

http://dx.doi.org/10.7236/JIIBC.2013.13.2.181

JIIBC 2013-2-24

개별 입력 공간 기반 퍼지 뉴럴 네트워크에 의한 최적화된 패턴 인식기 설계

Design of Optimized Pattern Recognizer by Means of Fuzzy Neural Networks Based on Individual Input Space

박건준*, 김용갑**, 김변곤***, 황근창****

Keon-Jun Park, Yong-Kab Kim, Byun-Gon Kim, Geun-Chang Hoang

요약 본 논문에서는 패턴 인식기를 설계하기 위하여 개별 입력 공간을 기반으로 한 퍼지 뉴럴 네트워크를 소개한다. 제안된 퍼지 뉴럴 네트워크는 각 입력 공간을 개별적으로 분할함으로써 네트워크를 구성한다. 규칙의 전반부는 개별적 입력 공간을 퍼지 분할하여 독립적으로 구성하고, 규칙의 후반부는 다항식으로서 표현된다. 퍼지 뉴럴 네트워크의 학습은 퍼지 규칙의 후반부에 있는 뉴런의 연결가중치를 조정함으로써 실현되고, 오류 역전파 알고리즘을 이용하여 실현한다. 또한, 제안한 네트워크의 파라미터를 최적화하기 위하여 실수 코딩 유전자 알고리즘을 이용한다. 마지막으로, 패턴 인식을 위한 실험 데이터를 이용하여 최적화된 패턴 인식기를 설계한다.

Abstract In this paper, we introduce the fuzzy neural network based on the individual input space to design the pattern recognizer. The proposed networks configure the network by individually dividing each input space. The premise part of the networks is independently composed of the fuzzy partition of individual input spaces and the consequence part of the networks is represented by polynomial functions. The learning of fuzzy neural networks is realized by adjusting connection weights of the neurons in the consequent part of the fuzzy rules and it follows a back-propagation algorithm. In addition, in order to optimize the parameters of the proposed network, we use real-coded genetic algorithms. Finally, we design the optimized pattern recognizer using the experimental data for pattern recognition.

Key Words : Fuzzy Neural Networks, Individual Input Space, Multi-Output Rule, Genetic Algorithms, Pattern Recognizer

1. 서론

퍼지 모델과 신경회로망을 결합한 퍼지 뉴럴 네트워크에 관한 연구가 활발히 진행되고 있다. 퍼지 모델은

시스템을 이해하기 쉽도록 정성적인 표현이 용이하고 불확실한 정보를 가지고 있는 시스템에 강인성을 발휘할 수 있다. 그러나 학습기능을 가지고 있지 않고 있으며 퍼지규칙을 얻기 위해 전문가나 경험에 의존해야 하

*정회원, 원광대학교 정보통신공학과

**정회원, 원광대학교 정보통신공학과

***정회원, 군산대학교 전자공학과

****정회원, 원광대학교 반도체·디스플레이학과

접수일자 2013년 1월 22일, 수정완료 2013년 2월 25일

게재확정일자 2013년 4월 12일

Received: 22 January 2013 / Revised: 25 February 2013 /

Accepted: 12 April 2013

*Corresponding Author: gchoang@wonkwang.ac.kr

Division of Semiconductor and Display, Wonkwang University, Korea

는 어려움이 있다. 한편, 신경회로망은 시스템의 입출력 관계를 학습을 통해 추출할 수 있으며 병렬처리 기능을 가지고 있어 빠른 처리 능력을 가진다. 그러나 신경회로망은 주어진 시스템에 대해 정성적 표현이 어려워 시스템을 이해하기에는 어려움을 가진다. 이러한 두 모델의 장점을 결합하고 단점을 해결하기 위해 퍼지 모델과 신경회로망의 유사성과 상호 보완관계를 이용하여 다양한 결합을 시도하고 있으며 이러한 구조가 퍼지 뉴럴 네트워크이다^{[1][2][3]}. 퍼지 뉴럴 네트워크는 기존의 모델에 비해서 학습속도가 빠르고, 수렴특성이 우수한 장점을 가지며, 이러한 장점으로 인해 아직까지도 많은 연구가 진행되고 있다^{[4][5][6]}. 일반적으로 퍼지 뉴럴 네트워크는 퍼지 규칙으로 표현되며, 다차원 입력 패턴을 갖는 네트워크를 설계할 경우 퍼지 규칙의 수가 많이 증가하는 문제를 가지고 있다.

본 논문에서는 다차원의 패턴 인식기를 설계하기 위해 개별적으로 입력 공간을 분할하여 퍼지 규칙을 구성하고 삼각형 소속 함수를 이용하여 퍼지 규칙의 전반부를 형성한다. 퍼지 규칙의 후반부는 간략 추론, 선형 추론, 변형된 2차식 추론 방법을 사용하여 표현하고 후반부 다항식 계수는 오류 역전파 알고리즘을 이용하여 학습한다. 설계된 네트워크는 실수코딩 유전자 알고리즘^[7]을 이용하여 각 입력 변수에 대한 전반부 소속 함수의 정점과 학습률 및 모멘텀 계수와 같은 파라미터들을 최적적으로 동조한다. 또한, 제안한 네트워크는 실험 데이터를 이용하여 패턴 분류 및 평가를 통해 패턴 인식기를 설계한다.

본 논문의 구성은 다음과 같다. 2장에서는 제안한 네트워크의 설계에 대해 다루고, 3장에서는 최적화 알고리즘에 대해 설명한다. 4장에서는 제안한 방법의 실험 및 결과에 논하고, 5장에서는 결론을 맺는다.

II. 퍼지 뉴럴 네트워크 설계

1. 퍼지 뉴럴 네트워크의 구조

퍼지 뉴럴 네트워크는 퍼지이론과 신경회로망의 두 구조가 유사성과 상호 보완적인 특성으로부터 결합이 시도되었다. 이 결합에 의한 퍼지 뉴럴 네트워크 구조는 퍼지이론의 언어적 논리를 규칙의 형태로 표현할 수 있는 능력과 신경회로망의 학습기능과의 상호간에 높은

융통성을 가지게 된다.

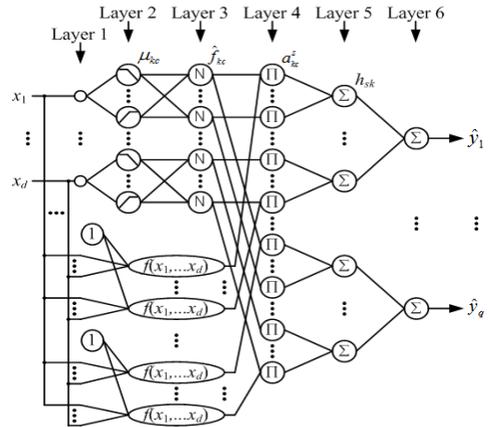


그림 1. 제안한 퍼지 뉴럴 네트워크의 구조
Fig. 1. The structure of the proposed fuzzy neural networks

입력에 따른 퍼지 공간 분할은 개별적인 분할 공간에 의해 퍼지 규칙을 형성하며 후반부 구조는 간략 추론, 선형 추론, 변형된 2차식 추론에 의해 표현된다. 각 퍼지 규칙의 추론된 값은 다중 출력을 위해 연결가중치로 연결된 구조이다. 그림 1은 제안한 퍼지 뉴럴 네트워크의 구조를 보여준다.

제안한 퍼지 뉴럴 네트워크는 각 입력에 대해 퍼지 규칙의 전반부를 이루고, 퍼지 규칙의 후반부는 다중 출력을 기반으로 한 다중 규칙을 가진다. 제안한 퍼지 뉴럴 네트워크의 퍼지 규칙은 식 (1)과 같이 표현된다.

$$R^{kc}: \text{If } x_k \text{ is } A_{kc} \text{ then } y_{kc}^s = f(x_1, \dots, x_d) \quad (1)$$

간략 추론(Type 1) : $f = w_{kc}^{s0}$

선형 추론(Type 2) : $f = w_{kc}^{s0} + \sum_{i=1}^d w_{kc}^{si} x_i$

변형된 2차식 추론(Type 3) :

$$f = w_{kc}^{s0} + \sum_{i=1}^d w_{kc}^{si} x_i + \sum_{i=1}^d \sum_{j=i+1}^d w_{kc}^{sz} x_i x_j$$

여기서, R^{kc} 은 k, c 번째 퍼지 규칙을 나타내고 A_{kc} 는 전반부 퍼지 변수로 소속 함수를 나타내며, k 와 c 는 각각 입력 변수의 수와 소속 함수의 수이다. w_{kc}^{si} 는 후반부 계수이며, 연결가중치를 나타낸다. z 는 입력 변수

의 조합의 수이다. 설계된 퍼지 뉴럴 네트워크에서 각 층의 연산과정은 다음과 같다.

[1층] 입력층

입력 신호가 다음 층의 해당 노드로 전달된다.

[2층] 적합도 계산 : μ_{kc}

삼각형 소속 함수는 식 (2)와 같이 계산된다. 여기서, a, b, c 는 삼각형 소속 함수의 파라미터이다.

$$\mu(x;a,b,c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases} \quad (2)$$

[3층] 정규화된 적합도 계산

각 규칙의 소속 값을 이용하여 정규화된 적합도를 식 (3)과 같이 계산한다.

$$\hat{f}_{kc} = \frac{\mu_{kc}}{\sum_{c=1}^g \mu_{kc}} = \mu_{kc}, \quad \sum_{c=1}^g \mu_{kc} = 1 \quad (3)$$

[4층] 연결가중치와의 곱

전반부의 정규화된 적합도는 식 (4)와 같이 연결가중치와 곱해진 후 다음 층으로 입력된다.

$$a_{kc}^s = \hat{f}_{kc} y_{kc}^s \quad (4)$$

[5층] 각 입력 변수의 퍼지 추론 값

각 입력 변수에 대한 퍼지 추론 값은 식 (5)와 같다.

$$h_{sk} = \sum_{c=1}^g a_{kc}^s = \sum_{c=1}^g \hat{f}_{kc} y_{kc}^s \quad (5)$$

[6층] 최종 출력

최종 출력은 식 (6)과 같이 대수적 합을 통해 구해진다.

$$\hat{y}_s = \sum_{k=1}^d h_{sk} \quad (6)$$

2. 퍼지 뉴럴 네트워크의 학습

네트워크의 학습은 후반부 다항식 계수인 연결가중치를 가장 적절한 값으로 조정해 나가면서 이루어진다. 학습 방법은 오류역 전파 알고리즘을 이용하며, 다중 출력에 의한 오차는 식 (7)과 같이 정의한다.

$$E_p = \frac{1}{2} \sum_{s=1}^q (y_{ps} - \hat{y}_{ps})^2 \quad (7)$$

간략 추론, 선형 추론 및 변형된 2차식 추론의 경우 연결가중치의 조절은 기존의 값에 오차로부터 구해진 조절량 만큼의 변화를 더해 주며, 간략 추론의 경우 다음과 같다.

$$w_{kc}^{s0}(p+1) = w_{kc}^{s0}(p) + \Delta w_{kc}^{s0} \quad (8)$$

$$\Delta w_{kc}^{s0} = \eta \left(- \frac{\partial E_p}{\partial w_{kc}^{s0}} \right) \quad (9)$$

$$- \frac{\partial E_p}{\partial w_{kc}^{s0}} = - \frac{\partial E_p}{\partial \hat{y}_{ps}} \frac{\partial \hat{y}_{ps}}{\partial h_{sk}} \frac{\partial h_{sk}}{\partial a_{kc}^s} \frac{\partial a_{kc}^s}{\partial w_{kc}^{s0}} \quad (10)$$

따라서,

$$\Delta w_{kc}^{s0} = \eta (y_{ps} - \hat{y}_{ps}) \hat{f}_{kc} \quad (11)$$

또한, 모멘텀을 추가해 학습시간을 좀 더 단축시키고, 학습성능을 향상시킨다. 연결가중치의 변화량이 클 경우에는 변화량을 키워주고, 변화량이 작아지면 변화량을 줄여 주는 역할을 한다. 모멘텀은 현재의 연결가중치와 그 이전 연결가중치의 차이에 의해 계산된다. 모멘텀까지 포함하는 연결가중치의 최종 조절식은 식 (12)와 같다.

$$\Delta w_{kc}^{s0} = \eta (y_{ps} - \hat{y}_{ps}) \hat{f}_{kc} + \alpha (w_{kc}^{s0}(p) - w_{kc}^{s0}(p-1)) \quad (12)$$

선형 추론인 경우와 변형된 2차식 추론인 경우에도 같은 방법으로 유도된다.

$$\Delta w_{kc}^{si} = \eta (y_{ps} - \hat{y}_{ps}) \hat{f}_{kc} x_i + \alpha (w_{kc}^{si}(p) - w_{kc}^{si}(p-1)) \quad (13)$$

$$\Delta w_{kc}^{sz} = \eta (y_{ps} - \hat{y}_{ps}) \hat{f}_{kc} x_j + \alpha (w_{kc}^{sz}(p) - w_{kc}^{sz}(p-1)) \quad (14)$$

III. 유전자 알고리즘을 이용한 최적화

유전자 알고리즘^[7]이란 적자생존의 생물학 원리에 바탕을 둔 최적화 기법중의 하나로 자연계의 생명체 중 환경에 잘 적응한 개체가 조금 더 많은 자손을 낳길 수 있다는 자연선택 과정과 자연계 생명체의 설계도와 같은 유전자의 변화를 통해서 좋은 방향으로 발전해 나간다는 자연진화 과정의 유전자 메카니즘에 바탕을 둔 탐색 알고리즘이다. 즉, 자연계에 있어서 생물학의 유전과 진화의 메카니즘을 공학적으로 모델화하는 것에 의해 생물의 환경 적응능력과 자연도태의 원리를 기반으로 만들어진 계산 모델로, 실제계의 문제를 풀기 위해 잠재적인 해들을 컴퓨터상에서 코딩된 개체로 나타내고, 여러 개의 개체들은 모아 군집을 형성한 뒤, 세대를 거듭하면서 이들의 유전 정보를 서로 교환하거나 새로운 유전 정보를 부여하면서 적자 생존의 법칙에 따라 모의 진화를 시킴으로써, 주어진 문제에 대한 최적의 해를 찾는 계산 모델이다.

유전자 알고리즘은 3개의 기본 연산자, 즉 재생산, 교배, 돌연변이를 가지고 있다. 생산은 다음 세대를 위해 교배 유전자가 선택되어지는 과정으로, 적합도에 따라 다음세대를 생산할 수 있는 기회를 부여한다. 각각의 문자열들은 그들의 적합도를 가지고 다음세대에 전달된다. 교배는 교배 유전자로부터 염색체들은 짝짓고 짝지어진 문자열 쌍은 확률적으로 선택되어진다. 돌연변이는 문자열 위치의 값을 임의로 변경한다. 2진 코딩에서 돌연변이는 0을 1로 또는 1을 0으로 바꾸는 것을 의미한다. 적절하게 정의된 적합도 함수와 함께 조합된 연산자는 유전자 알고리즘의 주요 부분이 된다. 유전자 알고리즘은 초기 집단 생성후 적합도를 평가하고, 재생산, 교배, 돌연변이의 기본 연산자를 통해 최적해를 탐색한다.

실세계의 문제들은 고정밀도의 해를 요구하고, 해에 대한 사전지식이 결여되거나, 복잡한 제약조건이 존재하는 경우가 종종 있다. 이진코딩을 채용할 때 정밀도를 높이거나 해에 대한 사전지식의 결여로 탐색공간을 확대하게 되면 염색체 길이가 길어진다. 긴 염색체는 매우 큰 탐색공간을 만들어 해를 찾는데 많은 시간을 요구하거나, 경우에 따라서는 실패하는 원인을 제공한다. 이러한 문제점들은 근본적으로 염색체 표현을 조금 더 해공간에 접근시켜 문제와 관련된 지식을 포함시키는 연산자 설계를 용이하게 하고, 제약조건을 다루기 위한 도구

를 설계하는 것이 쉽도록 함으로써 해결할 수 있으며, 대표적인 표현법이 실수코딩이다. 실수코딩을 채용함으로써 염색체의 유전자와 벡터 요소는 정확히 일대일 일치하는 관계를 가지며 염색체의 길이는 벡터의 차원과 같게 된다.

본 논문에서는 제안한 네트워크에 대한 전반부 소속 함수의 정점과 학습률 및 모멘텀 계수를 최적으로 설정해 주기 위하여 실수 코딩 유전자 알고리즘을 이용하여 네트워크의 최적화 과정을 수행하게 된다. 그림 4는 네트워크의 최적화를 위해 입력 변수에 대해 3개의 소속 함수를 할당하고 그 다음으로 학습률 및 모멘텀 계수를 할당한 염색체 구조를 보여준다. 이들 염색체들은 유전 연산자에 의해 세대를 거듭하면서 최적 해를 탐색한다. 그림 2는 제안된 네트워크의 최적 설계를 위한 염색체 구조를 보여준다.

M _j apexes of input variable z _j (3) Small _j Middle _j Big _j			...	M _j apexes of input variable z _j (3) Small _j Middle _j Big _j			learning rate (1)	momentum coefficient (1)
---	--	--	-----	---	--	--	-------------------	--------------------------

그림 2. 최적화를 위한 염색체 구조
Fig. 2. Chromosomes structures for optimization

IV. 실험 데이터를 통한 결과 고찰

본 논문에서는 패턴 인식기를 설계하기 위해 Fisher의 Iris 데이터^[8]와 Wisconsin Diagnostic Breast Cancer (WDBC) 데이터^[8]를 이용하여 제안한 퍼지 뉴럴 네트워크의 패턴 인식을 수행한다.

각각의 실험은 random sub-sampling을 이용하여 각 데이터 집합을 7:3의 비율의 클래스별로 임의적으로 학습 데이터와 테스트 데이터로 나누어 5번 반복 실험한다. 성능 평가는 인식률(CR) 및 MSE에 의한 정확도(PI)의 평균과 표준편차에 의해 평가한다. 여기서, K는 random sub-sampling에 의한 반복 횟수를 의미한다.

$$E_p = \frac{\text{No. of classification}}{\text{No. of examples}} \times 100 \quad (15)$$

$$CR = \frac{1}{K} \sum_{i=1}^K E_p \quad (16)$$

$$PI = \frac{1}{K} \sum_{i=1}^K MSE \quad (17)$$

실험에 앞서 표 1은 최적의 네트워크를 설계하기 위한 유전자 알고리즘 및 제안된 네트워크의 초기 파라미터를 보여준다.

표 1. 제안된 네트워크의 최적화를 위한 초기 파라미터
Table 1. Initial parameters of optimization of the proposed networks

	파라미터	값
GAs	세대 수	100
	군집 크기	50
	교배율	0.65
	돌연변이율	0.1
FNN	소속 함수의 정점	2, 3, 5개
	학습률	$0.0 \leq \eta \leq 0.01$
	모멘텀 계수	$0.0 \leq \alpha \leq 0.001$

1. Fisher의 Iris 데이터

실험에 사용된 Iris 데이터^[8]는 3개의 클래스(setosa, versicolor, virginica)로 구성되며, 각 클래스마다 50개의 패턴으로 구성되어 있고, 각 패턴은 4개의 속성으로 정의된다.

표 2. 최적화된 퍼지 뉴럴 네트워크의 성능
Table 2. Performance of optimized FNN

FNN		CR		PI	
MFs 수	추론	학습	테스트	학습	테스트
2	간략	97.33±1.56	96.89±3.37	0.030±0.00	0.032±0.01
	선형	99.43±0.52	98.67±1.22	0.023±0.00	0.025±0.00
	2차식	99.05±0.67	99.56±0.99	0.023±0.00	0.025±0.01
3	간략	99.43±0.52	99.11±1.22	0.021±0.00	0.018±0.01
	선형	99.43±0.52	99.11±1.22	0.018±0.00	0.020±0.00
	2차식	99.43±0.52	99.11±1.22	0.019±0.00	0.015±0.00
5	간략	99.43±0.52	98.22±0.99	0.017±0.00	0.018±0.00
	선형	99.05±0.67	99.11±1.22	0.016±0.00	0.019±0.00
	2차식	99.81±0.43	96.89±1.22	0.015±0.00	0.021±0.01

Fisher의 Iris 데이터를 이용한 퍼지 뉴럴 네트워크에 의한 패턴 분류는 각 입력 데이터의 최소값과 최대값을 균등 분할하여 입력 공간 분할을 수행하였고, 공간 분할에 따른 전반부 소속 함수의 정점을 각 입력 변수에 대해 2개, 3개, 5개씩 할당하였으며, 후반부 구조로는 간략 추론, 선형 추론, 변형된 2차식 추론을 사용하였다. 후반부 다항식 계수의 연결가중치는 오류 역전파 알고리즘

을 이용하여 학습하였다. 또한, 실수코딩 유전자 알고리즘을 적용하여 전반부 소속 함수의 정점과 학습률, 모멘텀 계수를 동조하였다. 표 2는 제안한 퍼지 뉴럴 네트워크의 성능을 보여준다.

표 2에서 알 수 있듯이 대부분 상당히 좋은 인식률을 보여주며, 정확도 측면에서는 규칙수가 증가할수록 후반부 구조가 간략 추론, 선형 추론, 변형된 2차식 추론으로 갈수록 성능이 좋아지는 것을 알 수 있다. 또한, 근사화 및 일반화 모두 성능이 향상된 것을 알 수 있다. 가장 좋은 모델은 각 입력에 대해 소속 함수의 수가 2개 이고, 후반부 구조가 변형된 2차식 추론인 경우이다. 이때의 인식률은 학습 데이터에 대해 99.05±0.67%이고 테스트 데이터에 대해 99.56±0.99%이며, 정확도는 학습 데이터에 대해 0.023±0.00이고 테스트 데이터에 대해 0.025±0.00이다.

표 3은 선택한 모델에 대한 분류 행렬을 보여준다. 표 3에서 학습 데이터와 테스트 데이터에 대해 Setosa와 Virginica는 각각 100%의 인식률을 보인 반면, Versicolor를 Virginica로 잘못 인식하는 경우는 학습 데이터에 대해 2.86%이고 테스트 데이터에 대해 1.33%인 것을 알 수 있다.

표 3. 분류 행렬에 의한 성능 평가
Table 3. Performance evaluation by Confusion matrix

(a) 학습 데이터

	Setosa	Versicolor	Virginica
Setosa	100.00±0.00	0.00±0.00	0.00±0.00
Versicolor	0.00±0.00	97.14±2.02	2.86±2.02
Virginica	0.00±0.00	0.00±0.00	100.00±0.00

(b) 테스트 데이터

	Setosa	Versicolor	Virginica
Setosa	100.00±0.00	0.00±0.00	0.00±0.00
Versicolor	0.00±0.00	98.67±2.98	1.33±2.98
Virginica	0.00±0.00	0.00±0.00	100.00±0.00

그림 3은 선택한 모델의 5번 반복에 따른 인식률과 정확도의 평균값에 대한 최적화 탐색과정을 보여주며 빠른 수렴 특성을 갖는 것을 알 수 있다.

표 4는 기존 모델과의 비교를 보여준다. 기존 모델과 비교해 보면 제안한 네트워크는 학습 데이터와 테스트 데이터에 대한 평균 패턴 인식률이 모두 99%를 넘는 가장 좋은 패턴 인식률을 갖는다.

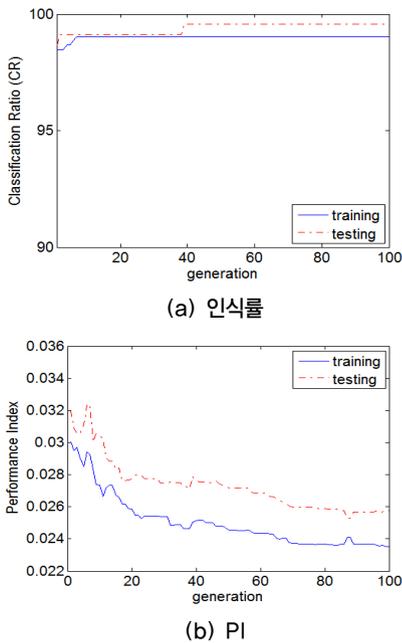


그림 3. 최적화 과정
Fig 3. Optimization process

표 4. 기존 모델과의 성능 비교
Table 4. Comparison of previous models

모델	평균 분류율(%)		
	전체	학습	테스트
Simpson ^[9]	97.3		
Nauck ^[10]		96	97.3
		97.3	96
Meesad ^[11]	88~97.3		
Yen ^[12]		96.7	96.2
Li ^[13]	96.67		
The proposed model		99.05	99.56

2. Wisconsin Diagnostic Breast Cancer 데이터

WDBC 데이터는 유방암의 악성 유무를 판단하는 패턴 인식 데이터이다. WDBC 데이터는 총 569개의 패턴으로 구성되어 있으며 이중 357개의 데이터는 양성(benign), 나머지 212개의 데이터는 악성(malignant)으로 구분된다. 각 패턴들은 암 세포핵의 특징을 나타내는 30개의 실수를 가진 입력 벡터이며 특징들에 대한 자세한 설명은 참고 문헌^[8]에 기술되어 있다.

WDBC 데이터를 이용한 퍼지 뉴럴 네트워크에 의한 패턴 분류는 앞 절의 방법과 같은 방법으로 수행하였으며, WDBC 데이터의 입력 공간의 차원이 매우 크기 때

문에 공간 분할에 따른 전반부 소속 함수의 정점을 각 입력 변수에 대해 2개 또는 3개씩 할당하였으며, 후반부 구조로는 간략 추론, 선형 추론을 사용하였다. 표 5는 제안한 퍼지 뉴럴 네트워크의 성능을 보여준다.

표 5. 최적화된 퍼지 뉴럴 네트워크의 성능
Table 5. Performance of optimized FNN

FNN		CR		PI	
MFs 수	추론	학습	테스트	학습	테스트
2	간략	98.69±0.45	98.36±1.12	0.060±0.00	0.060±0.01
	선형	98.59±0.38	98.25±0.72	0.047±0.00	0.050±0.00
3	간략	98.94±0.33	98.36±0.64	0.044±0.00	0.049±0.01
	선형	99.05±0.28	98.25±0.92	0.037±0.00	0.047±0.01

표 5에서 알 수 있듯이 대부분 98%의 좋은 인식률을 보여준다. 정확도 측면에서는 규칙수가 증가할수록 후반부 구조가 간략 추론, 선형 추론으로 갈수록 성능이 좋아지는 것을 알 수 있다. 또한, 근사화 및 일반화 모두 성능이 향상된 것을 알 수 있다. 각 입력에 대해 소속 함수의 수가 3개 이고, 후반부 구조가 간략 추론인 경우에 가장 좋은 성능을 갖는 것을 알 수 있다. 이때의 인식률은 학습 데이터에 대해 98.94±0.33%이고 테스트 데이터에 대해 98.36±0.64%이며, 정확도는 학습 데이터에 대해 0.044±0.00이고 테스트 데이터에 대해 0.049±0.01이다.

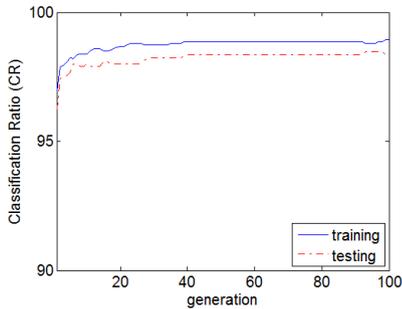
표 6은 선택한 모델에 대한 분류 행렬을 보여준다. 표 6에서 학습 데이터에서 양성을 악성으로 오분류하는 경우는 0.40%이고 악성을 양성으로 오분류하는 경우는 2.16%인 것을 알 수 있다. 테스트 데이터를 보면 양성을 악성으로 오분류하는 경우는 0.37%이고 악성을 양성으로 오분류하는 경우는 3.75%인 것을 알 수 있다. 대체로 악성을 양성으로 오분류하는 경우가 대략 3% 전후인 것을 알 수 있다.

표 6. 분류 행렬에 의한 성능 평가
Table 6. Performance evaluation by Confusion matrix

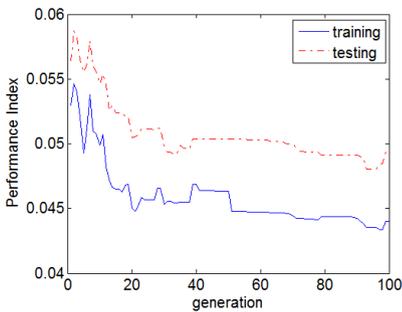
(a) 학습 데이터		
	양성	악성
양성	99.60±0.40	0.40±0.40
악성	2.16±0.57	97.84±0.57

(b) 테스트 데이터		
	양성	악성
양성	99.63±0.51	0.37±0.51
악성	3.75±1.78	96.25±1.78

그림 4는 선택한 모델의 5번 반복에 따른 인식률과 정확도의 평균값에 대한 최적화 탐색과정을 보여주며 빠른 수렴 특성을 갖는 것을 알 수 있다.



(a) 인식률



(b) PI

그림 4. 최적화 과정
Fig. 4. Optimization process

표 7은 기존 모델과의 비교를 보여준다. 기존 모델과 비교해 보면 제안한 네트워크는 학습 데이터와 테스트 데이터에 대한 평균 패턴 인식률이 모두 98%를 넘는 가장 좋은 패턴 인식률을 갖는다.

표 7. 기존 모델과의 성능 비교
Table 7. Comparison of previous models

Model	Classification Ratio (%)
SVM ^[14]	96.68±2.40
Bayes Net ^[15]	95.81
RVM ^[16]	97.20±1.86
MLP ^[17]	85.92±3.02
MPANN ^[18]	98.1
DigaNN ^[19]	97.9
RBF ^[20]	97.13±1.80
The proposed model	98.36±0.64

V. 결론

본 논문에서는 개별 입력 공간을 기반으로 하는 퍼지 뉴럴 네트워크를 설계하였으며, 그 설계과정을 상세히 설명하였다. 퍼지 규칙의 전반부는 개별 입력 공간을 독립적으로 분할하여 형성하였으며, 퍼지 규칙의 후반부는 다항식을 이용하여 표현하고 오류 역전파 알고리즘을 이용하여 각 규칙의 후반부 다항식 계수를 학습하였다. 또한, 실수코딩 유전자 알고리즘을 이용하여 전반부 소속 함수의 정점과 학습률, 모멘텀 계수를 최적화하였다. 제안한 네트워크는 Fisher의 Iris 데이터와 WDBC 데이터를 이용하여 패턴 분류에 적용하였다.

두 가지의 실험 데이터를 통해 모델을 평가하는 데 있어서 인식률과 정확도는 서로 밀접한 관계가 있는 것을 알 수 있었다. 즉, 인식률이 좋으면 정확도도 좋은 경향을 보여준다. 하지만 인식률이 가장 적은 모델이라 할지라도 정확도는 그러하지 않는 경우가 있었다.

실험을 통해 인식률과 정확도에 있어서 근사화 및 일반화 모두 좋은 성능 향상을 보여주었으며 퍼지 뉴럴 네트워크를 이용하여 최적의 패턴 인식기를 설계할 수 있었다. 본 연구에 의해 개발된 퍼지 뉴럴 네트워크는 모델링 및 패턴 인식률 해석에 보다 광범위하게 적용될 것으로 사료된다.

참고 문헌

- [1] Takeshi Yamakawa, "A Neo Fuzzy Neuron and Its Applications to System Identification and Prediction of the System Behavior", Proceedings of the 2nd International Conference on Fuzzy logic & Neural Networks, pp. 477-483, 1992.
- [2] J. J. Buckley and Y. Hayashi, "Fuzzy neural networks: A survey", Fuzzy Sets and Systems, vol. 66, pp. 1-13, 1994.
- [3] J.-S. R. Jang, C. -T. Sun, E. Mizutani, "Neuro-Fuzzy And Soft Computing", Prentice-Hall, 1997.
- [4] Y.-H. Han, K.-C. Kwak, "An Optimization Design of Granular Network by GA and Information Granules", Journal of Korean Institute of Information Technology, vol. 8, no. 7, pp. 81-87, Oct 2010.
- [5] I.-K. Park "A Study on the Prediction of the

- Nonlinear Chaotic Time Series Using Genetic Algorithm based Fuzzy Neural Network”, Journal of the Institute of Webcasting Internet and Telecommunication, vol. 11, no. 4, pp. 91-97, Apr 2011.
- [6] K.-J. Park, D.-Y. Lee, “Design of Fuzzy Neural Networks Based on Fuzzy Clustering and Its Application”, Journal of Korea Academia-Industrial cooperation Society, vol. 14, no. 1, pp. 378-384, Jan 2013.
- [7] D. E. Goldberg, “Genetic Algorithm in search, Optimization & Machine Learning”, Addison wesley, 1989.
- [8] UCI Machine Learning Repository: Data Sets, <http://archive.ics.uci.edu>
- [9] P. K. Simpson, “Fuzzy Min-Max Neural Networks -Part 1 : Classification”, IEEE Trans on. Neural Networks, vol. 3, no. 5, 1992.
- [10] D. Nauck, R. Kruse, “A neuro-fuzzy method to learn fuzzy classification rules from data”, Fuzzy Sets and Systems, vol. 89, pp. 277-288, 1997.
- [11] P. Meesad, G. G. Yen, “Pattern classification by a neurofuzzy network : application to vibration monitoring”, ISA Transactions, vol. 39, pp. 293-308, 2000.
- [12] G. G. Yen, P. Meesad, “An effective neuro-fuzzy paradigm for machinery condition health monitoring”, IEEE Trans. on Systems, Man, and Cybern., : Part B, vol.31, no.4, 2001.
- [13] R. Li, M. Mukaidono and I.B. Turksen, “A fuzzy neural network for pattern classification and feature selection”, Fuzzy Sets and Systems, vol. 130, pp. 101-140, 2002.
- [14] V. Vapnik, “The Nature of Statistical Learning Theory. New York” Springer-Verlag, 1995
- [15] F. Jensen, “An Introduction to Bayesian Networks“, UCL Press/Springer-Verlag, 1996
- [16] M. E. Tipping, “The relevance vector machine“, Adv. Neural Inf. Process. Syst., vol. 12, pp. 652- 658, 2000
- [17] R. O. Duda, and P. E. Hart, “Pattern Classification and Scene Analysis“, New York: Wiley, 2002
- [18] H. A. Abbass, “An evolutionary artificial neural networks approach for breast cancer diagnosis“, Artif Intell in Med, vol. 25, no. 3, pp. 265-281, 2002
- [19] I. Anagnostopoulos, and I. Maglogiannis, “Neural network-based diagnostic and prognostic estimations in breast cancer microscopic instances“, Medical & Biological Engineering & Computing Springer Publishers, vol. 44, no. 9, pp. 773-784, 2006
- [20] Z. R. Young, “A Novel Radial Basis Function Neural Network for Discriminant Analysis”, IEEE Trans. Neural Networks, vol. 17, no. 3, pp. 604-612, 2006

※ 본 논문은 2012년 원광대학교의 교비 지원에 의하여 수행되었으며, 이에 감사드립니다.

저자 소개

박 건 준(정회원)



- 2003년 : 원광대학교 전기전자공학부 졸업 (공학사)
- 2005년 : 원광대학교 제어계측공학과 졸업 (공학석사)
- 2010년 : 수원대학교 전기공학과 (공학박사)
- 2010년 ~ 2012년 : 원광대학교 공과

대학 POST-BK21 Post-Doc

• 2012년 ~ 현재 : 원광대학교 리서치펠로우 연구교수
 <관심분야 : 컴퓨터 및 인공지능, 유전자 알고리즘 및 최적화 이론, 지능시스템 및 제어>

김 용 갑(정회원)



- 1988년 : 아주대학교 전자공학과 (공학사)
- 1993년 : 엘라바마 주립대 (공학석사)
- 2000년 : 노스캐롤라이나 주립대 전기·컴퓨터공학과 (공학박사)
- 2003년 ~ 현재 : 원광대학교 정보통신공학과 정교수

• 2012년 ~ 현재 : LED 인력양성사업단장(전북)

• 2012년 ~ 현재 : 원광대학교 IT·BT창업보육센터장

<관심분야 : 가시광통신시스템, 전력선통신>

김 변 곤(정회원)



과 교수

<관심분야 : 가교환 및 시스템, 트래픽 제어>

- 1990년 : 한국항공대학교 항공전자공학과 졸업(공학사)
- 1997년 : 전북대학교 대학원 전자공학과 졸업(공학석사)
- 2001년 : 전북대학교 대학원 전자공학과 졸업(공학박사)
- 현재 : 군산대학교 공과대학 전자공학과 교수

황 근 창(정회원)



디스플레이학과 교수

- 2010년 ~ 현재 : 한국 정신과학 학회 이사
- 2011년 ~ 현재 : 원광대학교 인체과학 연구소장
- 2012년 ~ 현재 : 원광대학교 자연대학 학장

<관심분야 : 광학및 광응용, LED 및 태양광 발전, 레이저 분광학, RF 스퍼터링, 정신과학>

- 1981년 : 고려대학교 물리학과 (이학사)
- 1985년 : Write State Univ. 물리학과 졸업 (이학 석사)
- 1989년 : Texas Christian Univ. 물리학과 졸업 (이학 박사)
- 1992년 ~ 현재 : 원광대학교 반도체 디스플레이학과 교수