

NEWFM 기반 가중평균 역퍼지화에 의한 비선형 시계열 예측 모델링

Nonlinear Time Series Prediction Modeling by Weighted Average Defuzzification Based on NEWFM

채수한 · 임준식*

Soo-Han Chai and Joon Shik Lim*

경원대학교 소프트웨어학부

Department of E-Commerce Software, Kyungwon University

요 약

본 논문은 가중 퍼지소속함수 기반 신경망(Neural Network with Weighted Fuzzy Membership Functions, NEWFM)을 이용하여 클래스의 분류강도를 구하고 비선형 시계열 추이선을 예측하는 방안을 제안하고 있다. NEWFM에 의하여 추출된 가중퍼지 소속함수(BSWFM)를 이용하여 입력값에 대한 분류강도를 구하게 되고, 이들에 대한 가중평균 역퍼지화를 통하여 비선형 시계열 추이선을 작성한다. 실증분석결과 NEWFM은 목표 클래스로 설정된 GDP에 대하여 92.22%의 분류성능을 보여 주었다. 따라서 동 비선형 시계열 추이선은 대표적인 경기지표인 GDP 추이에 비교적 높은 유사도를 나타내는 가운데 분석대상기간인 제5순환기-제8순환기 중 정점(peak)에서 평균 12개월, 저점(trough)에서 평균 6개월의 선행성(look-ahead)을 보여 줌으로써 경기변동에 앞서 상당기간의 시차를 둔 예측지표로서 활용가능성이 입증되었다. NEWFM은 그 특징선택(feature selection)에 의하여 선행지표 10개 중 3개의 축소를 기할 수 있게 해 줌으로써 보다 적은 수의 경제지표를 가지고도 분류성능을 90.0%에서 92.22%로 향상을 기하는 가운데 효율적인 예측기능을 수행할 수 있음이 입증되었다.

Abstract

This paper presents a methodology for predicting nonlinear time series based on the neural network with weighted fuzzy membership functions (NEWFM). The degree of classification intensity is obtained by bounded sum of weighted fuzzy membership functions extracted by NEWFM, then weighted average defuzzification is used for predicting nonlinear time series. The experimental results demonstrate that NEWFM has the classification capability of 92.22% against the target class of GDP. The time series created by NEWFM model has a relatively close approximation to the GDP which is a typical business cycle indicator, and has been proved to be a useful indicator which has the turning point forecasting capability of average 12 months in the peak point and average 6 months in the trough point during 5th to 8th cyclical period. In addition, NEWFM measures the efficiency of the economic indexes by the feature selection and enables the users to forecast with reduced numbers of 7 among 10 leading indexes while improving the classification rate from 90% to 92.22%.

키워드 : 퍼지 신경망, 비선형 시계열, 가중평균 역퍼지화, NEWFM, 경기국면 예측

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 networks, FNN)이 제안되어 왔다[1][4][10-12][14][17][20][21]. 여러 가지 구조의 FNN이 학습(learning), 적응(adaptation), 규칙추출(rule extraction)을 위한 알고리즘과 더불어 제시된 바 있다[3,9,13,15,16].

if-then 형식의 퍼지규칙의 추출 기법은 의사결정을 위한 FNN의 장점 중 하나이다. 이는 분류나 예측에 있어서 보편적인 패턴을 if-then 퍼지규칙과 같은 단순한 형태의 지식 표현으로 나타내는 것이다. 주어진 일련의 학습 데이터로부터 지식 추출을 위하여 자기 조직화 시스템(self-organizing system) 기반 퍼지신경망이 개발되었다[5,6,16,18]. Setnes[16]는 유전자 알고리즘을 이용하여 간단하고 정확도가 높은 퍼지규칙 기반 모델을 얻는데 초점을 맞추었다.

본 논문은 가중 퍼지소속함수 기반 신경망(Neural Network with Weighted Fuzzy Membership Functions, NEWFM)[6,13]에 의해 분류된 각 클래스의 분류강도를 측정하여 각 클래스 소속 정도인 분류강도를 측정하고, 이를 가중평균 역퍼지화[18]를 통하여 비선형 시계열을 예측하는

* 교신저자

접수일자 : 2006년 10월 24일

완료일자 : 2007년 7월 1일

모델을 제시하고 있다. 이를 경기종합지수(composite index, CI)를 이용한 경기국면의 판단 예측에 적용하여 경기국면의 분류뿐만 아니라 경기국면의 방향성을 판단하는데 이용하였다.

2. NEWFM(Neural Network with Weighted Fuzzy Membership Function)과 분류강도

2.1 NEWFM의 구조

NEWFM은 입력으로부터 학습된 가중 퍼지소속함수의 경계합을 이용하여 클래스 분류를 하는 지도 퍼지 신경망이다 [5,7]. 가중 퍼지소속함수의 경계합은 가중치를 갖는 대, 중, 소의 3개 퍼지소속함수의 경계합을 하나의 퍼지소속함수로 합성한 것이다. NEWFM의 구조는 그림 1에서 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, l 번째 하이퍼박스 노드 B_l 은 단 하나의 클래스 노드에 연결되며 n 개의 퍼지집합을 갖는다.




그림 1. 가중 퍼지 소속함수 신경망(NEWFM)의 구조
Fig. 1 Structure of Neural Network Weighted with Weighted Fuzzy Membership Function

B_l 의 i 번째 퍼지집합은 B_l^i 로 표시되는데 대, 중, 소로 구성된 3개의 가중 퍼지소속함수를 갖는다. 출력 계층은 p 개의 클래스 노드들로 구성되며 각 클래스 노드는 하나 이상의 하이퍼박스 노드에 연결되어 있다. 입력노드로 입력되는 h 번째 입력 패턴은 $I_h = \{A_h = (a_1, a_2, \dots, a_n), class\}$ 로 기록되며 여기서 $class$ 는 분류값이고 A_h 는 n 개 특징입력으로 구성된다.

하이퍼박스노드 B_l 과 클래스노드 C_i 사이의 연결 가중치는 초기값으로 연결이 안 된 상태에서는 $w_{li} = 0$ 이 주어지나 연결 시 $w_{li} = 1$ 로 설정된다. B_l 과 클래스노드 C_i 를 초기에 연결하기 위해서 입력 $I_h = \{A_h = (a_1, a_2, \dots, a_n), class\}$ 에 따른 각 하이퍼박스의 $Output(B_l)$ 값 중 최대값을 갖는 B_l 과 $i = class$ 인 C_i 를 선택한다. 초기 연결 이후, 입력 I_h 에 대해 최대값을 갖는 B_l 과 C_i 가 연결된 경우에만 B_l 이 학습된다. 함수

$Output(B_l)$ 은 다음과 같다.

$$Output(B_l) = \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^3 B_l^i(\mu_j(a_i))W_j.$$

그림 3의 v_1, v_2, v_3 는 B_l^j 로 표기되는 대, 중, 소 퍼지소속함수의 중심위치이고 학습 시 좌우로 조정된다. v_0 와 v_4 는 일정한 값으로 고정되어 있다. 입력 a_i 는 그림 3의 $v_{min} \sim v_{max}$ 범위 안에 있다.

$\mu_j(\cdot)$ 는 B_l^j 의 가중 퍼지소속함수를 나타내며 $j=1,2,3$ 은 대, 중, 소 가중 퍼지소속함수의 인덱스를 각각 나타낸다. 각 가중 퍼지소속함수 $\mu_j(\cdot)$ 의 모양은 $(v_{j-1}, 0)$, $(v_{j+1}, 0)$, (v_j, W_j) 의 세 점으로 표현되는 삼각형이다. 여기서 W_j 는 소속함수의 강도(strength)를 나타내는 소속함수 가중치($0 \leq W_j \leq 1$, 초기값 $0.45 \leq W_j \leq 0.55$)를 의미한다.

$Adjust(B_l)$ 은 B_l 의 학습 시 입력 $A_h = (a_1, a_2, \dots, a_n)$ 에 의해 B_l 내의 B_l^i 들($1 \leq i \leq n$)을 조정하는 함수이다. 입력 a_i 를 받는 B_l^j 의 v_j 와 W_j 는 ($j=1,2,3$) a_i 값에 의하여 그림 2와 같이 a_i 값에 수렴하는 방향으로 조정 된다.




그림 2. B_l^i 의 $Adjust(B_l)$ 연산 전후의 예
Fig. 2 i -th Fuzzy set of B_l (3 Weighted Fuzzy Membership Functions)

학습을 거친 하이퍼박스노드 B_l 은 입력패턴을 분류하기 위한 if-then 형식의 퍼지규칙으로 사용될 수 있다. B_l^j 는 3개의 가중 퍼지소속함수($\mu_j(\cdot)$, where $j=1,2,3$), weighted fuzzy membership functions, WFM, 그림 3의 회색 부분)로 구성된다. 그림 3의 굵은 선으로 표시된 $\mu_b^i(\cdot)$ 은 WFM의 경계합(bounded sum of WFM, BSWFM)으로써 다음 식과 같이 정의되며 3개의 WFM의 퍼지 특성을 통합하게 된다. 학습된 BSWFM $\mu_b^i(\cdot)$ 은 i 번째 입력에 대한 퍼지규칙으로 이용된다.

$$\mu_b^i(x) = \sum_{j=1}^3 B_l^i(\mu_j(x))$$




그림 3. 3개 가중 퍼지소속함수의 경계합(BSWFM) 예 (굵은 선)

Fig. 3 An Example of Bounded Sum of 3 Weighted Fuzzy Membership Functions (BSWFM, Bold Line)

이와 같이 n 개의 특징입력에 의해 생성된 n 개의 BSWFM 들은 다시 비중복면적 분산 측정법[6]에 의하여 중요도가 낮은 특징입력을 제거함으로써 BSWFM의 수를 최소화할 수 있게 된다.

2.2 분류강도에 의한 시계열 추이선

NEWFM에 의해 학습이 끝나면 하이퍼박스노드 B_i 과 클래스노드 C_i 사이가 연결된다. 이후 입력 $A_h = (a_1, a_2, \dots, a_n)$ 가 들어오면 다음 식에 의해 B_i 의 출력값인 $Output(B_i)$ 의 값 중 최대값을 갖는 클래스노드 C_i 가 결정되며 이 값이 C_i 의 분류강도가 된다. 이 분류강도가 클수록 해당 클래스에 분류된 소속정도가 강한 것이며 각 C_i 의 분류강도를 이용하여 클래스의 분류뿐만 아니라 비선형 시계열을 예측할 수 있다. 여기서 그림 4와 같이 클래스 노드의 수를 C_1 과 C_2 2개로 제한한 NEWFM의 구조에 가중평균 역퍼지화[18]를 위한 출력노드인 O 를 추가하게 되면 O 의 출력값이 예측된 비선형 시계열이 된다.

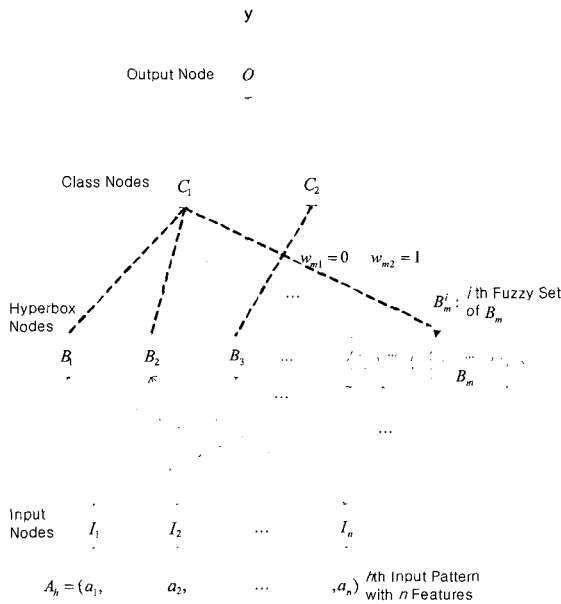


그림 4. 비선형 시계열 예측을 위해 변형된 NEWFM의 구조
Fig. 4 Modified Structure of NEWFM for Nonlinear Time Series

3. 실험 결과 (Experimental Results)

경기변동은 국민경제의 총체적 활동수준 즉 생산, 물가, 고용수준 등의 확장국면(expansion phase)과 수축국면(contraction phase)이 주기적으로 순환을 반복하는 변동현상으로 여러 방법론들이 제시된 바 있다. 본 논문에서는 CI(composite index)를 이용한 경기변동 예측을 위해 NEWFM 기반 가중평균 역퍼지화에 의한 비선형 시계열을 보여준다.

3.1 경기에측 분류

경기관련 지표는 통계청에서 매월 발표하는 CI 즉 선행지수를 이용하였고 시계열은 1991.1월~2005.6월까지의 185개월별 자료를 사용하였다. 그리고 목표인 클래스(class) 지표로서는 국민경제의 활동수준을 총체적으로 나타낼 수 있는 국내총생산(gross domestic product, GDP)을 선택하되 각 지표의 월별대응은 보간(interpolation)방법에 의하였다. 표 1은 NEWFM에서 사용된 입력 및 테스트 데이터와 이에 대한 내용을 간략한 것이다.

<표 1> NEWFM 경기국면 예측을 위한 이용지표
<Table 1> Indices for NEWFM Economic Situation Prediction

구분	지수별(수)	세부 구성지표	시 계 열
훈련 데이터	선행지수(10)	고용1,생산1,소비1, 투자3,금융3,무역1	180 (91.1~05.12)
테스트 데이터	선행지수(10)	고용1,생산2,투자3, 금융2,무역1	186 (91.1~06.6)

클래스구분: 1970년 이후 경기 확장국면 및 수축국면의 실질 GDP 평균성장률 기준으로 구분하되 최근 우리나라의 잠재성장을 저하 경향을 감안하여 이를 조정, 상하한 임계치를 설정1)
class 0: 하한(5.5% 미만)
class 1: 상한(5.5% 이상)

주 1) 우리나라의 경기순환국면의 식별(한국은행 조사통계월보 2004년1월호)및우리경제의 성장잠재력약화 원인과 전망(한국은행 조사통계월보 2005년9월호)

3.2 경기국면 예측을 위한 퍼지규칙 생성

본 논문에서는 CI의 10개 선행구성지표와 NEWFM을 이용하여 경기에측을 위한 퍼지규칙을 생성하고 비중복면적 분산 측정법[6]에 의하여 최소의 퍼지규칙을 추출, 경기국면의 판단작업을 수행하였다. 선행지수의 경우 제조업의 고용 생산부문 등의 10개 선행 구성지표를 특징입력요소로 하고 GDP 증가율을 2개 클래스인 상한 및 하한 임계치로 구분하여 1991.1~2005.12월까지의 180개 시계열에 대한 학습을 수행하였다.

표 2는 생성된 퍼지소속함수에 비중복면적 분산 측정법을 적용한 결과로 얻어진 각 입력특징들의 순위를 보여 주고 있다. 동 순위는 예측 내지 분류의 효율성을 나타내는 지표로서 동 순위에 따라 입력특징수를 점차 줄여 나가면서 예측성을 떨어뜨리지 않는 수준에서 다시 학습과정을 거치게 되면 최소의 퍼지소속함수가 추출된다. 그림 5는 비중복면적 분산 측정법에 의해서 최종적으로 추출된 7개 선행지표의 가중 퍼지소속함수(BSWFM)를 보여 주고 있으며 이를 퍼지규칙으로 사용하게 된다.

<표 2> 비중복면적 분산측정법에 의한 최종 7개 선행지수
 <Table 2> Final 7 Precedence Indices by Non-Overlap Area Measurement Method

선행구성지표수	10개		9개		8개		7개	
	순위	area	순위	area	순위	area	순위	area
구인구직비율	7	0.115	6	0.176	3	0.170	5	0.081
재고순환지표	8	0.077	5	0.208	2	0.190	3	0.100
소비자기대지수	9	0.058	8	0.073	8	0.057	4	0.092
기계수주액	1	0.307	4	0.240	4	0.137	6	0.061
자본재수입액	5	0.124	7	0.108	6	0.122	7	0.054
건설수주액	3	0.161	1	0.286	1	0.311	1	0.117
종합주가지수	2	0.277	2	0.272	5	0.126	2	0.104
총유동성	6	0.123	9	0.035				
장단기금리차	10	0.050						
순상품교역조건	4	0.125	3	0.241	7	0.118		

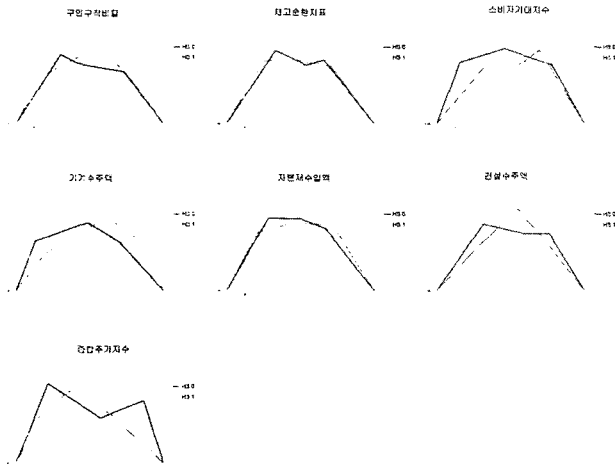


그림 5. 7개 선행지수 구성지표에 의한 BSWFM (흑색선:하한국면, 회색선:상한국면)

Fig. 5. BSWFMs generated by 7 Leading Indexes

최종적으로 추출된 7개 선행 구성지표를 사용한 결과 표 3과 같이 경기국면의 확장과 수축에 대해 92.22%의 신뢰성 있는 분류율을 보여 주고 있다. 이는 10개의 선행 구성지표를 사용한 결과보다 2.22%가 증가하였으며 재고순환지표, 소비자 기대지수 및 장단기 금리차 구성지표가 타 구성지표보다 분류율 향상에 대한 기여도가 낮음을 의미한다.

<표 3> NEWFM에 의한 분류율
 <Table 3> Classification Rates by NEWFM

		총시계열 수	정상 분류	분류율 (%)	에러율 (%)
선행 구성지표	10개 사용시	180	162	90.00	10.00
	7개 사용시	..	166	92.22	7.78

3.3 NEWFM 기반 가중평균 역퍼지화를 이용한 GDP 예측

그림 4의 비선형 시계열 예측을 위해 변형된 NEWFM의 구조를 이용하면, 경기국면의 확장과 수축에 대한 클래스 분류를 확장한 시계열 예측이 가능하다. 그림 4의 클래스노드(C)는 각 클래스 분류강도를 출력하게 되고 이를 출력노드(O)에서 입력받아 가중평균 역퍼지화(weighted average defuzzification)[18]를 통해 비선형 시계열 값을 출력한다. 1991.1~2006.6까지의 예측결과를 보면 그림 6과 같이 동기간 중의 실제 GDP 추이와 그 변동패턴을 같이 하고 있을 뿐만 아니라 일정한 시차를 두고 경기확장국면과 경기수축국면에 대해 민감하게 반영하고 있음을 보여 주고 있다. 즉 NEWFM은 목표클래스로 설정된 GDP에 대하여 92.22%의 분류성능을 나타내고 있으므로 NEWFM 기반 비선형 시계열은 대표적인 경기지표인 GDP에 대하여 이와 같은 분류성능에 대응되는 비교적 높은 유사도를 보여주는 경기예측지표임을 뒷받침하고 있다.




그림 6. GDP와 선행 구성지표에 의한 NEWFM 기반 비선형 시계열

Fig. 6. GDP and NEWFM Based Nonlinear Time Series Using Leading Indexes

3.4 NEWFM 기반 비선형시계열의 경기예측성능


NEWFM 기반 비선형 시계열의 예측성능에 관하여는 표 6 및 그림 7에서 보는 바와 같이 정부에서 발표한 기준순환일 대비 정점에서 평균 12개월, 저점에서 평균 6개월의 선행성(look-ahead)을 보여 주고 있다. 이와 같은 선행성은 정부에서 편제, 발표하고 있는 선행종합지수와 비슷한 성능으로서 경기변동에 앞서 상당한 시차를 둔 경기예측지표로서 활용이 가능함을 입증하고 있다.

<표 4> 예측성능 비교

<Table 4> Comparison of forecasting performance

경기전환점	NEWFM(평균)	선행종합지수(평균)1)
정점(개월)	8-14(12)	8-15(13)
저점(개월)	4-8(6)	3-8(6)

1) 정부발표의 경기예측지표



· 위의 정점(저점)은 2006.2월 통계청 발표의 경기중영지수계편 및 기준순환일 설정에 의함

그림 7. 기준순환일과 NEWFM 기반 비선형 시계열의 시차
Fig. 7. The time difference between the Reference Cycle Date and NEWFM based nonlinear time series

4. 결 론

본 논문은 NEWFM 기반 가중평균 역퍼지화에 의한 비선형 시계열 모델을 제안하고 경기국면 예측에 적용하였다. NEWFM은 클래스의 분류에 효율적이며 비중복면적 분산 측정법에 의하여 중요도가 낮은 특징입력을 제거할 수 있어 분류를 위한 퍼지규칙의 수를 최소화 해준다. 최종적으로 추출된 가중퍼지소속함수의 경계함(BSWFM)은 퍼지규칙의 특징을 가시적으로 보여줌으로써 특징입력의 분석 및 해석을 용이하게 해준다. 이러한 장점을 유지하면서 비선형 시계열 작성을 위해, 클래스 분류를 2개로 제한하고 각 클래스의 분류강도를 역퍼지화하는 모델을 제시하고 있다. 본 논문에서 제안된 모델의 실증을 위해 선행 구성지표에 의한 NEWFM 기반 비선형 시계열은 실제의 GDP와 그 추이가 유사함을 보여 주고 있으며, 보다 합리적인 지표선정과 이를 통한 예측의 효율화를 기할 수 있게 해 준다. 더욱이 경제지표의 입력만으로 경기예측의 자동화에 따른 기동성 및 편이성을 통하여, 관심 있는 경기예측의 수요층 즉 정책당국, 기타 금융 및 기업 등 경제주체들로 하여금 보다 기동성 있는 정책수립 내지 사업계획의 수립과 조정을 가능하게 해 준다.

참 고 문 헌

[1] 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.

[2] A. F. Gomez-Skarmeta, M. V. F. Jimenez, J. G. Marin-Blazques, "Approximative Fuzzy Rules Approaches for Classification with Hybrid-GA Techniques," *Informaion Sciences*, Vol.136, pp.193-214, 2001.

[3] 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.

[4] R. Jang, "ANFIS: Adaptive network-based fuzzy inference system," *IEEE Trans. Syst., Man, Cybern.*, Vol.23, pp.665- 685, May-June, 1993.

[5] Joon S. Lim, D. Wang, Y.-S. Kim, and S. Gupta,

"A neuro-fuzzy approach for diagnosis of antibody deficiency syndrome," *Neurocomputing* 69, Issues 7-9, pp. 969-974, March 2006.

[6] Joon S. Lim, T-W Ryu, H-J Kim, and S. Gupta, "Feature Selection for Specific Antibody Deficiency Syndrome by Neural Network with Weighted Fuzzy Membership Functions," *FSKD 2005 (LNCS 3614)*, pp. 811-820, Springer-Verlag, Aug. 2006.

[7] Joon S. Lim, T-W Ryu, H-J Kim, and S. Gupta, "Feature Selection for Specific Antibody Deficiency Syndrome by Neural Network with Weighted Fuzzy Membership Functions," *LNCS 3614*, pp. 811-820, Springer-Verlag, Aug. 2005.

[8] 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.

[9] N. Kasabov, *Foundation of Neural Networks, Fuzzy Systems and Knowledge Engineering*, The MIT Press, Cambridge, MA, 1996.

[10] T. Kasuba, "Simplified Fuzzy ARTMAP," *IEEE AI Expert*, pp.19-25, Nov., 1993.

[11] Ho J. Kim, Tae W. Ryu, Thai T. Nguyen, Joon 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.

[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] Joon Shik 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.211-217, September, 2004.

[14] 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.

[15] 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.

[16] 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.

[17] P. Simpson, "Fuzzy min-max neural networks-Part 1: Classification," *IEEE Trans., Neural Networks*, Vol.3, pp. 776-786, 1992.

[18] T. Takagi, M. Sugeno, "Fuzzy Identification of Systems and Its Applications to Modeling and Control," *IEEE Trans., Syst. Man, Cybern.*, Vol. 15, pp.116-132, 1985.

- [19] 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.
- [20] 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.
- [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.
-

저 자 소 개



채수한(Soo-Han Chai)

1960년 : 서울대학교 상과대학 졸업(학사)
2004년 : 2004년 경원대학교 산업환경대학
원 정보통신 시스템공학과 업
(석사)
2007년 : 경원대학교 일반대학원
전자계산학과 졸업(박사)

관심분야 : neuro-fuzzy systems의 경제분야 응용
e-mail : soochai@hanmail.net



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 소프트웨어학부 교수(현)

관심분야 : neuro-fuzzy systems, biomedical systems
e-mail : jslim@kyungwon.ac.kr