

자동 특징 추출기법에 의한 최소의 주식예측 특징선택

Minimized Stock Forecasting Features Selection by Automatic Feature Extraction Method

이상홍 · 임준식*

Sang-Hong Lee and Joon S. Lim*

경원대학교 컴퓨터소프트웨어학과

Dept. of Computer Software, Kyungwon University

요 약

본 논문은 가중 퍼지소속함수 기반 신경망(Neural Network with Weighted Fuzzy Membership Functions, NEWFM)기반의 자동 특징 추출기법을 사용하여 1일 후의 주식 예측을 하는 방안을 제안하고 있다. 비중복면적 분산측정법에 의해 중요도가 가장 낮은 특징입력을 자동적으로 하나씩 제거하면서 최소의 특징입력을 선택하였다. 특징입력으로써 $CPP_{n,m}$ (Current Price Position of the day n)과 최근 32일간의 $CPP_{n,m}$ 을 웨이블릿 변환한 38개의 계수들 중 비중복면적 분산측정법에 의해서 자동적으로 추출된 2개의 계수가 사용되었다. 제안된 방법으로 1989년부터 1998년까지의 실험군을 사용한 결과로서 60.93%의 예측율을 나타내었다.

키워드 : 퍼지 신경망, 특징선택, 웨이블릿변환, 주식

Abstract

This paper presents a methodology to 1-day-forecast stock index using the automatic feature extraction method based on the neural network with weighted fuzzy membership functions (NEWFM). The distributed non-overlap area measurement method selects the minimized number of input features by automatically removing the worst input features one by one. $CPP_{n,m}$ (Current Price Position of the day n : a percentage of the difference between the price of the day n and the moving average from the day $n-1$ to the day $n-m$) and the 2 wavelet transformed coefficients from the recent 32 days of $CPP_{n,m}$ are selected as minimized features using bounded sum of weighted fuzzy membership functions (BSWFM). For the data sets, from 1989 to 1998, the proposed method shows that the forecast rate is 60.93%.

Key Words : Fuzzy Neural Networks, Feature Selection, Wavelet Transforms, Stock

1. 서 론

패턴 분류나 진단, 예측 등을 위해 신경망 및 퍼지집합 이론을 결합한 적응적 의사결정지원 툴(Adaptive Decision Support Tool)인 퍼지신경망(Fuzzy Neural Network, FNN)이 제안되어 왔다[2,6,8-10,12,15,19,21-22]. 여러 가지 구조의 FNN이 학습(Learning), 적응(Adaptation), 규칙추출(Rule Extraction)을 위한 알고리즘과 더불어 제시된 바 있다[5,8,13,16,18]. 주어진 일련의 학습 데이터로부터 지식 추출을 위하여 자기 조직화 시스템(Self-Organizing System) 기반 퍼지신경망이 개발되었다[7,20-21]. Setnes[15]는 유전자 알고리즘을 이용하여 간단하고 정확도가 높은 퍼지규칙 기반 모델을 얻는데 초점을 맞추었다.

이러한 지능형 시스템을 이용하여 금융 예측을 위한 응용이 다양하게 이루어지고 있다. 과거의 통계적 지표를 기

반으로 금융추세를 예측하는 비선형 시계열 예측 방법[4], 손익 결정 시스템을 이용한 주식거래[1], 경기전환점 예측[3,17] 등이 연구되고 있다.

KIM은 KOSPI 예측을 위하여 12개의 기술지표(Technical Indicator)를 SVM(Support Vector Machine)의 특징입력으로 이용하였다[11]. Tsaih는 S&P 500 예측을 위하여 10개의 기술지표를 Reasoning Neural Networks의 특징입력으로 이용하여 학습하였다[24]. 또한 이렇게 학습된 결과를 이용하여 몇 가지 규칙(Rule)을 생성하여 규칙 기반 시스템(Rule-Based System)을 구성하였다. 그러나 KIM[11]은 해석이 가능한 일반적인 규칙을 제공할 수 없다. 또한 예측성능을 높이기 위하여 각각의 지표들을 -1부터 1사이의 값으로 정규화 하여 실시간 시스템에는 사용이 어렵다는 단점을 지니고 있다. Tsaih[24]는 일반화된 규칙을 제공하고는 있으나 실험군이 달라지면 적용하기 어렵고 규칙을 생성하는 과정이 여러 단계의 복잡한 구조로 되어있다는 단점을 가지고 있다.

본 논문은 가중 퍼지소속함수를 이용한 신경망(Neural Network with Weighted Fuzzy Membership Functions,

접수일자 : 2008년 8월 8일

완료일자 : 2009년 4월 1일

* 교신저자: jslim@kyungwon.ac.kr

NEWFM[13]기반의 KOSPI 예측을 위하여 비중복면적 분산추정법을 사용하여 여러 개의 특징입력 중에서 중요도가 가장 낮은 특징입력을 자동적으로 하나씩 제거하면서, 최소화된 특징입력으로 고도의 예측성능을 구하는 방안을 제안하고 있다. NEWFM은 각 입력에 대해 퍼지이론의 경계함(Bounded Sum)[13]을 이용하여 예측 또는 분류를 위한 가중 퍼지소속함수들을 생성한다. 또한 비중복면적 분산추정법을 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 예측이나 분류의 효율을 낮추는 특징입력을 제거함으로써 더욱 효과적인 결과를 줄 수 있다.

NEWFM을 이용한 KOSPI 예측성능 비교를 위해 KIM[11]의 실험군과 결과를 사용하였다. KIM은 KOSPI 예측을 위해서 전체 실험군에서 약 20%의 데이터를 SVM을 이용하여 57.83%의 1일 후 예측성능을 보여주었다[11].

본 논문은 NEWFM기반의 비중복면적 분산추정법[14]을 사용하여 1일 후의 KOSPI 예측을 위해서 39개의 특징입력으로부터 중요도가 가장 낮은 특징입력을 자동적으로 하나씩 제거해가면서 가장 높은 분류성능의 평균값을 나타내었던 2개의 최소 특징입력을 추출하고, 이 최소 특징입력들에 대한 학습된 가중 퍼지소속함수를 제시하고 있다. 자동 추출된 2개의 최소 특징입력이 실험군에 적용될 수 있음을 검증하기 위해 KIM에서 사용한 1989년부터 1998년까지의 실험군[11]들을 사용하였다.

2. KOSPI 예측 모델의 개요

본 논문에서는 그림 1의 KOSPI 예측 모델 다이어그램에서 알 수 있듯이 KOSPI 데이터를 입력 값으로 하여 기술지표(Technical Indicator)를 이용하여 전처리 과정을 수행한다. 전처리 과정 후에 웨이블릿 변환(Wavelet Transforms)을 이용하여 초기 특징입력을 추출하고 NEWFM기반의 비중복면적 분산추정법[14]을 이용하여 분류성능이 가장 좋은 최소의 특징입력을 추출하게 된다.




그림 1. KOSPI 예측 모델 다이어그램
Fig. 1. Diagram of KOSPI forecasting model

2.1 전처리과정

그림 1에서 설명하고 있는 전처리 과정을 하기 위해서 본 논문에서는 1일 후의 예측을 위한 새로운 기술지표로 식 (1)에서 $CPP_{n,m}$ (Current Price Position of the day n)을 제안하고 있다. $CPP_{n,m}$ 은 기준일 n 의 증가(Closing Price)가 $n-1$ 일부터 $n-m$ 일까지의 이동평균(Moving Average)에 대해 어느 위치에 있는지를 나타내는 기술지표이다. 식 (1)에서 C_n 은 기준일인 n 일의 증가이고, $MA_{n-1,n-m}$ 는 $n-1$ 일부터 $n-m$ 일까지의 이동평균을 가리킨다.

$$CPP_{n,m} = ((C_n - MA_{n-1,n-m}) / MA_{n-1,n-m}) \times 100 \quad (1)$$

2.2 특징 추출 (웨이블릿 변환)

웨이블릿 변환(Wavelet Transforms)은 신호처리에 있어서 시간상의 국소적인 특정 지점에서의 주파수 특성을 분석함으로써 진역적 주파수 특성 정보를 주는 푸리에 분석의 단점을 보완해 준다. 비연속 웨이블릿 변환은 시간-주파수 신호를 다양한 스케일의 비연속 신호로 분리해 준다. 그림 2는 이분 비연속 웨이블릿 분리 구현을 위한 필터뱅크를 보여주고 있다. detail이라고 하는 $g(n)$ 은 웨이블릿 계수와 관련된 FIR(Finite Impulse Filters) 고대역필터(High-Pass Filters) 계수이고, approximation이라고 하는 $h(n)$ 은 스케일 함수 계수와 관련된 FIR 저대역필터(Low-Pass Filters) 계수이다. 각 필터를 지나 그 길이가 반으로 감소한 $h(n)$ 신호로 다음 스케일 레벨에서 반복하여 변환 시킨다. 웨이블릿 변환으로 추출된 웨이블릿 계수는 웨이블릿 모함수(mother wavelet)에 대한 유사도로써 이는 스케일에 의해 주어진 시간에 따른 주파수 신호를 나타낸다. 그림 2에서 d_i 와 a_i 는 각각 스케일 레벨 i 의 detail과 approximation 계수들을 의미한다.

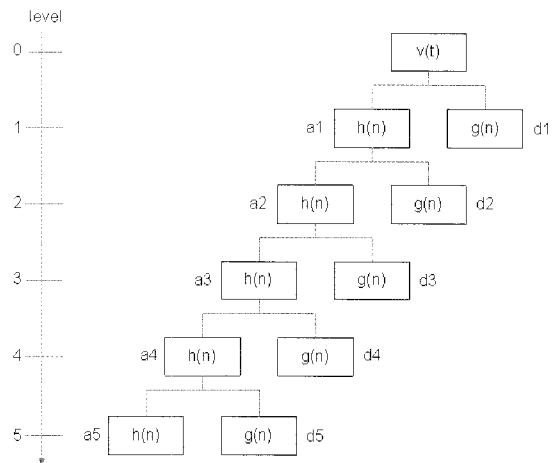


그림 2. 스케일 레벨 5인 이분 비연속 웨이블릿 변환
Fig. 2. Dyadic wavelet transforms at level 5

본 논문에서는 초기 특징입력을 추출하기 위해 그림 1의 전처리 과정에서 생성된 식 (1)에서 제안한 $CPP_{n,m}$ 을 이용하여 기준일 n 의 $CPP_{n,5}$ 로부터 31일 전인 $CPP_{n-31,5}$ 까지의 32개 $CPP_{n,5}$ 에 대해서 그림 2에서와 같이 스케일 레벨 5인 이분 비연속 Haar 웨이블릿 변환을 수행하여 38개의 계수를 생성하였다. 이들은 d_1 에서 16개, d_2 에서 8개, a_3 와 d_3 에서 각각 4개, a_4 와 d_4 에서 각각 2개, a_5 와 d_5 에서 각각 1개의 계수들로 구성되어 있다. 이들 38개의 계수에 $CPP_{n,5}$ 값을 포함한 총 39개가 초기 특징입력이 된다.

2.3 가중 퍼지소속함수 기반 신경망 (Neural Network with Weighted Fuzzy Membership Function, NEWFM)

NEWFM[13]은 입력으로부터 학습된 가중 퍼지소속함수의 경계함을 이용하여 클래스 분류를 하는 지도학습(supervised) 퍼지 신경망이다. 가중 퍼지소속함수의 경계

합은 가중치를 갖는 대, 중, 소의 3개 퍼지소속함수의 경계합을 하나의 퍼지소속함수로 합성한 것이다. NEWFM의 구조는 그림 3에서 보는 바와 같이 입력, 하이퍼박스, 클래스의 3개 계층으로 구성되어 있다. 입력 계층에는 n 개의 입력 노드들로 구성되며 각 입력노드는 하나의 특징입력을 입력 받게 된다. 하이퍼박스 계층은 m 개의 하이퍼박스 노드로 구성되고, 1번째 하이퍼박스 노드 B_1 은 단 하나의 클래스 노드에 연결되며 n 개의 퍼지집합을 갖는다.

본 논문에서는 그림 1의 특징 추출 과정에서 웨이블릿 변환된 계수들이 그림 3의 n 개의 특징입력을 갖는 h 번째 입력 $A_h = (a_1, a_2, \dots, a_n)$ 에 대한 NEWFM의 입력값으로 사용되어진다.

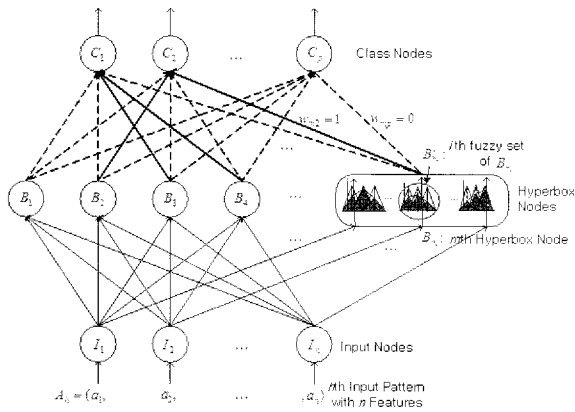


그림 3. 가중 퍼지소속함수 신경망(NEWFM)의 구조
Fig. 3. Structure of NEWFM

3. 특징 선택(비중복적 분산 측정법)

퍼지규칙이나 중요한 특징입력을 선택하는 것은 최근 논문에서 언급되어지고 있다[14,23]. 본 논문에서는 그림 1의 웨이블릿 변환으로부터 생성된 39개의 초기 특징입력 중 중요도가 가장 낮은 특징입력을 자동적으로 하나씩 제거하면서 예측성능의 평균값이 가장 높은 2개의 최소 특징입력을 추출하였다. 이 방법은 i 번째 특징입력에 대해 식 (2)에 의해 그 중요도를 측정한다.

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

여기서 $Area_U$ 와 $Area_L$ 은 각각 상승 및 하락에 대해 더 우세한 퍼지함수의 면적을 의미한다. 그림 4는 KOSPI 상승과 하락의 예측을 위한 39개의 초기 특징입력으로부터 식 (2)에 의해 측정된 중요도가 가장 높은 것과 가장 낮은 것에 대한 가중 퍼지소속함수의 경계합(BSWFM)[13]의 예를 보여주고 있다. 흰 부분과 검은 부분의 면적이 각각 $Area_U$ 와 $Area_L$ 을 나타내고 있다. $Area_U + Area_L$ 면적이 넓으면 $Area_U$ 와 $Area_L$ 의 넓이가 균등히 분산되어 있으면 두 클래스를 분류할 수 있는 특징을 더 많이 가지고 있다고 볼 수 있다.

그림 5는 39개의 전체 특징입력의 개수로부터 비중복적 분산측정법을 사용하여 중요도가 가장 낮은 특징입력을 자동적으로 하나씩 제거해 나가면서 구한 예측성능의 평균값을 표시한 것이다. 특징입력이 39개부터 하나씩 감소하여

2개 일 때까지 예측성능의 평균값이 점차 높아지다가 이후 예측성능의 평균값이 낮아짐을 알 수 있다. 이는 최종적으로 남은 2개의 특징입력이 최소화되었음을 보여주는 것이다.




그림 4. 39개의 초기 특징입력으로부터 중요도가 가장 높은 것과 가장 낮은 것에 대한 가중 퍼지소속함수의 경계합(BSWFM)의 예

Fig. 4. Examples of BSWFM for the best and worst input features among thirty-nine numbers of initial input features




그림 5. 특징입력의 개수에 따른 예측성능의 평균값의 변화
Fig. 5. Changes of the average performance results on the number of input features

그림 6은 그림 5에서 특징입력이 39개 일 때 가장 좋은 특징입력과 가장 나쁜 특징입력의 누적개수를 구한 것이다. 이는 500회의 훈련(Train)과 테스트(Test)로 얻은 것으로써, 39개의 특징입력 중에서 1번째 특징입력($CPP_{n,5}$)이 가장 좋은 특징입력으로 나타났으며, 5번째 특징입력(a_4 의 두 번째 계수)이 가장 나쁜 특징입력으로 나타났다.

그림 5에서 특징입력의 개수가 많을 때는 예측성능의 평균값이 불규칙적으로 상승과 하락을 반복하고 있다. 이것은 그림 6의 실험결과를 보면 알 수 있듯이 상대적으로 나쁜 특징입력의 개수가 좋은 특징입력의 개수보다 많기 때문이라고 볼 수 있다. 따라서 나쁜 특징들이 하나씩 제거되면서

점차적으로 성능이 꾸준히 향상되고 있음을 알 수 있다.




그림 6. 가중 퍼지소속함수의 경계함(BSWFM)에 대한 비중복면적 분산측정법을 이용한 특징입력 순위 누적의 예
Fig. 6. Number of accumulated counters of the worst input features using non-overlap area distribution measurement method

표 1. 웨이블릿을 통해 생성된 39개의 특징입력과 최종 선택된 2개의 특징입력(✓)
Table 1. Minimum number of two input features selected among thirty-nine numbers of input features produced by wavelet transforms

순번	웨이블릿 계수	선택	순번	웨이블릿 계수	선택
1	$CPP_{n,5}$	✓	21	여섯 번째 계수	
2	a5 첫 번째 계수		22	d2 일곱 번째 계수	
3	d5 첫 번째 계수		23	여덟 번째 계수	
4	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	d1 다섯 번째 계수	
9	a3 두 번째 계수		29	여섯 번째 계수	
10	a3 세 번째 계수		30	일곱 번째 계수	
11	a3 네 번째 계수		31	여덟 번째 계수	
12	d3 첫 번째 계수		32	d1 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	d2 다섯 번째 계수		40		

표 1은 초기 특징입력으로 사용한 39개의 웨이블릿 계수

를 나타내었고 중요도가 높아 최종 선택된 2개의 최소 특징 입력을 "✓"로 표시하였다.

4. 실험 결과(Experimental Results)

본 논문은 1일 후의 KOSPI 상승과 하락의 예측성능 평가를 위해 KIM이 사용한 1989년부터 1998년까지의 KOSPI 데이터를 사용하여 실험 하였다[11]. KOSPI 데이터를 식 (1)의 $CPP_{n,5}$ 로부터 31일 전인 $CPP_{n-31,5}$ 까지의 32개 $CPP_{n,5}$ 에 대해서 스케일 레벨 5인 이분 비연속 Haar 웨이블릿 변환을 수행하여 38개의 계수를 생성하였다. 이렇게 생성된 38개의 계수와 $CPP_{n,5}$ 이 초기 특징입력으로 사용되었다. KIM은 SVM(Support Vector Machine)을 사용하여 전체 데이터의 약 20%를 예측성능의 평가를 위하여 사용하였다. 표 2는 KIM이 사용한 2928개의 전체 실험군에서, 훈련(Train)을 위해 2347개의 실험군이 사용되었고, 테스트(Test)를 위해 581개의 실험군이 사용되었음을 보여주고 있다.

표 2. KOSPI 실험군[11]

Table 2. Experimental data used for forecasting KOSPI

Training instances for SVM	Holdout instances for SVM	Total instances
2347	581	2928

표 3. KIM[11]에 대한 NEWFM 예측성능 비교

Table 3. Comparisons of performance results for Kim with NEWFM

	NEWFM	SVM[11]	BP[11]
예측성능(%)	60.93	57.83	54.73

표 3에서는 KIM이 사용한 SVM과 NEWFM 예측성능 비교를 보여준다. 표 3에서의 NEWFM 예측성능은 예측성능의 평균값이 가장 높은 2개의 최소 특징입력을 이용하여 10000번의 훈련(Train)과 테스트(Test)를 반복하여 구한 결과 값이다. 표 3에서 KIM은 BP(Back-Propagation Neural Network)와 SVM의 예측성능에서 SVM이 BP보다 3.1%, NEWFM이 SVM보다 3.1% 높은 값을 보여주고 있다.

5. 결 론


본 논문은 NEWFM과 비중복면적 분산측정법을 이용하여 중요도가 가장 낮은 특징입력을 자동적으로 하나씩 제거하면서 KOSPI 예측을 위한 최소의 특징입력을 선택하는 방안을 제안하고 있다. 또한 이렇게 자동적으로 구한 최소의 특징입력을 이용하여 1일 후의 KOSPI 상승과 하락에 대한 예측성능의 최대값을 구하는 방안을 제안하였다. 본 논문에서는 KOSPI 예측을 위한 새로운 기술지표(Technical Indicator)로써 $CPP_{n,m}$ (Current Price Position of day n)을 제안하였다. 최소의 특징 선택을 위해 비중복면적 분산측정법을 이용하여, 최근 32일간의 $CPP_{n,m}$ 값을 웨이블릿 변환한 38개 계수와 $CPP_{n,m}$ 값 중 2개의 최소 특

정입력을 추출하였다. 비중복면적 분산측정법은 불필요하거나 예측결과에 악영향을 주는 특징입력을 제거함으로써 특징입력의 수를 최소화 시켜주고 가장 높은 예측성능을 구할 수 있게 해준다. NEWFM과 비중복면적 분산측정법을 이용한 실험 결과 1일 후의 KOSPI 상승과 하락에 대한 60.93%의 예측성능을 보여주었다.

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, Sept. 2006.
- [2] G. A. Carpenter, S. Grossberg and J. Reynolds, "ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network," *Neural Networks*, Vol.4, pp.565-588, 1991.
- [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, Summer 2007.
- [4] T. V. Gestel et al., "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, July 2001.
- [5] H. Ishibuchi and T. Nakashima, "Voting in Fuzzy Rule-Based Systems for Pattern Classification Problems," *Fuzzy Sets and Systems*, Vol.103, pp.223-238, 1999.
- [6] R. Jang, "ANFIS: Adaptive network-based fuzzy inference system," *IEEE Trans. Syst., Man, Cybern.*, Vol.23, pp.665-685, May-June 1993.
- [7] C. F. Juang and C. T. Lin, "An On-Line Self-Constructing Neural Fuzzy Inference Network and Its Applications," *IEEE Trans. Fuzzy Systems*, Vol.6, No.1, pp.12-32, 1998.
- [8] N. Kasabov, *Foundation of Neural Networks, Fuzzy Systems and Knowledge Engineering*, The MIT Press, Cambridge, MA, 1996.
- [9] T. Kasuba, "Simplified Fuzzy ARTMAP," *IEEE AI Expert*, pp.19-25, Nov., 1993.
- [10] Ho J. Kim, T. W. Ryu, T. T. Nguyen, J. S. Lim, and Sudhir Gupta, "A Modified Fuzzy Min-Max Neural Network for Pattern Classification," *Computational Science and Its Applications ICCSA 2004 (LNCS 3046)*, pp.792-798, Springer-Verlag, 2004.
- [11] Kyoung-jae Kim, "Financial time series forecasting using support vector machines," *Neurocomputing* 55, pp. 307-309, 2003.
- [12] H.-M. Lee, K.-H. Chen and I.-F. Jiang, "A Neural Networks with Disjunctive Fuzzy Information," *Neural Networks*, Vol.11, pp. 1113-1125, 1998.
- [13] 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, September, 2004.
- [14] J. S. Lim and S. Gupta, "Feature Selection Using Weighted Neuro-Fuzzy Membership Functions," *The 2004 International Conference on Artificial Intelligence(IC-AI'04)*, June 21-24, 2004, VOL. 1, pp. 1301-1315, Las Vegas, Nevada, USA.
- [15] C. T. Lin and C. S. George Lee, "Neural-network-based fuzzy logic control and decision system," *IEEE Trans. Computers*, Vol. 40, No. 12, Dec. 1991.
- [16] D. Nauck and R. Kruse, "A Neuro-Fuzzy Method to Learn Fuzzy Classification Rules from Data," *Fuzzy Sets and Systems*, Vol.89, pp.277-288, 1997.
- [17] Min Qi, "Predicting US recession with leading indicators via neural network models," *International Journal of Forecasting*, Vol. 17, pp.383-401, 2001.
- [18] M. Setnes and H. Roubos, "GA-Fuzzy Modeling and Classification: Complexity and Performance," *IEEE Trans., Fuzzy Systems*, Vol.8, No.5, pp.509-522, 2000.
- [19] P. Simpson, "Fuzzy min-max neural networks-Part 1: Classification," *IEEE Trans., Neural Networks*, Vol.3, pp. 776-786, 1992.
- [20] K. Tanaka, M. Sano and H. Watanabe, "Modeling and Control of Carbon Monoxide Concentration Using a Neuro-Fuzzy technique," *IEEE Trans., Fuzzy Systems*, Vol.3, pp.271-279, June, 1995.
- [21] J. S. Wang and C. S. G. Lee, "Self-Adaptive Neuro-Fuzzy Inference System for Classification Applications," *IEEE Trans., Fuzzy Systems*, Vol.10, No.6, pp.790-802, 2002.
- [22] C. Z. Ye, J. Yang, D. Y. Geng, Y. Zhou, N. Y. Chen, "Fuzzy Rules to Predict Degree of Malignancy in Brain Glioma," *Medical and Biological Engineering and Computing*, Vol.40, 2002.
- [23] 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.
- [24] Ray Tsaih, Yenshan Hsu, and Charles C. Lai. "Forecasting S&P 500 stock index futures with a hybrid AI system," *Decision Support Systems*.23, pp. 161 - 174, 1998

저 자 소 개



이상홍(Sang-Hong Lee)
1999년 : 경원대학교 전자계산학과(학사)
2001년 : 경원대학교 일반대학원 전자계산학과(석사)
2006년~현재 : 경원대학교 일반대학원 전자계산학과 박사과정 수료

관심분야 : neuro-fuzzy systems이용한 주가예측, 전문가 시스템

E-mail : shleedosa@kyungwon.ac.kr



임준식(Joon Shik Lim)
1986년 : 인하대학교 전자계산학과(학사)
1989년 : University of Alabama at Birmingham, Dept. of Computer Science (M.S.)
1994년 : Louisiana State University, Dept. of Computer Science (Ph.D.)
1995년~현재 : 경원대학교 전자거래학부 교수(현)

관심분야 : neuro-fuzzy systems, biomedical systems

E-mail : jslim@kyungwon.ac.kr