

기상레이더를 이용한 최적화된 Type-2 퍼지 RBFNN 에코 패턴분류기 설계

Design of Optimized Type-2 Fuzzy RBFNN Echo Pattern Classifier Using Meteorological Radar Data

송 찬 석* · 이 승 철* · 오 성 권**
(Chan-Seok Song · Seung-Chul Lee · Sung-Kwun Oh)

Abstract - In this paper, The classification between precipitation echo(PRE) and non-precipitation echo(N-PRE) (including ground echo and clear echo) is carried out from weather radar data using neuro-fuzzy algorithm. In order to classify between PRE and N-PRE, Input variables are built up through characteristic analysis of radar data. First, the event classifier as the first classification step is designed to classify precipitation event and non-precipitation event using input variables of RBFNNs such as DZ, DZ of Frequency(DZ_FR), SDZ, SDZ of Frequency(SDZ_FR), VGZ, VGZ of Frequency(VGZ_FR). After the event classification, in the precipitation event including non-precipitation echo, the non-precipitation echo is completely removed by the echo classifier of the second classifier step that is built as Type-2 FCM based RBFNNs. Also, parameters of classification system are acquired for effective performance using PSO(Particle Swarm Optimization). The performance results of the proposed echo classifier are compared with CZ. In the sequel, the proposed model architectures which use event classifier as well as the echo classifier of Interval Type-2 FCM based RBFNN show the superiority of output performance when compared with the conventional echo classifier based on RBFNN.

Key Words : Radial basis function neural network, Precipitation echo(PRE), Non-precipitation echo(N-PRE), Event classifier, Echo classifier, Radar data, Interval Type-2 based FCM

1. 서 론

지구 온난화가 심각해짐에 따라 집중호우, 태풍과 같은 기상이변이 빈번히 일어나며, 이로 인한 산사태 및 홍수가 일어남에 따라 인명 및 재산피해가 심각하게 증가하고 있다. 이러한 이유로 빠른 시간에 반사도를 추출하여 호우정보를 관측할 수 있는 기상레이더가 중요시 되고 있다. 기상레이더 자료에는 강수정보를 나타내는 강수 에코(Precipitation echo) 뿐만 아니라, 관측 시 레이더의 위치, 대기의 상태, 주위 지형, 이상굴절 등에 따라 강수 이외의 에코가 관측되는데 이러한 에코를 비강수에코(Non-precipitation echos)라 한다. 비강수에코는 맑은 날에 나타나기도 하지만 강수 시에도 관측이 되기 때문에 비강수에코의 제거는 레이더에서 강수에코만을 판별하기

위해 반드시 선행 되어야 하는 과정이다.[1] 비강수에코의 종류로는 지형에코(Ground echo), 청천에코(Clear air echo), 이상굴절 에코(AP Echo : Anomalous Propagation echo), 파랑에코(Sea-clutter), 체크 에코(Cheff Echo) 등으로 종류가 다양하다. 본 연구에서는 비강수에코인 지형에코와 이상굴절 에코, 파랑 에코, 그리고 청천 에코를 제거하며, 강수 시에 강수에코와 비강수에코를 분류하여 비강수에코를 제거한다. 지형에코란 일반적으로 지형물 등에 의하여 레이더 빔의 일부 또는 전체가 반사되거나 산란되어 나타나는 에코를 말한다. 이러한 지형 에코는 레이더 빔의 전파효과, 과대굴절 등에 의해 더 강하게 나타나고 넓은 지역에 걸쳐 나타나게 된다. 청천에코는 맑은 대기 속에 대기 중의 곤충이나 작은 부유입자, 난류 등에 의해 레이더 파가 반사되어 발생하는 에코이다. 이상굴절 에코는 대기 굴절에 의해 레이더 파가 지면에 맞고 돌아오는 에코이며 파랑에코는 해상에 맞고 돌아오는 에코이다. 이러한 비강수에코들의 특징으로 인하여 레이더 자료에서 강수에코만을 나타내기 어렵기 때문에 비강수에코를 제거하기 위하여 각 에코들의 특성을 파악해야 하며 각 에코들을 분류하기 위한 입력인자가 중요하다. 기존 분류방법은 여러 사례들을 샘플링하여 학습데이터를 구축하고 강수에코와 비강수에코를 분류하는 방식이었다. 여기서 문제점은 데이터가 많기 때문에(1개의 UF데이터에서 사용되는 데이터 수는 344,520개) 대표

† Corresponding Author : Dept. of Electrical Engineering, The University of Suwon, Korea

E-mail : ohsk@suwon.ac.kr

* Dept. of Electrical Engineering, The University of Suwon, Korea

** Dept. of Electrical Engineering, Daelim University College, Korea
Received : March 05, 2015; Accepted : April 30, 2015

적인 특성을 갖는 에코들로 학습데이터를 구성하였지만, 강수사례와 비강수사례가 20사례(강수사례, 비강수사례 각각 10개씩 총 20개의 UF데이터, 10분에 1개의 UF데이터가 존재)뿐이기 때문에 학습데이터의 신뢰성이 떨어진다. 또한 비강수에코가 강수에코와 유사한 특성을 보이면 강수에코로 판단하여 성능을 떨어뜨리는 문제가 발생하였다. 이를 해결하기 위하여, 1차적으로 강수사례와 비강수사례를 분류하는 사례 분류를 먼저 수행하고, 이후에 사례 분류의 결과를 통하여 2차적으로 강수에코와 비강수 에코를 분류하는 에코 분류를 진행하도록 한다. 분류된 사례가 비강수사례일 경우 에코를 전부 제거하며, 강수사례일 경우 2차적으로 강수 에코와 비강수 에코를 분류하는 에코 분류 과정을 진행한다. 마지막으로는 제안하는 에코 분류기의 성능을 확인하기 위하여 레이더 필터링자료인 CZ와 비교하여 성능을 검증하였다. 본 논문은 2장에서 강수에코와 비강수 에코를 분류 하기위한 기상레이더 데이터의 구축 과정 및 각 입력변수의 특성분석 및 입력데이터의 구성을 나타내었고, 3장에서는 사례 및 에코 분류를 하기위한 제안된 모델의 구조에 대하여 설명한다. 4장에서는 진화 알고리즘을 통한 최적화된 파라미터를 탐색하는 알고리즘과 방법에 대하여 기술하였으며, 5장에서는 제안된 분류모델의 성능을 기존 분류 모델과의 비교를 통하여 각 에코종류마다 성능을 확인하였으며, 6장에서는 결론으로 기술하였다.

2. 기상레이더 구축 및 전 처리 과정

2.1 기상레이더 구조 및 에코 특성

본 절에서는, 기상레이더 자료인 UF(Universal Format)데이터의 구조를 분석하며, 레이더에 관측되는 강수에코, 지형에코, 청천에코의 특성 등을 파악한다. Radar(Radio Detecting And Ranging)는 대기 중의 전자기파 또는 음파 등의 파동매체를 이용하여 관측자로부터 멀리 떨어져 있는 물체의 존재 및 특성을 감지하고 분석하는 일체의 장비로써, 기상레이더를 이용하여 얻어낸 산물인 UF 기상레이더 자료는 레이더 설치 지역마다의 레이더에서 관측되는 자료들을 바이너리(binary)형태 자료로 저장된 데이터를 말한다.[2] 저장되는 값들은 필터링 후 반사도(CZ), 필터링 후 시선속도(VR), 필터링 후 스펙트럼 폭(SW), 필터링 전 반사도(DZ)가 저장된다. 저장되는 반사도는 dBZ(decibel Z)라는 단위를 사용하는데, 이는 반사도 인자의 대수(logarithm)로써 다음 식과 같다.[2]

$$dBZ = 10 \cdot \log_{10} \left(\frac{Z}{1mm^6/m^3} \right) \quad (1)$$

즉, $1mm^6/m^3$ 에 대한 비 값을 대수로 나타낸 것을 의미한다. 예를 들면, 단위부피 $1m^3$ 안에 직경 $1mm$ 인 물방울이 한 개 있으면 0[dBZ], 10개 있으면 10[dBZ], 100개 있으면 20[dBZ], 1000개 있으면 30[dBZ]가 되는 것이다. 또한 Z는 레이더 방정식을 이용하여 다음과 같이 식 (2)로 계산될 수 있다. 즉,

$$Z = \frac{2^{10} (\ln 2)}{\pi^3 c} \left[\frac{\lambda^2}{P_t h G^2 \theta_{3dB}^2} \right] \left[\frac{\gamma^2 \bar{P}_r}{|K|^2} \right] \quad (2)$$

여기서, \bar{P}_r 는 평균 반사전력 (Watt), P_t 는 최대 송신 출력 (Watt), G 는 안테나 이득 (무 차원), λ 는 레이더 파장 (m), θ_{3dB}

는 안테나 빔 출력 반치 폭 (radian), h 는 펄스 지속시간 (펄스 폭)(sec), c 는 전자기파의 전파속도, 상수(빛의 속도)는 $3 \times 10^8 msec^{-1}$, γ 는 레이더와 목표물간의 거리 (m), Z 는 레이더 반사도 인자, K 는 복소 굴절율을 의미하며 일반적으로 $|K|^2$ 값은 물일 경우 0.93, 얼음일 경우 0.2로 취해진다. 그림 1은 레이더를 통하여 얻어진 UF 데이터의 구조를 간략화 하여 나타낸 그림이다.




그림 1 UF 데이터의 구조
Fig. 1 Structure of UF data

UF 데이터는 4개의 소속변수인 DZ, CZ, VR, SW를 저장하고 있으며, DZ를 제외한 3가지 소속변수는 각각 필터링을 거쳐 저장되고 있다. 이중 필터링이 되지 않은 반사도 값인 DZ는 레이더 사이트 경우마다 차이는 있지만, 실험에 사용한 오성산 레이더 사이트의 경우 레이더의 반경을 나타내는 957개의 Bin과 방위각 $0^\circ \sim 360^\circ$ 범위의 Ray로 344520개의 각 좌표지점마다의 반사도 값을 저장하며, 이 반사도 값(344520개의 좌표에서 얻어진 반사도 값)들은 각각 1번째 Sweep에서 15번째 Sweep(총 15개)에 저장이 된다.

레이더를 통하여 얻어진 반사도 값을 통하여 얻어진 UF레이더의 데이터를 이용하여 에코 맵을 구성하면, 여러 형태의 관측된 에코들을 확인 할 수 있으며, 강수에코와 비강수에코는 각 에코들의 성격을 통하여 여러 종류로 나뉘지만, 강수에코를 3개의 대분류로 나누면, 다시 층상에코(Stratiform echo), 대류성 에코(Convective echo), 태풍 에코(Typhoon echo)등으로 나눌 수 있으며, 비강수에코는 지형에코, 이상굴절 에코, 파랑에코, 청천에코로 나눌 수 있다. 지형에코는 산이나 건물 등의 지표면 고정 물체에 의한 에코로써 대류성 에코와 그 모양이 유사하지만, 움직이지 않는 특징이 있으며, 이상전파 에코는 대기 중의 전파 굴절률의 변화가 심한 곳이 존재함에 따라 레이더 전파가 굴절을 통하여 강수입자가 아닌 다른 지형이나 물체에 반사되어 나타나며, 그 모양은 반점의 집합, 넓고 밝은 선, 층상에코와 유사한 모양으로 나타난다. 파랑에코는 전파가 해면에 반사되어 나타나는 에코로써, 파도가 높을 때나 파의 진행 전면이 급경사 이면에 전파가 수면과의 입사각이 적어질 때 잘 나타난다. 청천에코는 강수가 없는 날 대기 중의 새나 벌레, 혹은 입자가 큰 먼지나 채프에 의해 발생하는 에코를 나타내며, 대기중에서 이동을 하기 때문에 레이더의 시선속도가 존재하는 특징을 가지고 있다.[3]

2.2 UF 데이터에서의 입력변수 생성

하지만 UF 데이터에는 몇 가지 문제점이 있다. 첫 번째는 CZ,

VR, SW, DZ로만 강수예코와 비강수예코의 구분을 할 수가 없다. 강수 사례와 비강수 사례를 조사해본 결과 CZ, DZ의 범위는 -20 ~ 80[dBZ]사이로 나타나며, 강수 사례와 비강수 사례일 때의 CZ, DZ의 범위가 유사하여 강수 사례와 비강수 사례가 분류되는 특징을 파악할 수 없었다. 또한 VR, SW들도 강수 사례와 비강수 사례일 때의 특징이 유사하여 강수예코와 비강수예코 특징을 파악할 수 없었다.

두 번째로는 뉴로-퍼지 알고리즘은 강수예코와 지형예코에 대한 소속변수가 통계적으로 나타나는 특성을 이용한다. VR, SW는 필터링을 거친 후의 자료이기 때문에 지형예코에 대한 정보는 거의 없다. 만일 VR, SW가 소속변수로서의 역할을 제대로 하려면 지형예코에 대한 정보가 반드시 존재해야 한다. 따라서 VR과 SW는 소속변수로 채택될 수가 없다.

마지막으로, CZ가 필터링 후의 반사도 값이라고 하지만 강수 사례일 때 여전히 지형예코가 존재한다. 이 뿐만이 아니라 비강수 사례에서 비강수예코 또한 존재하여 필터링을 거친 후의 데이터라고는 하지만 정보의 신뢰성이 낮다. 이러한 문제점 때문에 기상레이더 데이터의 DZ(필터링 전 dBZ 값)를 이용하여 반사도의 표준편차(SDZ: Standard Deviation of reflectivity), 반사도의 연직기울기(VGZ: Vertical Gradient of reflectivity), 반사도 변곡점 수의 백분율(SPN: Spatial variability of the reflectivity change)을 구하였으며, 그 특성들을 분석하였다.

SDZ는 주어진 고도각 상으로 반사도의 산포도를 계산하는 입력변수로써 Sweep (0.5°)의 (Ray, Bin)의 좌표에 생성되는 DZ 값으로 계산하며, 다음 식 (3)과 같이 나타낸다.

$$SDZ = \left[\frac{1}{n} \sum_{j=1}^n (dBZ_{i,j} - \overline{dBZ})^2 \right]^{1/2} [dB] \quad (3)$$

여기서, i는 레이더의 Ray, j는 레이더의 Bin을 의미하며, n=10으로 한 개의 (Ray, Bin)의 좌표를 중심으로 각 이웃하는 좌표를 대상으로 표준편차를 구하였다.

또 다른 입력 변수 VGZ는 두 개의 Sweep의 반사도 값의 차이를 Sweep 간의 각도 차로 나눈 것으로 식 (4)와 같이 계산한다.


$$VGZ = - \frac{dBZ_{\theta_{(i,j,k+1)}} - dBZ_{\theta_{(i,j,k)}}}{\theta_{(i,j,k+1)} - \theta_{(i,j,k)}} [dBZ/deg] \quad (4)$$

여기서 θ 는 각 Sweep의 각을 의미하고, i는 Ray, j는 Bin, k는 Sweep을 의미한다. 식 (4)에서 나타낸 바와 같이 주어진 (i,j,k)에서의 반사도 자료를 그 보다 높은 고도각에 해당하는 (i,j,k+1)에서의 반사도 자료와의 차이를 구하게 되는데 본 논문에서 두 Sweep을 0.5°와 1.5°로 지정하여 두 Sweep간의 차이를 1°로 한다. Sweep 0.5°와 1.5°를 사용한 이유는 Sweep 차가 1°를 초과하게 되면 비강수예코가 사라지는 장점이 있지만 강수예코들도 유실되는 단점이 있다. 1°미만 일 경우 반사도의 연직 기울기가 과도하게 높아지며 비강수예코 또한 상당수가 존재하기 때문에 강수예코와 비강수예코의 상관성이 적절하게 잘 나타나는 1°차이로 VGZ를 계산하였다. 또한 DZ_FR(FR : Frequency), SDZ_FR, VGZ_FR을 추가하여 레이다 데이터의 특성을 분석하였다. 사례분류를 위한 학습데이터는


강수 사례 1524개의 UF데이터와 비강수 사례 1480개의 UF데이터 (기간 명시는 5장 실험 및 결과의 표 5로 참조)로 입력변수 DZ, SDZ, VGZ, 각각의 빈도수 (DZ_FR, SDZ_FR, VGZ_FR)를 사용하여 구성하였다. 강수예코와 비강수예코 분류를 위한 학습데이터는 많은 사례 중에서 대류형, 층운형, 발달하는 대류셀, 대류셀+층운형, 태풍에 의한 대류셀의 강수사례들 중 하나씩을 샘플링 하여 강수 학습데이터를 구성하였으며, 비강수 학습데이터로는 맑은 날의 지형예코와 청천 예코들을 샘플링 하여 구성하였다[4].

2.3 입력변수를 이용한 특성분석


본 절에서는 이전 절에서 살펴본 입력변수들을 이용하여 특성분석을 파악한다. 사례 분류에서 사용할 입력변수로는 오성산 레이더의 강수사례와 비강수 사례에서의 각 입력변수의 대한 도수 분포도를 통하여 특성분석을 한다. 먼저 DZ의 빈도수 분포는 UF데이터 마다 정보 값이 달라 빈도수의 차이는 있지만 30~60[dBZ]의 범위내에서 두 사례간의 구분점이 나타나며, 강수 사례 일 경우 강수량의 따라



(a) 강수사례와 비강수사례의 반사도 그래프



(b) 강수사례와 비강수사례의 표준편차 그래프



(c) 강수예코와 비 강수예코의 연직기울기 그래프

그림 2 강수예코와 비강수예코의 빈도수 그래프

Fig. 2 Frequency graph of PRE and NPRE

빈도수가 다른 점을 가지고 있지만, 비강수 사례의 경우 대부분 비슷한 빈도수를 가지는 것이 특징이다. DZ 빈도그래프에서 30~40[dBZ]의 범위에 두 사례간의 차이점을 확인 할 수 있으며, 그림 2(a)에 나타내었다. SDZ의 빈도수는 DZ와 동일한 범위인 30~60[dBZ]범위의 값으로 표준 편차로 구하였고, DZ값을 통한 표준 편차를 구하기 때문에 시시각각 변하는 특징을 가지고 있지만, 표준편차의 빈도수의 밀집정도는 0.5~35[dBZ]내에서 확인한 차이를 드러낸다. 입력데이터의 DZ와 SDZ 범위는 0.5~60[dBZ]의 범위로 지정하였으며, SDZ의 빈도 그래프는 그림 2(b)에 나타내었다. 강수사례의 경우 표준 편차값의 범위가 비강수 사례일 경우 보다 좁게 분포하고 있으며, 비강수 사례에서 넓게 분포함을 보인다.

반사도의 연직경도를 살펴보면, 강수사례와 비강수 사례의 연직경도 분포는 강수사례의 경우 0.5~45.5(dBZ/deg) 사이에 분포하고 있으며, 비강수사례의 경우 빈도수의 개수가 미비하다가 20~60[dBZ/deg] 구간에서 두드러지게 나타나는 형태를 보인다. 이는 입력 변수 VGZ의 경우에서 가장 강수와 비강수 사례의 구분점이 되는 기준이기도 하다. 강수예코와 비강수 예코의 VGZ의 빈도수 그래프를 그림 2(c)에 나타내었다.

2.4 입력변수를 통한 데이터구성

학습데이터와 테스트 데이터의 구성은 DZ, CZ, SW, VR 중에서 DZ를 이용하여 구성 하였다. 입력변수들의 이전장의 특성 분석을 기반으로 사례 분류기 및 패턴 분류기의 각각 데이터를 구축한다. 사례 분류기 데이터의 입력변수(DZ, DZ_FR, SDZ, SDZ_FR, VGZ, VGZ_FR)로 구성하여 DZ 경우 30~60[dBZ]범위의 0.5 단위로 구성하며 SDZ의 경우 0.5~30[dBZ]범위까지 0.5 단위의 간격이며 VGZ는 0.5~25[dBZ/deg]까지 0.5단위로 구성 한다. 사례분류의 경우 SPN은 데이터는 사례 분류시에 두드러지는 특성분석을 보이지 않음에 따라 제외하게 된다. 예코 분류기의 입력 변수로는 1개의 고도각에 대한 방위각과 반경의 총 갯수인 344520개의 반사도 값과 반사도로부터 추가적으로 얻어지는 반사도값의 빈도수를 포함하여 다섯 개의 입력변수(DZ, SDZ, VGZ, SPN, DZ_FR)로 입력 데이터로 구성한다. 그림 3에서 보는 바와 같이 (a)는 사례 분류 데이터로 구성하게 되는데, 10분당 하나씩 얻어 내는 UF 레이다 데이터를 DZ와 DZ_FR로 짝을 이루어 하나의 분류기의 데이터로 사용하며, 마찬가지로 SDZ 및 SDZ_FR을 2번째 사례 분류 데이터 구성하고, 마지막으로 VGZ 및 VGZ_FR을 데이터로 사용하여 분류기의 수가 3개인 RBFNN(Radial basis Function Neural Network : 방사형 기저함수 신경회로망)이 병렬적인 구조로 구성이 된다. 이에 분류된 결과는 1 혹은 0의 패턴을 가지며, 1일 경우 강수 사례로 판단하며 0일 경우는 비강수 사례로 분류를 하게 된다. 비강수 사례로 분류될 경우 예코 분류과정은 생략이 되어 비강수 예코가 제거되는 결과를 얻어 내며, 강수사례로 분류 시에만 예코 분류를 진행하게 된다. 예코 분류의 데이터는 UF 레이다 하나의 한 Sweep에 해당하는 오성산 레이다 사이트 기준으로 344520개의 좌표 지점의 반사도 값을 가지게 되며 DZ, SDZ, VGZ, SPN 그리고 DZ_FR로 구성되어 예코 분류를 진행하게 된다.

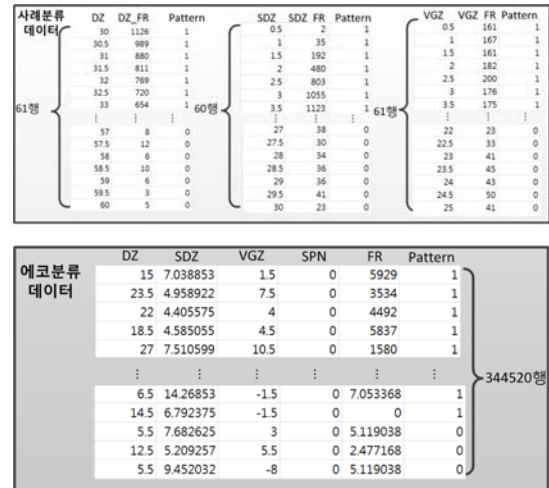


그림 3 사례 및 예코 분류기 데이터 구성
Fig. 3 Composition data of event and echo classification

3. RBFNN기반 사례 및 예코 분류기의 설계 및 구조

3장에서 강수사례와 비 강수 사례의 분류하기 위한 퍼지 뉴럴 네트워크 기반 사례 분류기의 구조 및 예코 패턴 분류기의 구조를 설명한다. 제안된 뉴로퍼지 네트워크의 구조는 비선형적인 데이터들 간의 상호간의 연관성을 찾아 결합된 입력공간의 분할로부터 각 입력변수들의 퍼지 규칙의 적합도를 구하며, 입력신호와 연결 가중치의 곱으로 표현하여 각 규칙을 생성하게 된다. 사례 분류와 예코 분류에 사용 되는 RBFNN의 구조에서 Interval Type-2 FCM에 의하여 적합도를 구하는 과정과, FCM에 의하여 데이터가 클러스터링 되는 과정에 대하여 설명하고 후반부에 선택된 후반부 파라미터 구조와 파라미터 계수를 구하는 최소 자승법에 구해진 값들과의 결합을 설명하며, 사례 분류기와 예코 분류기의 구조에 대한 차이점을 설명 하도록 한다.

3.1 사례 분류를 위한 RBFNN기반 패턴 분류기의 설계

본 절에서는 사례 및 예코 분류를 하기위한 뉴로 퍼지 네트워크에 대하여 설명한다. 제안된 RBFNN은 식 (5)와 같이 If-then의 퍼지 규칙을 사용하였다.

$$R: \text{If } x_1, x_2 \dots \text{ and } x_n \text{ are } \bar{u}_i, \text{ then } y = f_i(x) \quad (5)$$

여기서 x 는 입력 데이터, \bar{u}_i 는 FCM 클러스터링에 의한 $i=(1, \dots, c)$ 번째 그룹의 소속 함수(membership function), $f_{ji}(x)$ 는 $j=(1, \dots, s)$ 번째 출력에 대한 i 번째 퍼지 규칙의 다항식이다.[5]

RBFNN은 입력층, 은닉층, 출력층으로 구성된 기존의 신경회로망의 기본 틀을 두고 있지만 크게 기능적 구조로 그림 4와 같으며 입력 데이터를 FCM 클러스터링을 통해 데이터의 중심점과의 거리로 소속행렬을 구하는 조건부, 입력 데이터를 다항식으로 표현하는 결론부, 마지막으로 조건부의 소속행렬과 결론부에서 구한 다항식을 결합하여 최소자승법(LSE : Least Square Estimation)으로 다

항식의 계수를 구하여 최종 출력을 하는 추론부로 나타낸다[6~8].

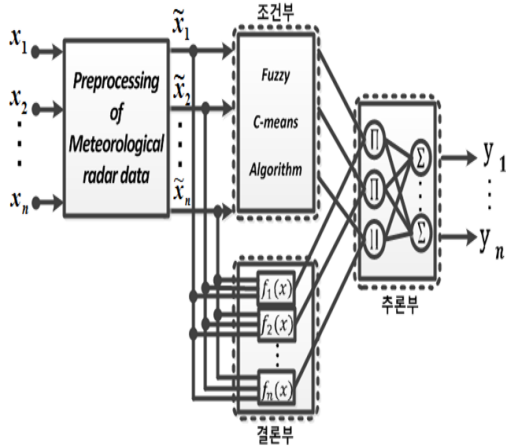


그림 4 RBFNN의 구조
Fig. 4 The structure of RBFNN

식 (5)에서 나타낸 “then” 이전의 조건부는 클러스터에 대한 각 데이터의 거리를 기준으로 소속정도를 측정하여 데이터들의 특성을 분류하는 FCM 클러스터링을 사용하였다. 은닉층 활성화함수의 중심점 및 분포상수를 정의하기 위해 쓰였으며 각 데이터의 소속정도는 각 규칙에 대한 적합도로서 사용된다. 기상레이더 자료를 입력 데이터로 사용하였으며 은닉층의 노드 수만큼 클러스터링하여 입력 공간을 분할하고, 클러스터링으로 나온 중심점을 활성화함수의 중심점으로 사용하였으며 활성화함수의 분포상수는 주어진 입력 데이터와 클러스터 중심점간의 표준편차를 구해 적용하였다. 다음은 FCM 클러스터링의 절차이다.

[step 1] 클러스터의 개수를 결정하고, 소속행렬 $U^{(r)}$ 을 초기화한다.

$$U^{(r)} = \left\{ u_{ik} \in [0, 1], \sum_{i=1}^c u_{ik} = 1 \forall k, 0 < \sum_{k=1}^n u_{ik} < n \forall i \right\} \quad (6)$$

[step 2] $U^{(r)}$ 값을 기반으로 각각의 클러스터에 대한 중심값과 소속함수의 값을 구한다.

$$v_i^{(r)} = \{v_{i1}^{(r)}, \dots, v_{ic}^{(r)}\}, v_{ij}^{(r)} = \left(\sum_{k=1}^n (u_{ik})^m \cdot x \right) / \left(\sum_{k=1}^n (u_{ik})^m \right) \quad (7)$$

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{\|x_k - v_i^{(r)}\|}{\|x_k - v_j^{(r)}\|} \right)^{2/(m-1)}} \quad (8)$$

[step 3] 각각의 클러스터 중심과 데이터와의 거리를 계산하여 새로운 소속행렬을 생성한다.

$$d_{ik} = d(x_k - v_i^{(r)}) = \left[\sum_{j=1}^l (x_{kj} - v_{ij}^{(r)})^2 \right]^{1/2} \quad (9)$$

[step 4] 오차가 허용범위 안에 도달하면 종료하고, 그렇지 않으면 [step 2]로 돌아간다.

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{\|x_k - v_i^{(r)}\|}{\|x_k - v_j^{(r)}\|} \right)^{2/(m-1)}} \quad (10)$$

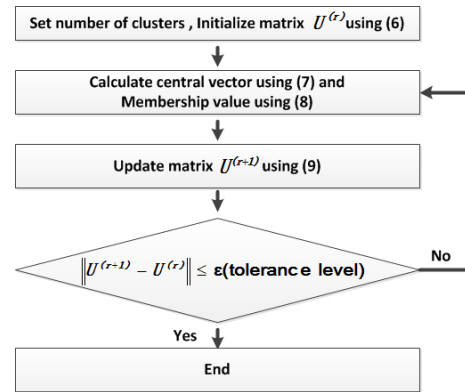


그림 5 FCM clustering의 절차
Fig. 5 Procedure of FCM clustering

FCM 알고리즘을 가우시안 활성화함수 대신 사용하여 데이터의 특성을 보다 잘 반영할 수 있다. FCM의 클러스터의 수는 은닉층 노드의 수를 대신하고 소속행렬의 값은 가우시안 활성화함수에 의한 적합도 값과 같다. 그리고 FCM의 퍼지화 계수는 가우시안 함수의 분포상수를 나타낸다.[9]

“then” 이후 결론부는 비선형 특성의 판정 경계를 위해 네트워크의 연결가중치를 다항식으로 구성하였으며, 퍼지 규칙의 로컬 모델로 동작된다. 후반부 다항식 구조는 식 (11)의 간략식, 식 (12)의 선형식 및 식 (13)의 변형된 2차식으로 나타내며 다항식 연결가중치의 파라미터 계수(a)를 동정하기 위해 식 (14)의 최소자승법을 사용하여 계수를 추정하였다.[10]

간략식 (Constant type)
 $f_j(x_1, x_2, \dots, x_n) = a_{j0} \quad (11)$

선형식 (Linear type)
 $f_j(x_1, \dots, x_n) = a_{j0} + a_{j1}x_1 + \dots + a_{jn}x_n \quad (12)$

변형된 2차식 (Modified quadratic type)
 $f_j(x_1, \dots, x_n) = a_{j0} + \sum_{i=1}^n a_{ji}x_i + a_{j(2n+1)}x_1x_2 + \dots + a_{j(n(n+3)/2)}x_{n-1}x_n \quad (13)$

LSE
 $a_j = (X_j^T X_j)^{-1} X_j^T Y \quad (14)$

추론부에서는 조건부와 결론부를 곱한 값들의 합이 퍼지 규칙의 추론 결과로서 네트워크의 최종출력이 구해진다. 모델의 최종 출력 식은 식 (15)와 같이 표현한다. 여기서, $i(1, \dots, c)$ 는 은닉층 노드 수를 나타낸다. 최종적으로 RBFNN의 성능평가를 위하여

패턴분류율을 사용하였다.

$$y = \frac{\sum_{i=1}^c R_i(\mathbf{x}) f_i(\mathbf{x})}{\sum_{k=1}^c R_k(\mathbf{x})} = \sum_{i=1}^c \hat{R}_i(\mathbf{x}) f_i(\mathbf{x}) \quad (15)$$

사례분류를 위해 제안된 RBFNN의 구조는 그림 6과 같다. 제안된 RBFNN은 기존 RBFNN과 달리 학습데이터가 여러 개인 것이 특징이다. 제안된 RBFNN과 같은 구조를 선택한 이유는 기존 학습데이터 수가 너무 많아 다양한 사례를 학습시킬 수가 없었다. 따라서 좀 더 많은 사례를 학습시킬 수 있게 학습데이터를 축소하여 각 특징에 맞게 분류기를 구축하였다. 각 분류기마다 퍼지화계수, 퍼지 rule 수, 다항식 차수가 다르기 때문에 데이터마다 특성에 맞는 파라미터를 구할 수 있으며, 각 분류기의 성능을 반영하여 최종 출력을 얻기 때문에 잘못 분류하는 오류를 줄여준다는 장점이 있다.

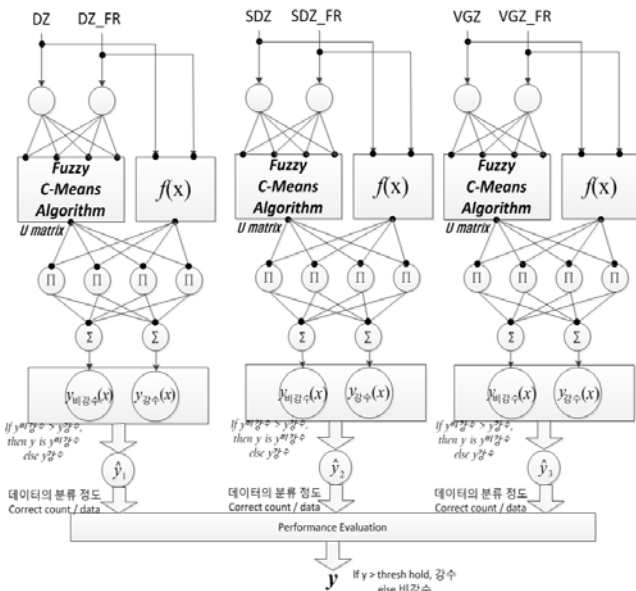


그림 6 사례분류를 위해 제안된 RBFNN의 구조

Fig. 6 The structure of proposed RBFNN for event classification

3.2 예코분류를 위한 방사형 기저함수 신경회로망의 구조

본 연구에서는 전체 입력 공간을 분산(퍼짐) 형태로 분할하는 Interval Type-2 FCM 기반 RBFNN을 이용하여 강수사례일 때 강수 예코와 비강수 예코를 세분화하여 분류한다. 각 분할된 퍼지 공간은 퍼지 규칙을 형성하게 되며, 퍼지 규칙 수는 클러스터의 수가 된다. 클러스터들의 부피가 비슷하거나 같을 경우에는 퍼지화 계수 m 값에 따라 좋은 성능을 기대할 수 있지만, 아래 그림과 같이 클러스터들의 부피가 다를 경우에는 하나의 m 으로 좋은 성능을 보일 수 없다. 그림 7(a)는 부피가 다른 2개의 클러스터에서 작은 m 값을 설정했을 때를 보여준다. C_2 클

러스터에 퍼지 멤버십 값을 갖는 구간이 걸쳐 있기 때문에 상대적으로 C_1 클러스터에 패턴들이 많이 할당이 된다. 그림 7(b)와 같이 큰 m 값을 설정했을 때에는 비슷한 멤버십 값이 할당되기 때문에 좋은 성능을 보일 것 같지만, C_1 클러스터의 센터 값이 C_2 클러스터로 이동하는 경향을 보인다.




그림 7 퍼지화 계수 값에 따른 부피가 다른 2개 클러스터에서의 퍼지 영역 : (a) 작은 m 값, (b) 큰 m 값

Fig. 7 Fuzzy area in the two clusters with different volume size according to the values of fuzzification coefficient : (a) Small value, (b) Big value

그래서 다른 부피를 가진 클러스터의 경우에는 다음 그림과 같이 m 을 설정하는 것이 가장 이상적이다.




그림 8 부피가 다른 2개 클러스터에서의 적합한 퍼지 영역
Fig. 8 Suitable fuzzy area in the two clusters with different volume size

Type-1 FCM의 소속행렬은 패턴인식에서 패턴의 불확실성을 나타내는 데 사용되어져 왔다. 하지만 Type-1 FCM으로 좋은 결과를 나타낼 수 없는 경우에는 Interval Type-2 기반 fuzzy set을 사용함으로써 더 나은 결과를 나타낼 수 있다. Interval Type-2 FCM 기반 RBFNN으로 Type-1 FCM보다 패턴의 불확실성을 더 다양하게 제어할 수 있기 때문이다. 본 논문에서는 m 에 따른 Upper and lower membership function을 구한다. m 은 퍼지화 계수로 클러스터링의 퍼지화 정도를 결정한다. m 에 따른 Upper and lower membership function은 다음과 같이 만들 수 있다.

$$u_{ik} = \begin{cases} \frac{1}{\sum_{k=1}^C \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{m_1-1}}}, & \text{if } \frac{1}{\sum_{k=1}^C \left(\frac{d_{ik}}{d_{jk}}\right)} < \frac{1}{C} \\ \frac{1}{\sum_{k=1}^C \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{m_2-1}}}, & \text{otherwise} \end{cases} \quad (16)$$

$$\underline{u}_{ik} = \begin{cases} \frac{1}{\sum_{k=1}^C \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{m_1-1}}}, & \text{if } \frac{1}{\sum_{k=1}^C \left(\frac{d_{ik}}{d_{jk}}\right)} \geq \frac{1}{C} \\ \frac{1}{\sum_{k=1}^C \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{m_2-1}}}, & \text{otherwise} \end{cases}$$

여기서 m_1 은 upper membership function의 퍼지화 계수이고, m_2 는 lower membership function의 퍼지화 계수, C는 클러스터 수이다.

입력패턴들이 각 클러스터에 대한 Upper and lower membership을 구하고 나면 각 클러스터들의 center 값을 갱신해야한다. center 갱신을 위해 Interval Type-2 FCM 기반 RBFNN의 소속행렬을 Type-1 FCM의 소속행렬로 바꿔주는 Type reduction이 필요하다. Type reduction을 수행하는 알고리즘은 KM(Karnik and Mendel) 알고리즘을 사용한다. KM 알고리즘은 가장 작은 왼쪽 값과 가장 큰 오른쪽 값을 구한다. 이 두 개의 값의 평균으로 Interval Type-2 FCM 기반 RBFNN의 소속행렬을 만들 수 있다.

[Step 1] 클러스터의 수 c를 정하고 퍼지화 계수 m를 선택한다. 그리고 소속행렬 U를 초기화 한다.

[Step 2] 식(7)을 이용하여 클러스터 중심 v를 계산하며, 식 (8)을 이용하여 소속행렬 U를 계산한다.

[Step 3] 종료 조건을 만족하면 [Step 5]로 이동한다. 그렇지 않으면 [Step 2]를 반복한다.

[Step 4] 새로운 소속행렬 U를 계산하고 [Step 5]로 이동한다.

[Step 5] 소속행렬 U에서 최대의 소속정도를 갖는 클러스터에 속한 데이터의 표준편차 σ_i 를 구한다.

[Step 6] 불확실성 계수 ρ_i 를 이용하여 $(1+\rho_i)\sigma_i$ 에 의해 불확실성을 조절한다.

$$\overline{m}_i = m + (1+\rho_i)\sigma_i \quad \underline{m}_i = m - (1+\rho_i)\sigma_i \quad (17)$$

여기서 \overline{m}_i 는 i번째 클러스터에 대한 상위 퍼지화 계수이며, \underline{m}_i 는 i번째 클러스터에 대한 하위 퍼지화 계수이다.

[Step 7] 상위 적합도와 하위 적합도의 평균을 이용하여 v_r 과 v_l 을 계산한다.

$$v_{ij}^r = \frac{\sum_{k=1}^n \frac{2}{u_{ik}^{m-1}} \times x_{kj}}{\sum_{k=1}^n \frac{2}{u_{ik}^{m-1}}} \quad (18)$$

[Step 8] 다음 식을 만족하는 스위칭 포인트를 찾고 스위칭 포인트를 기준으로 적합도 위치를 서로 바꿔준다.

$$v_r^p \leq \overline{v}_r \leq v_r^{p+1}, \quad \text{여기서 } p(1 \leq p < h-1) \quad (19)$$

$x_{kj} - \overline{v}_{ij}^r < 0$ 이면 lower 적합도 선택, $x_{kj} - \overline{v}_{ij}^r > 0$ 이면 Upper 적합도 선택

[Step 9] 선택된 적합도로 식 (18)을 이용하여 \overline{v}_r 을 계산 한다

[Step 10] ($\overline{v}^r = \overline{v}^l$)이 같으면 최종출력이 되고 알고리즘을 종료한다. 아니면 [Step 8]으로 이동한다.

(\overline{v}^l 도 [Step 7]부터 같은 방법으로 수행한다)

[Step 11] $v = (\overline{v}^r + \overline{v}^l)/2$ 로 클러스터 중심을 구하고, 클러스터 중심과 데이터 사이의 거리로 다시 소속행렬 U를 구한다.

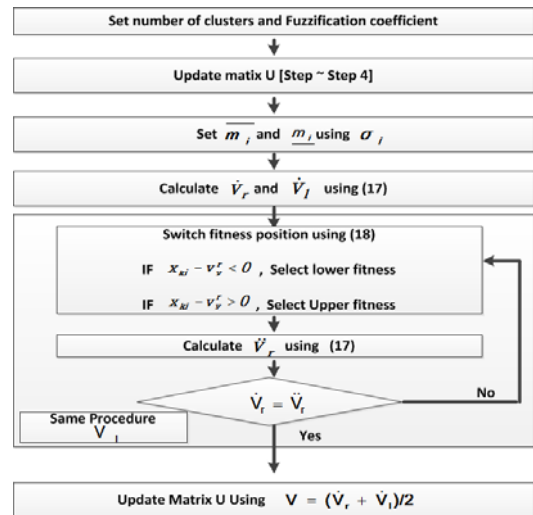


그림 9 Interval Type-2 FCM의 절차
Fig. 9 Procedure of Interval Type-2 FCM

3.3 RBFNN 기반 사례 및 예코 분류 시스템 설계

본 절에서는 앞서 설명한 사례 분류를 거친 사례를 토대로 예코 분류를 수행하는 통합된 사례 및 예코 분류기의 시스템 과정과 구조에 대하여 설명한다. 제안하는 사례 분류기의 구조는 3.1 절에서 설명한 바와 같이 강수사례와 비 강수사례를 분류하는 사례분류기는 각각 병렬적인 구조이다. DZ, DZ_FR처럼 짝을 이뤄 하나의 분류기의 입력변수가 되며, SDZ, SDZ_FR은 두 번째 분류모델의 입력변수가 되며, VGZ, 와 VGZ_FR은 세 번째 분류모델의 입력변수가 된다. 다시 말해, 각각의 독립적인 입력변수(총 3개의 병렬적인 분류모델)를 통하여 클러스터링의 과정을 거쳐 적합도와 정규화를 진행한다. 또한 후반부 파라미터 구조와 후반

부 파라미터의 계수는 최소 자승법을 통하여 파라미터 계수를 추론한다. 다만 두 분류기의 차이점으로는 사례 분류에서 병렬적인 구조로 각 입력 데이터(각 입력변수와 입력변수의 빈도수의 조합으로 된 입력변수)구성의 패턴 분류를 통한 독립적인 분류를 진행함으로써, 하나의 입력변수의 결과 값에 치중되지 않도록 고려하였다. 예코 분류에서는 Interval Type-2 FCM 기반 RBFNN의 과정으로 노이즈에 강인한 특징을 이용하여 복잡한 강수에코와 비강수 에코의 혼합된 상태의 분류를 용이하도록 한다. 사례 분류기와 달리 하나의 분류기에 DZ, SDZ, VGZ, SPN, DZ_FR의 다섯가지 입력변수를 입력변수간의 상호적인 관계를 고려하여 최종적인 예코 결과를 얻어내기 위함이다. 또한 사례 분류에서 분류결과가 강수일 경우 강수 사례에 섞여 있는 비강수 에코를 제거하기 위한 예코 분류 과정을 수행하지만, 만약 비강수 사례일 경우, 추가적인 예코분류 과정을 거치지 않고 모든 반사도 값이 기상학적으로 의미 없는 비강수 에코이기 때문에 반사도 값을 모두 제거하여, 보다 더 정확하고 신뢰있는 예코분류 과정을 유도한다. 아래그림은 통합적인 사례 및 예코 분류 시스템의 과정을 간략적으로 나타내며, 비강수 사례일 경우 에코패턴 분류 과정을 생략하는 과정을 볼 수 있다.

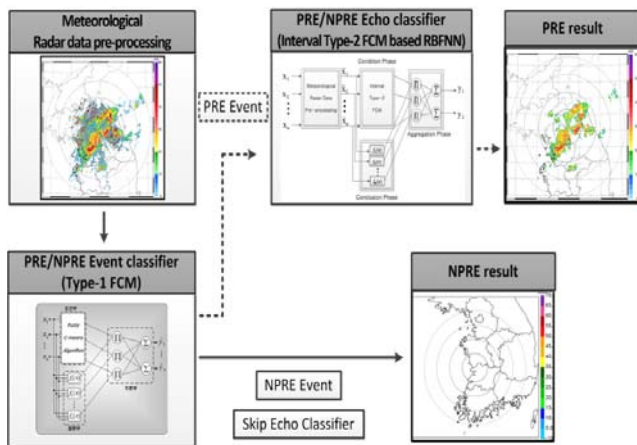


그림 10 RBFNN 기반 사례 및 에코 패턴 분류 시스템 과정
 Fig. 10 Classification procedures of both event and echo classifiers based on RBFNN.

4. PSO를 이용한 RBFNN 기반 사례 분류기 설계

4.1 PSO(Particle Swarm Optimization)

PSO는 Kennedy 와 Eberhart가 도입하여 진화연산 사회 심리학 특징의 결합으로, 새나 물고기 등의 먹이를 찾아가는 과정의 행동양식을 바탕으로 이루어진다. PSO는 엘리트 전략에 의해 유지되는 하나의 유용한 정보만 제공되는 것이 아니라 개체군 전체가 그들의 속도와 경험을 바탕으로 유용한 위치정보를 공유하고 조절하며, 주어진 문제의 해결을 위해 목적함수(성능지수)를 이용한다. 최적해의 탐색이 초기 값에 의존하지 않아 탐색공간의 어느 곳에서 출발하든지 해에 대한 방향을 제시 하여 최적해의 수렴을 보여주며, 미분가능하지 않은 함수들을 쉽게 다룰 수 있다.

또한 전역탐색과 지역탐색 사이에서의 관계를 유연하게 조절할 수 있어 빠른 수렴과 탐색능력을 강화할 수 있는 특징을 가지고 이러한 특징은 고차원으로 갈수록 두드러지는 특징이 있다. PSO 알고리즘의 수행단계는 다음과 같다.

[Step 1] : Initialization

n개의 Particle을 탐색 공간내에 임의적으로 생성하며, 이들을 pbest로 설정하며, 이들이 초기 Swarm을 구성한다.
 pbest : 각 Particle의 이동경로중 가장 좋은 적합도를 갖는 점의 Particle의 위치(값)이다. 초기 particle중 최적의 적합도값을 gbest로 선정.

[Step 2] : Velocity updating

식 (20)로 Particle velocity를 계산한다.

$$V_{jk}(t+1) = w(t) \cdot v_{jk}(t) + c_1 \cdot \gamma_1 (pbest_{jk}(t) - x_{jk}(t)) + c_2 \cdot \gamma_2 (gbest_k(t) - x_{jk}(t)) \quad (20)$$

[Step 3] : Position updating

식 (21)으로 Particle의 위치 정보를 조절한다.

$$x_{jk}(t) = v_{jk}(t) + x_{jk}(t-1) \quad (21)$$

[Step 4] : Particle & global best updating

새로운 Particle들은 목적함수에 의해 평가되며, 각 Particle의 적합도는 이전 pbest의 적합도와 비교되며 pbest를 재설정한다. 최적의 위치정보를 가지는 Particle을 gbest로 재설정한다.

[Step 5] : Stopping criteria

종료 조건을 만족하면 탐색과정을 종료하고, 그렇지 않으면 [Step 2]부터 반복한다.

[Step 6] : Optimal Parameter

최종적으로 생성된 gbest는 최적의 위치정보를 가진다.

4.2 PSO를 이용한 RBFNN 기반 사례 분류기의 설계

본 절에서는 강수사례와 비강수 사례의 분류과정 수행에 있어서 보다 우수한 성능을 가지기 위해 분류과정을 얻어내기 위하여 파라미터 최적화를 수행한다. 본 논문에서는 입자군집 알고리즘을 사용하여 사례 분류기의 Rule수, 퍼지화계수, 그리고 다항식의 차수를 고려하며, 수행단계는 다음과 같다.

[Step 1] 3개의 RBFNN은 Rule수, 퍼지화계수, 그리고 다항식의 차수의 범위는 다음과 같다.

표 1 PSO 파라미터의 탐색 범위

Table 1 Search ranges of PSO parameters

Parameters	Number of rules	Fuzzification coefficient	Type
Range	[2 ~ 8]	[1.1~3.0]	0: constant 1: Linear 2: Modified quadratic

[Step 2] 뉴로-퍼지 알고리즘을 기반한 사례분류기를 이용하여 학습, 검증 및 테스트 데이터의 인식성능을 평가하며 인식성능 및 목적 함수는 다음 식을 이용하여 산출 한다.

$$Objective\ function = \frac{(TR + VA)}{2} \quad (22)$$

$$PCR[\%] = 100 - \left(\frac{Error\ count}{No.\ Total\ count} \times 100 \right) \quad (23)$$

[Step 3] Step1의 범위 내의 파라미터 값을 반복하여 최적화된 파라미터 값을 탐색하며, [Step2]를 통해 인식성능을 반복적으로 확인한다.

5. 실험 및 결과 고찰

5.1 실험의 전체 개요 및 파라미터 설정

본 논문에서는 최종적인 에코분류를 하기위하여 사례 분류와 에코 분류의 두가지 분류를 진행한다. 반사도의 값이 30dBZ이상의 경우에 구분점이 뚜렷하게 나타나므로, 30dBZ 이상의 반사도 값을 가지고 있는 좌표들로 DZ, SDZ, VGZ 그리고 DZ_FR, SDZ_FR, VGZ_FR을 이용하여 사례 분류를 진행한다. 본 연구에서는 PSO 알고리즘을 사용하여 RBFNNs에 적용할 파라미터 값을 구하며, 기상청 데이터 목적함수 값들의 최적의 위치정보를 찾았다. 각 입력변수들의 독립적인 신경회로망을 통하여 사례 분류를 진행하며, 타 입력변수의 신경회로망의 결과를 취합해 평균을 구하여 본 실험에서 설정한 임계 값 0.5이상일 경우 강수사례로 판단, 그렇지 않을 경우 비 강수 사례로 판단하여 사례 분류를 마친다. 강수 사례와 비 강수 사례를 분류해내는 과정을 먼저 수행 한 뒤, 에코분류를 하기 위하여 입력변수 DZ, SDZ, VGZ, SPN, DZ_FR의 입력변수로 Interval Type-2 기반 FCM 기반 RBFNN의 입력변수로 사용하여 에코분류를 진행하게 된다. Interval Type-2 FCM 기반 RBFNN의 경우 최적화 알고리즘으로 파라미터 값을 구하지는 않았으나, 기존 Type-1 FCM 기반 RBFNN과 Interval Type-2 FCM 기반 RBFNN의 비교실험을 하였다. 최종적으로 에코 분류 과정을 마친 강수사례의 강수에코의 위치와 강수의 반사도 값을 나타내는 에코 맵으로 표현하여 이미지 비교를 하였다. 표 6~10에 기재된 학습(TR : Training)의 패턴 분류율은 동일한 학습데이터로 실험하여 패턴 분류율은 동일하며, 테스트는(TE : Test) 기상청에서 사용하고 있는 필터링된 CZ와 비교를 통하여 패턴 분류율을 백분율로 나타내었다. 제안된 에코분류기의 다양한 성능을 확인하기 위하여 강수사례와 비강수 사례를 테스트 하며, 본 실험을 위해 사용한 초기 파라미터 값을 표 2~4 에 나타내었다.

표 2 PSO의 파라미터 설정

Table 2 Setting parameters of PSO

PSO	
Generation	100
Swarm size	100
c_1, c_2	2.0
$[w_{min}, w_{max}]$	[0.4 0.9]
Fuzzification coefficient range	[1.1 3.0]
Number of rule	[2 8]
Type	0:Constant 1:Linear 2: Modified quadratic

표 3 PSO알고리즘으로 사례분류를 위한 선택된 RBFNN 파라미터

Table 3 Selected RBFNNs Parameters for event classification

Parameter	Value
Number of rule	7
Polynomial Type	Linear
Fuzzification coefficient	1.7

표 4 에코분류를 위한 Type-2 FCM 기반 RBFNN의 파라미터

Table 4 Parameter of Type-2 FCM-based RBFNN for echo classification

Type-1 FCM		Interval Type-2 FCM	
Parameter	Value	Parameter	Value
Number of rules	4	Number of rules	4
Polynomial Type	Linear	Polynomial Type	Linear
Fuzzification coefficient	1.8	Fuzzification coefficient1	2.3
		Fuzzification coefficient2	1.5

표 5 사례 분류를 위한 학습 및 검증 데이터 범위

Table 5 Data range of training and validation for event classification

사이트 : 오성산			
Data	사례	기간	개수
Training	강수	2012년 3월~11월 (00분, 30분)	1524개
	비강수	2012년 3월~11월 (00분, 30분)	1480개
Validation	강수	2012년 3월~11월 (10분, 40분)	800개
	비강수	2012년 3월~11월 (10분, 40분)	800개

사례 분류를 진행하기 위한 Training Data의 범위와 Validation Data의 범위는 표 5에 기재하여 나타내었다. 학습데이터와 검증데이터의 중복이 되지 않도록 두 데이터는 기간 내에 발생한 강수 사례와 비강수 사례에서 강수일 경우의 시간 중 00분, 30분들의 UF데이터만을 선정하여, 사례분류의 학습데이터로 사용하였으며, 비강수 사례는 10분, 40분의 UF데이터를 선정하여 데이터를 구성 하였다.

5.2 강수 사례의 테스트

강수 사례의 테스트는 층운형, 대류형 그리고 층운형과 대류형이 혼합된 경우 그리고 강수에코와 비강수에코(Sea-clutter)가 혼합되어 있는 강수 사례도 테스트 하였다. 제안된 Interval

Type-2 FCM 기반 RBFNN의 성능을 확인하기 위해 Type-1 FCM 기반 RBFNN과 비교 하였다. 성능 결과는 표6 ~ 9에 나타내었고, 그림 11 ~ 14는 각 모델의 결과를 에코 맵으로 나타내었다. 실험에 사용된 모든 사례들에서 관측되는 지형에코(35 ~ 50dBZ 반사도 값을 갖는 에코)는 제안된 Interval Type-2 FCM 기반 RBFNN과 Type-1 FCM 기반 RBFNN의 두 모델 모두 동일하게 제거 되는 것을 확인 할 수 있었다. 하지만 그림 14와 같이 강수 에코와 비강수 에코가 혼합된 경우 비선형성에 강인한 Interval Type-2 FCM 기반 RBFNN이 Type-1 FCM 기반 RBFNN 보다 오성산 레이더 사이트의 서쪽 방향으로 관측되는 파랑에코를 조금 더 제거하는 것을 확인 할 수 있다. 이 두 모델의 차이를 시각적으로 확인하기 위하여 파랑에코가 제거되는 부분을 확대하여 그림 14 (e),(f)에 나타내었다. 강수에코와 비강수에코는 특성이 비슷하여 분류하는 것이 매우 어렵다. 하지만 비선형성에 강인하고, 견실성이 강한 특징을 갖는 Interval Type-2 FCM 기반 RBFNN이 기상학적으로 의미 없는 비강수 에코들을 분류하고 제거하는데 효율적이다.

표 6 각 테스트 데이터의 성능지표

Table 6 Performance index of each test data

Date (13. 07. 07.)	사례 분류 결과	Type-1 FCM 기반 RBFNN		Interval Type-2 FCM 기반 RBFNN	
		TR	TE	TR	TE
05:40	강수 사례	90.37	90.76	90.49	90.81
05:50			90.48		90.55
06:00			90.80		90.84
06:10			90.59		90.32
06:20			90.65		90.51
06:30			90.85		90.71
06:40			90.79		90.73

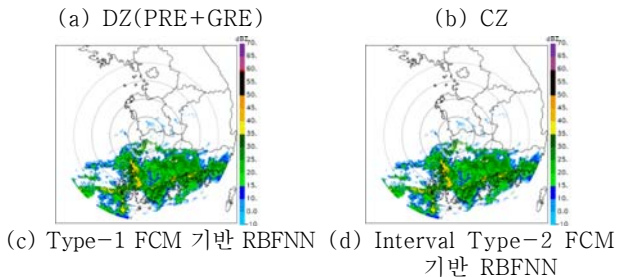



그림 11 레이더 자료(오성산 2013년 07월 07일 05시40분)의 반사도를 이용한 층운형 강수 에코 지도

기상레이더를 이용한 최적화된 Type-2 퍼지 RBFNN 에코 패턴분류기 설계

Fig. 11 Stratiform PRE map by using reflectivity of the radar data (KSN 05:40 on 07 July, 2013)

표 7 각 테스트 데이터의 성능지표

Table 7 Performance index of each test data

Date (13.07.11.)	사례 분류 결과	Type-1 FCM 기반 RBFNN		Interval Type-2 FCM 기반 RBFNN	
		TR	TE	TR	TE
14:00	강수 사례	90.37	84.20	90.49	84.40
14:10			83.60		83.92
14:20			83.87		84.25
14:30			84.04		84.56
14:40			84.26		85.02
14:50			82.69		83.57
15:00			81.87		82.80

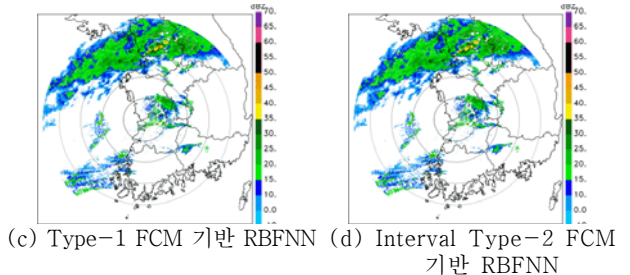



그림 12 레이더 자료(오성산 2013년 7월 11일 14시00분)의 반사도를 이용한 대류형 에코 지도

Fig. 12 Convection echo map by using reflectivity of the radar data (KSN 14:00 on 11 July, 2013)

표 8 각 테스트 데이터의 성능지표

Table 8 Performance index of each test data

Date (13.06.25.)	사례 분류 결과	Type-1 FCM 기반 RBFNN		Interval Type-2 FCM 기반 RBFNN	
		TR	TE	TR	TE
16:30	강수 사례	90.37	85.80	90.49	84.40
16:40			83.02		83.97
16:50			82.23		83.17
17:00			82.13		83.05
17:10			80.63		82.03
17:20			81.28		83.23
17:30			79.78		80.30

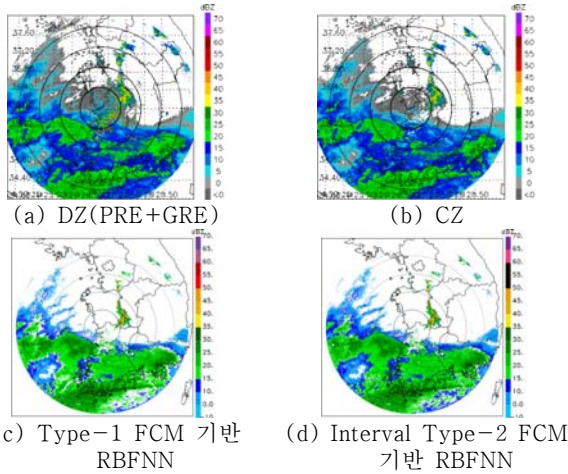


그림 13 레이더 자료(오성산 2013년 6월 25일 16시30분)의 반사도를 이용한 대류+층운형 강수 에코 지도

Fig. 13 Stratiform and Convection PRE map by using reflectivity of the radar data (KSN 16:30 on 25 June, 2013)

표 9 각 테스트 데이터의 성능지표

Table 9 Performance index of each test data

Date (13.04.14.)	사례 분류 결과	Type-1 FCM 기반 RBFNN		Interval Type-2 FCM 기반 RBFNN	
		TR	TE	TR	TE
08:00	강수 사례 (Sea clutter echo 포함)	90.37	84.13	90.49	84.52
08:10			84.97		85.31
08:20			85.72		86.03
08:30			85.86		86.19
08:40			86.59		86.86
08:50			88.39		88.63
09:00			90.63		90.81

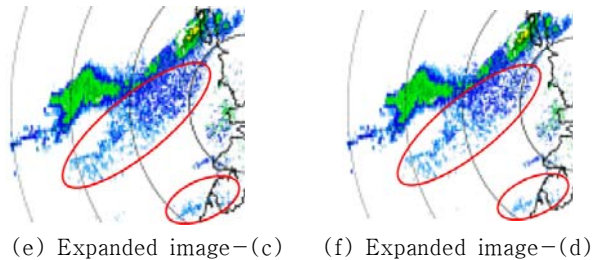
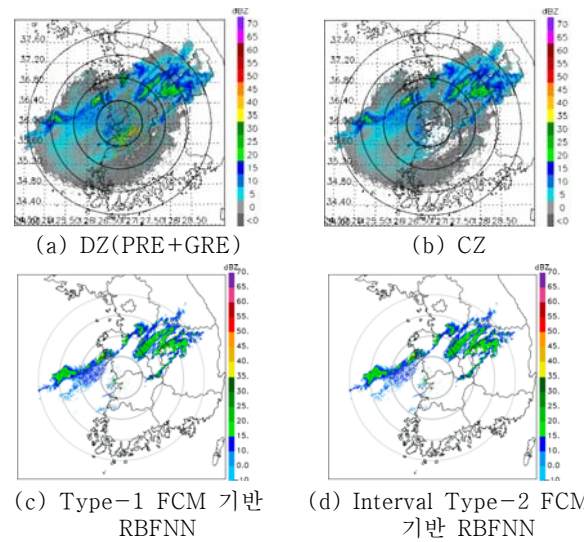


그림 14 레이더 자료(오성산 2013년 4월 14일 08시00분)의 반사도를 이용한 강수+파랑에코 지도

Fig. 14 PRE+Sea-clutter echo map by using reflectivity of the radar data (KSN 08:00 on 14 Apr. 2013)

5.3 비강수 사례의 파랑 에코 테스트

비강수 사례의 파랑에코 테스트의 성능 결과는 표 10에 나타내었고, 그림 15은 모델의 결과를 에코 맵으로 나타낸 것이다. 그림 15의 (a)인 DZ 에코 맵을 보면 지형 에코와 파랑 에코가 혼합되어 나타나고 있다. 그리고 (b)를 보면 필터링을 거쳐 지형에코와 파랑 에코를 제거하였지만, 모두 제거 되지 않은 것을 확인 할 수 있다. 하지만 (c)와(d)를 보면 기상학적으로 의미 없는 지형에코와 파랑 에코를 모두 제거하는 것을 확인 할 수 있다. 표 10과 같이 성능은 제안된 Interval Type-2 FCM 기반 RBFNN이 Type-1 FCM 기반 RBFNN 보다 개선된 성능을 보이지만, 사례 분류를 통해 두 모델이 동일하게 비강수 사례로 판단하여 에코 맵의 결과는 모든 반사도 값을 제거하여 나타난다. 제안된 모델은 사례분류의 결과에 따라 에코 분류를 수행한다. 이에 따라 비강수 사례로 분류 시 비효율적인 에코 분류 과정을 생략하기 때문에 좀 더 빠른 결과를 얻을 수 있다.

표 10 각 테스트 데이터의 성능지표

Table 10 Performance index of each test data

Date (13.04.30.)	사례 분류 결과	Type-1 FCM 기반 RBFNN		Interval Type-2 FCM 기반 RBFNN	
		TR	TE	TR	TE
05:20	비강수 사례	90.37	93.14	90.49	93.58
05:30			93.16		93.58
05:40			93.25		93.65
05:50			92.81		93.26
06:00			92.67		93.07
06:10			92.52		92.89
06:20			92.24		92.63

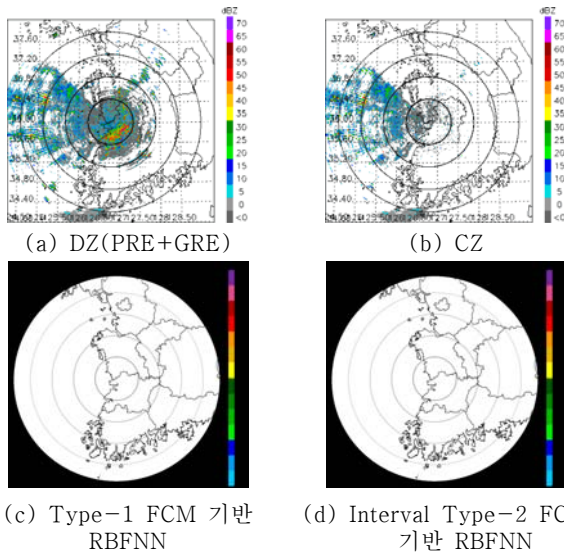


그림 15 레이더 자료(오성산 2013년 4월 30일 05시 20분)의 반사도를 이용한 파랑 에코 지도

Fig. 15 Sea-clutter echo map by using reflectivity of the radar data (KSN 05:20 on 30 Apr. 2013)

5.3 비강수 사례의 청천 에코 테스트

비강수 사례의 청천 에코 테스트의 성능 결과는 표 11에 나타내었고, 그림 16은 모델의 결과를 에코 맵으로 나타낸 것이다. 그림 16의 (a)를 보면 필터링을 거치지 않은 데이터이기 때문에 지형에코와 청천 에코가 같이 나타나고 있다. (b)는 필터링을 거쳐 지형에코를 제거하였지만 청천 에코는 여전히 제거 되지 않은 상태이다. 하지만 (c)와 (d)를 보면 지형 에코와 청천 에코가 모두 지워지는 것을 확인할 수 있다. 청천에코 경우, 앞서 설명한 파랑 에코와 동일한 비강수 사례의 경우로 성능은 제안된 Interval Type-2 FCM 기반 RBNN이 Type-1 FCM 기반 RBFNN보다 개선된 성능을 보이지만, 에코 맵의 결과는 동일하게 나타난다.

표 11 각 테스트 데이터의 성능지표

Table 11 Performance index of each test data

Date (13.10.01.)	사례 분류 결과	Type-1 FCM 기반 RBFNN		Interval Type-2 FCM 기반 RBFNN	
		TR	TE	TR	TE
04:00	비강수 사례	90.37	93.41	90.49	93.58
04:10			93.38		93.45
04:20			93.55		93.63
04:30			93.56		93.63
04:40			93.55		93.64
04:50			93.64		93.70
05:00			93.55		93.64

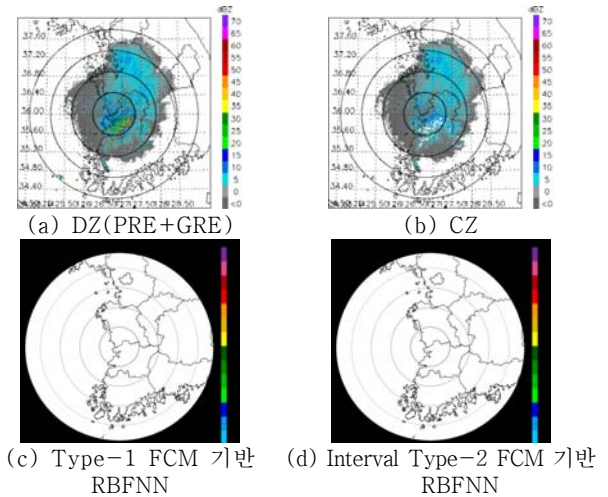


그림 16 레이더 자료(오성산 2013년 10월 01일 04시00분)의 반사도를 이용한 청천 에코 지도

Fig. 16 Clear air echo map by using reflectivity of the radar data (KSN 04:00 on 01 Oct. 2013)

6. 결론

기상 레이더 데이터는 강수 에코와 비강수 에코의 특성이 매우 비슷하여 분류하기가 쉽지 않고, 자연적인 특성으로 인해 외란과 불확실한 정보가 많기 때문에 본 연구에서는 비선형에 강인하고, 견실성이 강한 Interval Type-2 FCM 기반 RBFNN을 제안하였다. 또한 효율적인 에코 분류를 수행하기 위해 제안된 모델은 1차적으로 사례 분류기를 통해 강수 사례와 비강수 사례를 분류하고, 강수 사례일 경우 2차적으로 에코 분류기를 통해 강수 에코와 비강수 에코를 분류한다. 사례 분류기는 전처리 과정으로 수행되며, 이는 3개의 독립적인 신경회로망으로 구성하였다. 에코 분류기는 사례 분류기의 결과에 따라 강수 사례일 경우에만 수행하게 되며, 비강수 사례일 경우 모든 반사도 값을 제거함으로써 에코 분류 과정을 생략한다. 제안된 모델의 성능을 확인하기 위해 Type-1 FCM 기반 RBFNN과 비교 하였고, 모델의 결과를 에코 맵으로 나타내어 비교 설명 하였다. 실험을 통해 사례 분류의 결과가 비강수 사례일 경우, 모든 반사도 값을 제거하여 에코 맵으로 나타내기 때문에 보다 효율적인 결과를 얻을 수 있었다. 그리고 강수 사례일 경우, 제안된 Interval Type-2 FCM 기반

RBFNN이 Type-1 FCM 기반 RBFNN보다 개선된 성능을 보였고, 에코 맵의 결과에서도 비강수 에코를 우수하게 제거하는 것을 확인 할 수 있었다. 본 연구를 통한 기존 Type-1 FCM 기반의 RBFNN보다 개선된 성능은 강수에코에 존재하는 비강수에코를 더 잘 제거하여 정확한 에코 값을 얻을 수 있다는 점을 기대 할 수 있다. 또한, 사례 분류를 통하여 비강수 사례 시에, 비강수에코를 제거하는 분류과정을 효율적으로 생략 할 수 있는 장점이 있다. 향후 연구방향으로는 강수 에코 및 비강수 에코를 분류하기 위한 새로운 입력변수를 고려하여 특성분석을 통하여 새로운 입력변수의 적용이다. 또한 본 논문에서는 사례 분류시에만 진화 알고리즘으로 파라미터의 최적화를 하였으나, 추후에 Interval Type-2 FCM 기반 RBFNN의 파라미터들도 다양한 진화 알고리즘의 도움으로 최적화된 파라미터를 확보한다.

감사의 글

본 연구는 경기도의 경기도지역협력연구센터사업의 일환으로 수행하였음[GRRC 수원2014-B2, U-city 보안감시 기술협력센터]

References

[1] Yo-Han Cho, Gyu Won Lee, Kyung-Eak Kim, and Isztar Zawadzki, "Identification and removal of ground echoes and anomalous propagation using the characteristics of radar echoes." J. Atmos. Oceanic Technol, vol. 23, pp.1206-1222, 2006.

[2] Tanvir Islam, Miguel A. Rico-Ramirez, Dawei Han, and Prashant K. Srivastava, "Artificial intelligence techniques for clutter identification with polarimetric radar signatures." Atmospheric Research, vol. 109-110, pp. 95-113, 2012.

[3] Andi Walther, Marc Schröder, Jürgen Fischer, and Ralf Bennartz, "Comparison of precipitation in the regional climate model BALTIMOS to radar observations." Theoretical and Applied Climatology, vol 118, pp.627-640, 2009.

[4] Marc Berenguer, Daniel Sempere-Torres, Carles Corral, and Rafael Sánchez-Diezma, "A fuzzy logic technique for identifying nonprecipitating echoes in radar scans." J. Atmos. Oceanic Technol., vol.23, pp.1157-1180, 2006.

[5] Kilambi. A, A. Bellon, A. Singh, I. Zawadzki, C. Page and F. Fabry, "RAPID: A radar data analysis, processing and interactive display system", 28th Int Conf. on Radar Meteorology, pp.220-221. 1997.

[6] G. Pajares, M. Guijarro, and A. Ribeiro, "A Hopfield Neural Network for combining classifiers applied to textured images." Neural Networks, vol.23, pp.144-153, 2010.

[7] S. Abbasbandy, M. Otadi, and M. Mosleh, "Numerical solution of a system of fuzzy polynomials by fuzzy neural network." Information Sciences vol.178, pp.1948-1960, 2008.

[8] J. H. Ko, S. K. Oh, and Y. H. Lee, "Design of Echo Pattern Classifier Using Fuzzy Neural Networks", Proceedings of KIIS Fall Conference, Vol. 23-2, pp.19-20, 2013.

[9] Rhee. F, Choi B., "Interval type-2 Fuzzy Membership Function Design and its Application to Radial Basis Function Neural Networks" Int. Conf. Fuzzy Syst., pp. 2047-2052, 2007.

[10] W. Pedrycz, "Conditional fuzzy clustering in the design of radial basis function neural networks," IEEE Trans. Neural Networks, vol. 9, pp. 601-612, 1998.

저 자 소 개



송 찬 석(Chan-Seok Song)

2014년 수원대학교 전기공학과 졸업.
2014년~현재 동 대학원 석사과정. 관심분야는 퍼지추론 시스템, 뉴럴 네트워크, 패턴 분류, 진화론적 최적화 알고리즘,
Tel : 031-222-6544
Fax : 031-220-2667
E-mail : scsmouse@suwon.ac.kr



이 승 철(Seung-Chul Lee)

2014년 수원대학교 전기공학과 졸업.
2014년~현재 동 대학원 석사과정. 관심분야는 퍼지추론 시스템, 뉴럴 네트워크, 패턴 분류, 진화론적 최적화 알고리즘.
Tel : 031-222-6544
Fax : 031-220-2667
E-mail : lsc225@suwon.ac.kr



오 성 권(Sung-Kwun Oh)

1981년 연세대학교 전기공학과 졸업, 동 대학원 석사(1983), 박사(1993). 1983~1989년 금성산전연구소(선임연구원). 1996~1997년 캐나다 Manitoba 대학 전기 및 컴퓨터공학과 Post-Doc. 1993~2004년 원광대학교 전기전자 및 정보공학부 교수. 2005~현재 수원대학교 전기공학과 교수, 2002~현재 대한

전기학회, 제어로봇시스템학회, 퍼지및지능시스템학회 편집위원. 관심분야는 퍼지 시스템, 퍼지-뉴럴 네트워크, 자동화 시스템, 고급 computational intelligence, 지능 제어등.

Tel : 031-229-8162

Fax : 031-220-2667

E-mail : ohsk@suwon.ac.kr