

<https://doi.org/10.7236/JIIBC.2017.17.1.173>

JIIBC 2017-1-23

불확실성을 고려한 퍼지 클러스터링 기반 퍼지뉴럴네트워크 설계

Design of Fuzzy Neural Networks Based on Fuzzy Clustering with Uncertainty

박건준*, 김용갑**, 황근창***

Keon-Jun Park*, Yong-Kab Kim**, Geun-Chang Hoang***

요약 산업이 발달함에 따라서 빅데이터가 무수히 생산되고 있으며 이에 따라서 데이터에 내재된 불확실성도 증가하고 있다. 본 논문에서는 데이터에 내재된 불확실성을 다루기 위해 interval type-2 퍼지 클러스터링 방법을 제안하고 이를 이용하여 퍼지뉴럴네트워크를 설계하고 최적화한다. 제안한 클러스터링 방법을 이용하여 퍼지 규칙을 설계하고 학습을 수행한다. 최적화하는 방법으로서 유전자 알고리즘을 이용하고 모델 파라미터들을 최적 탐색한다. 실험에서는 두 가지 패턴 분류를 시행하였으며 두 가지 실험 모두 우수한 패턴 인식 결과를 보여준다. 제안한 네트워크는 증가하는 불확실성을 다룰 수 있는 방법을 제공할 수 있을 것이다.

Abstract As the industries have developed, a myriad of big data have been produced and the inherent uncertainty in the data has also increased accordingly. In this paper, we propose an interval type-2 fuzzy clustering method to deal with the inherent uncertainty in the data and, using this method, design and optimize the fuzzy neural network. Fuzzy rules using the proposed clustering method are designed and carried out the learning process. Genetic algorithms are used as an optimization method and the model parameters are optimally explored. Experiments were performed with two pattern classification, both of the experiments show the superior pattern recognition results. The proposed network will be able to provide a way to deal with the uncertainty increasing.

Key Words : Fuzzy clustering, Interval type-2 fuzzy set, Fuzzy neural networks, Genetic algorithms, Pattern recognition

1. 서론

디지털 산업이 발전하면서 주변에서는 가늠할 수 없을 정도의 데이터가 매일 생산되고 있다. 이러한 데이터들은 데이터의 양, 데이터의 입출력 속도, 데이터 종류의 다양성의 측면에서 빅데이터를 정의하였다. 이러한 빅데

이터들을 예측하고 분류하기 위한 다양한 접근이 시도되고 있다.^[1-3]

퍼지뉴럴네트워크는 시스템의 복잡성과 데이터의 불확실성을 나타내는 비선형 공정 및 패턴 분류 분석에서 많은 연구가 진행되고 있다. 퍼지논리는 1965년 Zadeh^[4]에 의해 처음 소개된 퍼지 집합을 이용하여 복잡한 실 시

*정회원, 가천대학교 스마트그린홈연구센터

**중신회원, 원광대학교 정보통신공학과

***정회원, 원광대학교 반도체디스플레이학과(교신저자)
접수일자 2016년 10월 5일, 수정완료 2017년 1월 6일
게재확정일자 2017년 2월 3일

Received: 5 October, 2016 / Revised: 6 January, 2017 /

Accepted: 3 February, 2017

***Corresponding Author: gchoang@wku.ac.kr

Dept. of Semiconductor & Display, Wonkwang University, Korea

시스템을 해석하고 적용함으로써 좋은 결과를 가져왔다. 이러한 결과는 0 또는 1로 표현되는 이진 논리와는 달리 0과 1사이의 소속정도로 표현함으로써 해결할 수 있었다. 또한, 인공지능망의 학습 방법을 도입하여 적용적인 네트워크를 설계할 수 있다. 하지만 디지털 산업이 발전하면서 시스템은 더욱 복잡해지고 수많은 데이터들이 생산되면서 데이터에 내재된 불확실성이 증가하고 있다^[3,5-7].

Type-1 퍼지 집합을 확장한 Type-2 퍼지 집합은 Zadeh^[7]에 의해 소개되었으며, type-2 퍼지 집합의 이론적인 연산 및 소속함수의 특성은 Mizumoto와 Tanaka^[8]에 의해 연구되었다. Mendel과 Karnik은 type-2 퍼지 논리 시스템에 대해 퍼지 “if-then” 규칙으로 표현하였으며 계산의 복잡성으로 인해 보다 간결한 interval type-2 퍼지 논리 시스템을 제안하였다^[9].

Interval type-2 퍼지뉴럴네트워크는 interval type-2 퍼지 집합과 신경망의 융합에 의한 네트워크이다. interval type-2 퍼지 모델은 정성적인 표현이 가능하고 불확실한 정보를 가지고 있는 시스템에 강인성을 가지며 신경망은 학습을 통해 시스템의 입출력 관계를 도출할 수 있으며 병렬처리 능력을 가진다. 그러나 시스템의 복잡성 및 빅데이터의 특성으로 인해 모델링하는데 어려움이 있으며 이러한 문제를 해결하기 위해 클러스터 방법을 융합한 방법들이 연구되고 있다^[10].

본 논문에서는 불확실성을 다루기 위해 interval type-2 퍼지 클러스터링을 이용하여 입력 공간을 분할하여 퍼지 규칙의 전반부를 형성한다. 후반부 구조는 interval 집합을 이용하여 다항식으로 표현되고 오류역전과 알고리즘을 이용하여 다항식 계수를 학습한다.

제한한 퍼지뉴럴네트워크는 파라미터들(불확실성 계수 그리고, 학습률 및 모멘텀 계수)을 추정하기 위하여 실수코딩 유전자 알고리즘^[11]을 이용한다. 또한, 제한한 퍼지뉴럴네트워크는 표준 모델로서 널리 사용되는 수치적인 예를 통하여 평가한다.

II. Fuzzy Clustering

1. Interval type-2 퍼지 집합

Interval type-2 퍼지 집합은 기존의 type-1 퍼지 집합을 확장한 개념으로 데이터에 내재된 불확실성을 보다 효과적으로 다룰 수 있다.

Interval type-2 소속함수 \tilde{A} 는 다음과 같이 표현된다.

$$\begin{aligned}\tilde{A} &= \int_{x \in X} \mu_{\tilde{A}}(x)/x \\ &= \int_{x \in X} \left[\int_{u \in J_x} 1/u \right] /x, J_x \subseteq [0,1]\end{aligned}\quad (1)$$

여기서, secondary 소속함수는 Interval이며, J_x 는 x 에 대한 primary 소속함수이다.

primary 소속 값에 대한 불확실성은 FOU(footprint of uncertainty)에 의해 표현된다. FOU에 대한 예는 그림 1에서 보여준다. 여기서, a, b, c 는 소속함수의 파라미터이며 σ_a 와 σ_c 는 파라미터 a 와 c 의 불확실성을 의미한다.




그림 1. Interval Type-2 퍼지 집합
Fig. 1. Interval Type-2 Fuzzy Set

Interval type-2 퍼지 집합은 두 개의 type-1 소속함수로 표현된다. 상위 소속함수 $\overline{\mu}_{\tilde{A}}(x)$ 는 FOU(\tilde{A})의 상위경계를 나타내며 하위 소속함수 $\underline{\mu}_{\tilde{A}}(x)$ 는 FOU(\tilde{A})의 하위경계를 의미한다.

2. Interval type-2 Fuzzy Clustering

퍼지 클러스터링은 주어진 데이터를 두 개 이상의 그룹으로 군집화 하는 방법으로 각각의 데이터는 0과 1사이에서의 소속정도를 갖는다. 주어진 데이터의 불확실성으로 다루기 위하여 interval type-2 퍼지 집합을 이용하여 interval type-2 퍼지 클러스터링 방법을 제안한다. 제안한 알고리즘의 수행과정은 다음과 같다.

[단계 1] 클러스터의 수 c 를 정하고 퍼지화 계수 m 를 선택한다. 그리고, 소속 행렬 \mathbf{U} 를 초기화 한다.

[단계 2] 클러스터 중심 \mathbf{v} 를 계산한다.

$$v_j = \frac{\sum_{i=1}^N u_{ij}^{m_j} x_i}{\sum_{i=1}^N u_{ij}^{m_j}} \quad (2)$$

[단계 3] 종료 조건을 만족하면 [단계 5]로 간다.
 [단계 4] 새로운 소속 행렬 \mathbf{U} 를 계산하고 [단계 2]로 간다.

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left(\frac{\|x_i - v_j\|}{\|x_i - v_k\|} \right)^{\frac{2}{m_j - 1}}} \quad (3)$$

[단계 5] 소속 행렬 \mathbf{U} 에서 최대의 소속 정도를 갖는 클러스터에 속한 데이터의 표준편차 σ_i 를 구한다.
 [단계 6] 불확실성 계수 ρ_i 를 이용하여 $(1 + \rho_i)\sigma_i$ 에 의해 불확실성을 조절한다.

$$\begin{aligned} \bar{m}_i &= m + (1 + \rho_i)\sigma_i, \\ \underline{m}_i &= m - (1 + \rho_i)\sigma_i \end{aligned} \quad (4)$$

여기서, \bar{m}_i 는 i 번째 클러스터에 대한 상위 퍼지화 계수이며, \underline{m}_i 는 i 번째 클러스터에 대한 하위 퍼지화 계수이다.

[단계 7] 클러스터 중심 \mathbf{v} 를 계산한다.
 [단계 7-1] 상위 퍼지화 계수에 의한 상위 클러스터 중심 $\bar{\mathbf{v}}_i$ 을 계산한다.
 [단계 7-2] 하위 퍼지화 계수에 의한 하위 클러스터 중심 $\underline{\mathbf{v}}_i$ 을 계산한다.
 [단계 8] 새로운 소속 행렬 \mathbf{U} 를 계산한다.
 [단계8-1] 새로운 상위 소속 행렬 $\bar{\mathbf{U}}$ 를 계산한다.
 [단계8-2] 새로운 하위 소속 행렬 $\underline{\mathbf{U}}$ 를 계산한다.

III. 퍼지뉴럴네트워크

1. 퍼지뉴럴네트워크의 구조

퍼지뉴럴네트워크는 퍼지 추론 시스템과 신경회로망의 두 구조가 결합된 구조로서 언어적 논리를 규칙의 형태로 표현하고 환경에 적응하는 학습 능력을 가지고 있다. 제안한 퍼지뉴럴네트워크는 데이터 속에 잠재된 불확실성을 다루기 위해 interval type-2 퍼지 클러스터링 알고리즘에 의해 입력공간을 분할하여 네트워크의 전반부를 퍼지 규칙으로 구성한다. 후반부 구조는 간략 추론,

선형 추론, 변형된 2차식 추론에 의해 표현되며 후반부 다항식은 데이터를 이용하여 학습된다. 그림 2는 제안한 Interval Type-2 퍼지 클러스터링 기반의 퍼지뉴럴네트워크의 구조를 보여준다.




그림 2. Interval Type-2 퍼지 클러스터링 기반의 퍼지뉴럴네트워크 구조
 Fig. 2. Structure of interval type-2 fuzzy clustering-based Fuzzy Neural Networks

입력 공간 분할에 의한 제안한 네트워크의 퍼지 규칙은 퍼지 규칙을 형성하며 다음과 같이 표현된다.

$$\begin{aligned} R^j: & \text{If } x_k \text{ is } \bar{A}_j \\ & \text{Then } y_j^s = f(x_1, \dots, x_d) \end{aligned} \quad (5)$$

간략 추론(Case 1) : $f = W_{j0}^s$

선형 추론(Case 2) : $f = W_{j0}^s + \sum_{i=1}^d W_{ji}^s x_i$

변형된 2차식 추론(Case 3) :

$$f = W_{j0}^s + \sum_{i=1}^d W_{ji}^s x_i + \sum_{i=1}^d \sum_{j=i+1}^d W_{j2}^s x_i x_j$$

여기서,

$$W_{ji}^s = [w_{ji}^s - s_{ji}^s, w_{ji}^s + s_{ji}^s], \quad i=0, \dots, d(d+1)/2$$

여기서, R^j 는 j 번째 퍼지 규칙을 나타내며, A_j 는 전반부 소속함수로 표현된다. W_{ji}^s 는 구간 집합으로 후반부 계수를 의미하며, w_{ji}^s 는 W_{ji}^s 의 중심음, s_{ji}^s 는 W_{ji}^s

의 폭을 각각 의미한다.

전반부 소속함수는 퍼지 클러스터링에 의한 소속행렬을 사용한다. 각 소속함수의 σ_a 와 σ_b 는 각 퍼지 부분 공간에 속한 데이터의 표준편차에 의해 구해지며, 불확실성 계수 ρ 를 이용하여 $(1+\rho)\sigma$ 에 의해 불확실성을 조절한다.

제안한 퍼지 뉴럴 네트워크 구조에서 각 층의 연산 과정은 다음과 같다.

[1층] 입력층

각 입력은 interval type-2 퍼지 클러스터링의 입력이 된다.

[2층] 입력에 대한 적합도 계산

소속함수는 앞서 설명한 interval type-2 퍼지 클러스터링에 의해 구해진 소속행렬에 의해 얻어진다.

$$\bar{\mu}_{F_j}(x) = \bar{u}_{ip}, \quad \underline{\mu}_{F_j}(x) = \underline{u}_{ip}, \quad j = i \quad (6)$$

$$\hat{f}_j = [\hat{f}_j^-, \hat{f}_j^+] = [\bar{u}_j, \underline{u}_j] \quad (7)$$

[3층] Type Reduction

가장 왼쪽 지점 y_l 과 가장 오른쪽 지점 y_r 은 \hat{f}_{kc} 에 의존하며, 반복법에 따른 Karnik-Mendel (KM) 알고리즘^[8]을 이용하여 구해진다.

$$y_l^s = \frac{\sum_{j=1}^n \hat{f}_{jl}^s y_{jl}^s}{\sum_{j=1}^n \hat{f}_{jl}^s}, \quad y_r^s = \frac{\sum_{j=1}^n \hat{f}_{jr}^s y_{jr}^s}{\sum_{j=1}^n \hat{f}_{jr}^s} \quad (8)$$

여기서, \hat{f}_{jl}^s 와 \hat{f}_{jr}^s 는 s번째 출력에 대한 각 규칙에서 가장 왼쪽 지점 y_{sl} 과 가장 오른쪽 지점 y_{sr} 에 영향을 준 상위 소속함수와 하위 소속함수이다.

[4층] 최종출력

최종 출력은 구간 집합이므로 최종 출력은 가장 왼쪽 지점 y_l^s 과 가장 오른쪽 지점 y_r^s 의 평균에 의해 구해진다.

$$\hat{y}_s = \frac{y_l^s + y_r^s}{2} \quad (9)$$

2. 퍼지뉴럴네트워크의 학습

네트워크의 학습은 연결가중치를 오차를 최소화하는 방향으로 조절해 가면서 이루어진다. 학습방법은 오류역전파 알고리즘을 이용한다.

$$E_p = \frac{1}{2} \sum_{s=1}^q (y_{ps} - \hat{y}_{ps})^2 \quad (10)$$

여기서, E_p 는 p번째 데이터에 대한 오차이고, y_{ps} 와 \hat{y}_{ps} 는 p, s번째 원 출력과 모델 출력을 나타낸다.

간략 추론의 경우 연결가중치 w_{j0}^s 의 조절은 다음과 같다.

$$w_{j0}^s(p+1) = w_{j0}^s(p) + \Delta w_{j0}^s \quad (11)$$

연결가중치의 변화량은 경사하강법을 이용하여 구할 수 있다.

$$\Delta w_{j0}^s = \eta \left(- \frac{\partial E_p}{\partial w_{j0}^s} \right) \quad (12)$$

여기서, η 는 학습률이며, 사슬법칙에 의해 다음과 같이 전개된다.

$$- \frac{\partial E_p}{\partial w_{j0}^s} = - \frac{1}{2} \frac{\partial E_p}{\partial y_{ps}} \left(\frac{\partial \hat{y}_{ps}}{\partial y_l^s} \frac{\partial y_l^s}{\partial w_{j0}^s} + \frac{\partial \hat{y}_{ps}}{\partial y_r^s} \frac{\partial y_r^s}{\partial w_{j0}^s} \right) \quad (13)$$

또한, 학습시간을 단축시키고, 학습성능을 향상시키기 위해 모멘텀을 추가한다. 모멘텀은 현재의 연결가중치와 그 이전 연결가중치의 차이에 의해 계산된다. 모멘텀까지 포함하는 연결가중치 w_{j0}^s 의 최종 변화량은 다음과 같다.

$$\Delta w_{j0}^s = 0.25\eta(y_{ps} - \hat{y}_{ps})(\hat{f}_j^l + \hat{f}_j^r) + \alpha(w_{j0}^s(p) - w_{j0}^s(p-1)) \quad (14)$$

한편, 연결가중치 s_{j0}^s 의 조절은 다음과 같다.

$$s_{j0}^s(p+1) = s_{j0}^s(p) + \Delta s_{j0}^s \quad (15)$$

같은 방법으로, 모멘텀까지 포함하는 연결 가중치 s_{j0}^s 의 최종 변화량은 다음과 같다.

$$\Delta s_{j0}^s = 0.25\eta(y_{ps} - \hat{y}_{ps})(-f_j^l + \hat{f}_j^r) + \alpha(s_{j0}^s(p) - s_{j0}^s(p-1)) \quad (16)$$

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

IV. 모델 최적화

유전자 알고리즘^[11]은 적자생존에 기반을 둔 생물학적인 원리에 바탕을 둔 최적화 기법중의 하나이다. 자연계에 있어서 유전과 진화의 메카니즘을 모델화함으로써 실제 세계의 문제를 풀 수 있으며 풀고자 하는 문제의 해를 개체로 나타내고, 이들 개체들로 군집을 형성한다. 진화를 거듭해 가면서 각 개체들의 유전 정보를 서로 교환하면서 적자 생존의 법칙에 따라 주어진 문제에서 최적의 해를 찾아 간다.

유전자 알고리즘은 재생산, 교배, 돌연변이의 3개의 기본 연산자를 가지고 있다. 재생산 연산자는 다음 세대를 위해 교배 유전자가 선택되는 과정으로, 적합도에 따라 다음세대를 생산한다. 교배 연산자는 교배 유전자로부터 염색체들을 확률적으로 선택 및 교환한다. 돌연변이 연산자는 유전자의 값을 일정한 확률로 변화시켜 진역탐색이 가능하도록 변경한다. 유전자 알고리즘은 초기 집단 생성하여 적합도를 평가한 후, 재생산, 교배, 돌연변이의 유전 연산자를 통해 최적해를 탐색한다.

본 논문에서는 제안한 퍼지뉴럴네트워크의 구조를 설계한 후 네트워크에 내재된 파라미터들을 실수 코딩 유전자 알고리즘을 이용하여 최적화 한다. 최적화할 파라미터는 불확실성 계수와 학습률 및 모멘텀 계수이며, 유전 연산자는 룰렛 휠 선택, 일점 교배, 랜덤 번이를 사용하고 우월한 유전자를 보존하기 위해 엘리티즘을 사용한다.

V. 실험 및 결과

본 절에서는 제안한 네트워크를 평가하기 위하여 두 가지의 패턴 실험 데이터를 이용한다.

실험에 앞서 각 실험 데이터는 random sub-sampling 을 사용한다. 학습 데이터와 테스트 데이터는 전체 데이터 집합을 7:3 비율로 랜덤하게 나눈다. 또한 5번 반복 실험하여 패턴 분류를 수행한다. 성능 평가는 아래의 식을 이용하여 인식률과 정확도의 평균과 표준편차에 의해 평가한다.

$$E_p = \frac{\text{No. of classification}}{\text{No. of examples}} \times 100 \quad (17)$$

$$CR = \frac{1}{K} \sum_{i=1}^K E_p \quad (18)$$

$$PI = \frac{1}{K} \sum_{i=1}^K MSE \quad (19)$$

또한, 제안한 네트워크를 최적화하기 위해 유전자 알고리즘을 사용하고 이를 위한 초기 파라미터는 표 1에서 보여준다.

표 1. 초기 파라미터
 Table 1. Initial parameters

	파라미터	값
GAs	세대 수	100
	군집 크기	50
	교배 율	0.65
	돌연변이 율	0.1
FNN	불확실성 계수	$-1.0 \leq \rho \leq 1.0$
	학습률	$0.0 \leq \eta \leq 0.01$
	모멘텀 계수	$0.0 \leq \alpha \leq 0.001$

1. Fisher의 Iris 데이터 셋

첫 번째로 실험에 사용된 데이터는 Fisher의 Iris 데이터 셋이다^[12]. Iris 데이터 셋은 Iris Setosa, Iris Versicolor, Iris Virginica를 패턴 분류하는 문제이며 3가지의 클래스로 구성된다. 각 패턴은 꽃받침 길이, 꽃받침 너비, 꽃잎 길이, 꽃잎 너비의 4가지의 속성으로 정의된다. 각 클래스는 50개의 패턴을 가지며 총 150개의 패턴으로 구성된다.

앞 장에서 언급한 내용을 바탕으로 퍼지뉴럴네트워크를 설계하였으며 초기 파라미터를 이용하여 제안한 퍼지뉴럴네트워크를 최적화하였다. 클러스터의 수와 후반부 구조를 변경하면서 각 모델에 대해 초기 파라미터를 설정하여 최적화 하였으며 5번 반복 실험하였다. 클러스터

의 수는 5, 10, 15, 20개를 사용하였으며 후반부 구조는 간략, 선형 및 변형된 2차식 추론을 사용하였다. 각 수행에 따른 성능은 그림 3과 그림 4에서 보여준다. 여기서 x 축은 규칙수와 후반부 추론을 나타낸다. 예를 들어 5/1은 규칙 5개, 간략 추론을 의미한다.

그림 3은 규칙 수(클러스터 수)와 후반부 구조에 따른 CR 성능을 보여준다. 모든 구조에 대해 97%이상의 분류 성능을 보이며 근사화 성능과 일반화 능력이 좋은 것을 알 수 있다. 가장 좋은 성능을 보이는 구조는 20/2인 규칙 수가 20개이고 후반부 구조가 선형 구조를 가지는 구조이다. 이 때의 성능은 학습 데이터에 대해 98.48 ± 0.52 을 보여주며 테스트 데이터에 대해 99.56 ± 0.99 을 보여준다. 간략 구조의 경우 성능 편차가 있으며 모델의 복잡성을 고려할 경우 10/1 구조를 선택할 수 있다.

그림 4는 규칙 수(클러스터 수)와 후반부 구조에 따른 PI 성능을 보여준다. CR 성능과 유사하게 근사화 성능과 일반화 능력이 좋은 것을 알 수 있다. 20/2 구조에서 학습 데이터에 대한 PI 성능은 0.024 ± 0.01 을 보 테스트 데이터에 대한 PI 성능은 0.017 ± 0.01 을 보여준다.




그림 3. 인식률에 의한 성능 평가
Fig. 3. Performance evaluation by CR

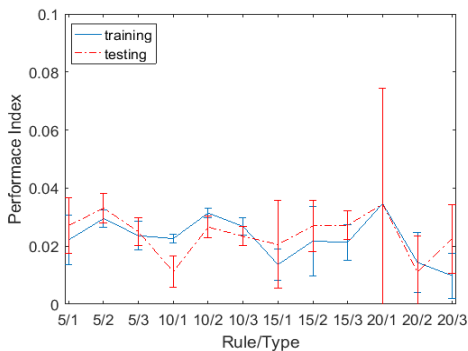


그림 4. 정확도에 의한 성능 평가
Fig. 4. Performance evaluation by PI

그림 5는 선택된 모델인 20/2에 대해 인식률에 대한 최적화 과정과 정확도에 대한 최적화 과정을 보여준다. 그림에서 알 수 있듯이 40세대 부근에서 수렴하는 것을 알 수 있으며, 수렴 속도 또한 빠른 것을 알 수 있다.




그림 5. 인식률에 대한 최적화 과정
Fig. 5. Optimization process for CR

제안한 모델과 기존 모델과의 비교를 표 2에서 보여준다. 제안한 퍼지뉴럴네트워크는 평균 패턴 인식률이 99%를 넘는 우수한 패턴 인식률을 갖는 것을 알 수 있다.

표 2. 기존 모델과의 비교
Table 2. Comparison of previous models

Model	Classification Ratio (%)
NEFCLASS	96.0
C4.5	94.0
FID3.1	96.0
HNFQ	98.67
HNFB-1	98.67
The proposed model	99.56

2. WDBC 데이터 셋

두 번째 실험 데이터는 WDBC(Wisconsin Diagnostic Breast Cancer) 데이터를 이용하였다^[11]. WDBC 데이터는 유방암의 악성 유무를 판단하는 패턴 인식 데이터 셋이다. WDBC 데이터는 357개의 양성(benign) 데이터와 212개의 악성(malignant) 데이터로 구분되며, 총 569개의 패턴으로 구성되어 있다. 각 패턴들은 30개의 실수를 가진 입력 벡터이며 암 세포핵의 특징을 나타낸다. 각 특징들에 대한 자세한 설명은 참고 문헌^[12]에 기술되어 있다.

앞에서 언급한 내용을 바탕으로 WDBC 데이터를 이용하여 제안한 퍼지뉴럴네트워크를 최적 설계하였다. 클

러스터의 수와 후반부 구조를 변경하면서 각 모델에 대해 초기 파라미터를 설정하여 최적화 하였으며 5번 반복 실험하였다. 클러스터의 수는 5, 10, 15, 20개를 사용하였으며 후반부 구조는 입력 변수의 개수를 고려하여 간략 및 선형 추론을 사용하였다. 각 수행에 따른 성능은 그림 6과 그림 7에서 보여준다.

그림 6은 규칙 수(클러스터 수)와 후반부 구조에 따른 CR 성능을 보여준다. 모든 구조에 대해 95%이상의 분류 성능을 보이며 근사화 성능과 일반화 능력이 좋은 것을 알 수 있다. 가장 좋은 성능을 보이는 구조는 10/2인 규칙 수가 10개이고 후반부 구조가 선형 구조를 가지는 구조이다. 이 때의 성능은 학습 데이터에 대해 98.49 ± 0.40 을 보여주며 테스트 데이터에 대해 98.48 ± 1.41 을 보여준다.

그림 7은 규칙 수(클러스터 수)와 후반부 구조에 따른 PI 성능을 보여준다. CR 성능과 유사하게 근사화 성능과 일반화 능력이 좋은 것을 알 수 있다. 10/2 구조에서 학습 데이터에 대한 PI 성능은 0.048 ± 0.00 을 보 테스트 데이터에 대한 PI 성능은 0.046 ± 0.01 을 보여준다.




그림 6. 인식률에 의한 성능 평가
 Fig. 6. Performance evaluation by CR




그림 7. 정확도에 의한 성능 평가
 Fig. 7. Performance evaluation by PI

그림 8은 선택된 모델인 10/2에 대해 인식률에 대한 최적화 과정과 정확도에 대한 최적화 과정을 보여준다. 각각의 그림에서 알 수 있듯이 30세대 부근에서 수렴하는 것을 알 수 있으며, 수렴 속도 또한 빠른 것을 알 수 있다.




그림 8. 인식률에 대한 최적화 과정
 Fig. 8. Optimization process for CR

제안한 모델과 기존 모델과의 비교를 표 3에서 보여준다. 제안한 퍼지뉴럴네트워크는 평균 패턴 인식률이 98%를 넘는 우수한 패턴 인식률을 갖는 것을 알 수 있다.

표 3. 기존 모델과의 비교

Table 3. Comparison of previous models

Model	Classification Ratio (%)
SVM	96.68±2.40
Bayes Net	95.81
RVM	97.20±1.86
MLP	85.92±3.02
MPANN	98.1
DigaNN	97.9
RBF2	97.13±1.80
The proposed model	98.36±0.64

VI. 결 론

본 논문에서는 interval type-2 퍼지 클러스터링을 이용하여 불확실성을 다루었으며 입력 공간을 분할하여 퍼지 규칙의 형성하였다. 후반부 구조는 interval 집합을 이용하여 다항식으로 부분공간을 표현하였으며 BP 알고리

즘을 이용하여 다항식 계수를 학습하였다. 또한, 제안한 퍼지뉴럴네트워크의 파라미터들을 실수코딩 유전자 알고리즘을 이용하여 최적화 하였다.

실험에서 알 수 있듯이 제안한 네트워크는 근사화 및 일반화 능력이 우수하고 학습속도도 빠르며 인식을 및 정확도 측면에서도 상당히 좋은 성능을 보여주었다. 아울러, 제안한 네트워크는 입력 공간이 고차원으로 갈수록 차원의 문제로부터 자유로우며 불확실성을 다룰 수 있었다. 추후 연구로는 IoT 환경에서 환경 변화에 따른 불확실성을 적응적으로 모델링 할 수 있는 네트워크를 설계할 계획이다.

References

[1] D. Laney, "3D Data Management: Controlling Data Volume, Velocity and Variety," META Group Research Note, 2001.

[2] Gartner.com, "Big data," IT Glossary. [Online]. Available: <http://www.gartner.com/it-glossary/big-data/>, 2012

[3] X. Z. Wang and J. Huang, "Editorial: Uncertainty in learning from big data," Fuzzy Sets Syst., vol. 258, pp. 1 - 4, Jan. 2015.

[4] L. A Zadeh, "Fuzzy sets", Inf. Control 8, pp. 338-353, 1965.

[5] K. J. Park, Y. K. Kim, B. G. Kim and G. C. Hoang, "Design of Optimized Pattern Recognizer by Means of Fuzzy Neural Networks Based on Individual Input Space," The Journal of The Institute of Internet, Broadcasting and Communication(JIIBC), vol. 13 no. 2, pp. 181-189, Apr. 2013.
DOI : 10.7236/JIIBC.2013.13.2.181

[6] H.S. Choi, "Tuning Method of the Membership Function for FLC using a Gradient Descent Algorithm", Journal of the Korea Academia-Industrial cooperation Society(JKAIS), vol. 15, no. 12, pp.7277-7282, 2014.

[7] L. A. Zadeh, "The concept of a linguistic variable and its application to approximate reasoning-I," Information Science, vol. 8, pp. 199-249, 1975.

[8] M. Mizumoto, and K. Tanaka, " Some Properties of Fuzzy Sets of Type-2," Information and

Control, vol. 31, pp. 312-340, 1976

[9] J. M. Mendel, Uncertain Rule-Based Fuzzy Logic Systems: Introduction and New Directions, Prentice-Hall: NJ, 2001.

[10] Y.-Y. Lin, S.-H. Liao, J.-Y. Chang, and C.-T. Lin, "Simplified Interval Type-2 Fuzzy Neural Networks," IEEE Transactions on Neural Networks and Learning Systems, vol. 25, no. 5, pp. 959-969, May 2014.

[11] D. E. Goldberg, Genetic Algorithm in search, Optimization & Machine Learning, Addison wesley, 1989.

[12] UCI Machine Learning Repository: Data Sets, <http://archive.ics.uci.edu>.

저자 소개

박 건 준(정회원)



- 2003년 2월 : 원광대학교 전기전자공학과 (공학사)
 - 2005년 2월 : 원광대학교 제어계측공학과 (공학석사)
 - 2010년 8월 : 수원대학교 전기공학과 (공학박사)
 - 2016년 5월 : 원광대학교 공업기술개발연구소 연구교수
 - 2016년 6월 ~ 현재 : 가천대학교 스마트그린홈연구센터 연구교수
- <주관심분야 : 컴퓨터 및 인공지능, 퍼지추론시스템, 인공지능 경망 및 최적화, 스마트그리드>

김 용 갑(중신회원)



- 1988년 : 아주대학교 전자공학과 (공학사)
 - 1998년 : 엘라바마 주립대학교 (공학석사)
 - 2000년 : 노스캐롤라이나 주립대학교 (공학박사)
 - 2003년 ~ 현재 : 원광대학교 정보통신공학과 교수
 - 2006년 ~ 2013년 : 공과대학 POST-BK21 사업단장
 - 2012년 ~ 2015년 : 원광대학교 창업보육센터장
 - 2014년 ~ 2015년 : 원광대학교 창업지원단장
 - 2012년 ~ 현재 : LED 인력양성사업단장(전북)
- <주관심분야 : 가시광통신시스템, 광메모리센서, 전력선통신>

황 근 창(정회원)



- 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

- 2012년 ~ 2014년 : 원광대학교 자연대학 학장
 - 2015년 ~ 2016년 : (사)한국정신과학 학회 회장
- <주관심분야 : 광학 및 광응용, LED 및 태양광 발전, 레이저 분광학, RF스퍼터링, 정신과학>

※ 본 논문은 2015년도 원광대학교의 교비지원에 의해 수행됨.