, Las Vegas, Nevada, 2004.

[13] S. A. George, P. V. Kimon, "Forecasting Stock Market Short-Term Trends using a Neuro-Fuzzy based Methodology," Expert Systems with Applications, Vol.36, Issue 7, pp.10696-10707, 2009

[14] M. Suryanarayana, B. Darcy, "Analysis of Feed forward Backpropagation Neural Networks used in Vehicle Detection," Transportation Research Part C: Emerging Tech., Vol.3, Issue 3, pp.161-174, 1995.

[15] S. Mallat, "Zero Crossings of a Wavelet Transform," IEEE Trans. Inf. Theory, Vol. 37, No.4, pp.1019 - 1033, 1991.

[16] B. Schölkopf, A. J. Smola, R. C. Williamson, P. L. Bartlett, "New Support Vector Algorithms," Neural Computation, Vol.12, pp.1207-1245, 2000.

[17] 이은진, 민철홍, 김태선, "신경 회로망과 통계적 기법을 이용한 종합주가지수 예측 모형의 개발", 전자공학회 논문지, 제45권, 제5호, 2008.

[18] 이상홍, 임준식, "KOSPI 예측을 위한 NEWFM 기반의 특징입력 및 퍼지규칙 추출", 한국 인터넷 정보학회 논문지, 제9권, 제1호, 2007.

저 자 소 개

신 동 근(Dong-Kun Shin)

정회원



- 1986년 : 인하대학교 전자계산학과 졸업(학사)
 - 1996년 : 동국대학교 대학원 전자계산학과 졸업(공학석사)
 - 2010년 : 인하대학교 대학원 컴퓨터정보공학과 졸업(공학박사)
 - 1997년 9월 ~ 2006년 2월 : 삼육의명대학 컴퓨터정보과 교수
 - 2006년 3월 ~ 현재 : 삼육대학교 컴퓨터학부 교수
- <관심분야> : Neuro-Fuzzy System, HCI, Software Engineering

정 경 용(Kyung-Yong Chung)

정회원



- 2000년 2월 : 인하대학교 전자계산공학과(공학사)
 - 2002년 2월 : 인하대학교 컴퓨터정보공학과(공학석사)
 - 2005년 8월 : 인하대학교 컴퓨터정보공학과(공학박사)
 - 2005년 9월 ~ 2006년 2월 : 한세대학교 IT학부 교수
 - 2006년 3월 ~ 현재 : 상지대학교 컴퓨터정보공학부 교수
- <관심분야> : 지능시스템, 데이터마이닝, 상황인식, 웨어러블 컴퓨팅, HCI, 바이오센서, IT융합