

정보입자기반 RBFNNs에 의한 하수처리공정 시뮬레이터의 설계

이승주, 오성권
수원대학교 전기공학과

Design of Sewage Treatment Process Simulator with the Aid of IG-based RBFNNs.

Seung-Joo Lee and Sung-Kwon Oh
Department of Electrical Engineering, The University of Suwon

Abstract - RBFNNs(Radial Basis Function Neural Networks) 모델의 경우 Min-Max, HCM(Hard C-means)클러스터링 그리고 FCM(Fuzzy C-means)클러스터링 중 한 가지를 통해 데이터 입자는 로드 규칙을 생성한 후 퍼지 공간을 분할 및 가우시안 함수의 정점을 정의한다. 본 논문은 기존의 방법과는 다르게 Min-Max와 FCM클러스터링을 혼합하여 로드의 규칙을 생성한 후 퍼지 공간을 분할 및 가우시안 함수의 정점을 정의하는 방법으로 사용하고자 한다. PSO최적화 알고리즘을 이용하여 같은 조건에서 최적화한 기존의 방법으로 모델링된 RBFNNs와 Min-Max와 FCM 클러스터링을 혼합하여 사용한 방법의 비교를 통하여 어떤 모델의 성능이 더욱 좋은지 비교하고자 한다.

1. 서 론

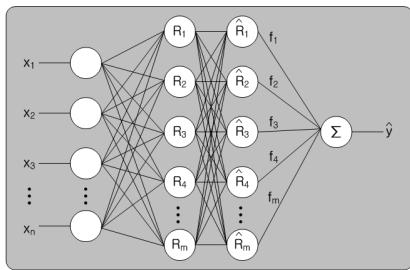
본 논문에서는 RBFNNs를 사용하여 모델을 구성하는데 있어서 전반부의 퍼지 공간 분할 방법에 변화를 주고자 한다. 기존 RBFNNs의 모델의 경우 전반부의 퍼지 공간의 분할 시에 입력데이터의 최대값과 최소값을 기준으로 사용하거나 HCM(Hard C-means)이나 FCM(Fuzzy C-means)을 사용하여 중심 값을 구하는 방법을 사용하게 된다. 하지만 이와 같은 방식에는 문제가 발생한다. 학습 데이터를 사용하여 모델을 만들고 테스트 데이터를 사용하여 성능을 평가하고자 할 때 은닉층의 증가에 따라 학습데이터의 성능이 나아지지만 테스트 데이터에 대한 성능은 급격하게 안좋아지는 경향을 보인다는 것이다.

그리하여 본 논문은 기존 FCM을 사용하는 방법과 Min-Max를 혼합하여 사용하고 이것을 같은 조건하에 PSO알고리즘을 통하여 어떠한 모델이 성능이 더 뛰어나게 나오지는 비교해 보도록 하겠다.

2. 본 론

2.1 RBFNNs

RBFNNs의 구조는 입력층, 은닉층, 출력층으로 구성되며 은닉층의 기본 구조는 <그림 1>과 같다. 여기서 n 은 입력공간의 차원 수를 나타내며 m 은 은닉층의 수를 나타낸다. 은닉층은 활성 함수로서 방사형 기저 함수(Radial Basis Function)을 사용하여 은닉층의 출력 값을 결정한다.



<그림 1> MISO RBFNNs

전반부는 다중 입력, 후반부는 단일 출력을 기반으로 한 단일 규칙을 가지고 그 규칙은 식 (1)과 같으며,

$$\text{If } x_1 \text{ and } \dots \text{ and } x_n \text{ is } R_i \text{ then } y_i = f(x_1, \dots, x_n) \quad (1)$$

후반부 추론식은 식 (2),(3)과 같다.

간략 추론(case 1) :

$$f = w_j^s \quad (2)$$

선형 추론(case 2) :

$$f = w_j^s + \sum_{k=1}^d w_{jk}^s x_k \quad (3)$$

여기서, s 는 출력변수의 수를 의미한다.

설계된 RBFNNs의 각 층의 연산과정은 다음과 같다.

[1층] 입력층

입력 신호가 다음 층의 해당 노드로 전달된다.

[2층] 적합도 계산 : R^i

가우시안 함수를 사용하여 은닉층의 출력 값을 결정

$$R^i = e^{-\sum_{j=1}^n \frac{(x_{ij} - v_{ij})^2}{2\sigma_j^2}} \quad (4)$$

[3층] 적합도 정규화 : \hat{R}^i

$$\hat{R}^i = \frac{R^i}{\sum_{i=1}^m R^i} \quad (5)$$

[4층] 최종 출력 : \hat{y}

LSE를 사용하여 전체 퍼지 규칙의 파라미터 계수를 동시 계산

$$\hat{y} = \sum_{i=1}^m \hat{R}^i \cdot f_i \quad (6)$$

2.1.1 FCM 클러스터링

FCM클러스터링은 각 클러스터의 점에 대하여 데이터의 소속 정도를 소속함수로 나타낸 데이터 분류 알고리즘으로 소속정도는 클러스터의 중심점과 각 데이터들의 거리로 계산한다.

FCM 클러스터링의 방법은 다음과 같다.

[단계1] 클러스터의 개수 c ($2 < c < n$)을 정하고 퍼지화계수 m ($1 < m < \infty$)을 선택한다. 초기 소속함수를 초기화 한다.

[단계2] FCM 클러스터 중심점 v_{ij} ($i=1, 2, \dots, c$, $j=1, 2, \dots, n$)를 계산한다.

$$v_{ij} = \frac{\sum_{k=1}^n (u_{ik})^2 x_{kj}}{\sum_{k=1}^n (u_{ik})^2} \quad (7)$$

[단계3] FCM클러스터의 중심과 데이터의 거리를 구한다.

$$d_{ik} = \left(\sum_{j=1}^n (x_{kj} - v_{ij})^2 \right)^{1/2} \quad (8)$$

[단계4] 구한 거리를 바탕으로 새로운 소속함수를 구한다.

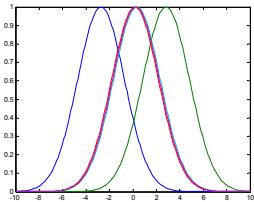
$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}} \right)} \quad (9)$$

[단계5] 이전 소속함수와 새로운 소속함수의 차가 초기 설정치에 만족하면 종료하고 아니면 위의 과정을 반복한다.

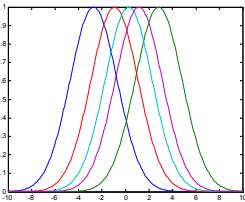
2.1.2 FCM 클러스터링과 Min-Max 혼합

FCM클러스터링과 Min-Max 혼합에는 여러 가지 방법을 생각해 볼 수 있겠으나 2가지 방법을 사용하도록 하겠다. 첫 번째 방법은 전체 은

넉총 중심 값의 50%는 FCM클러스터링을 통해서 나머지 50%는 Min-Max값의 균등 분할을 통해서 찾아내는 방법, 두 번째 방법은 FCM 클러스터링을 사용하되 클러스터링의 중심 값 중 두 개의 값을 입력데이터의 Min-Max값으로 고정을 시키는 방법이다. 두 번째 방법을 추가로 설명하면 은닉층이 5개가 존재할 때 2개의 중심 값을 데이터의 Min값과 Max값으로 고정해서 FCM클러스터링을 통해 구한 중심 값과 2개의 중심 값을 데이터의 Min값과 Max값을 넣고 3개만 FCM클러스터링을 통해 구한 중심 값은 확실히 차이가 있다. <그림 2>는 FCM클러스터링 시 Min-Max값을 함께 클러스터링에 사용한 것이며, <그림 3>은 Min-Max 값을 추가시킨 것이다.



<그림 2> Min-Max 학습



<그림 3> Min-Max 추가

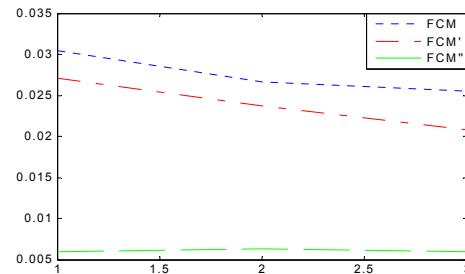
클러스터링 시 데이터의 Min-Max값을 함께 넣고 클러스터링을 하는 것이 학습데이터, 트레이닝데이터, 검증데이터의 성능이 더 좋은 것을 볼 수 있다. 그리고 은닉층의 반은 FCM클러스터링으로 나머지 반은 Min-Max 값의 균등분할 값으로 사용한 경우는 데이터에 따라 차이가 있음이 볼 수 있다.

〈표 4〉 수처리 성능

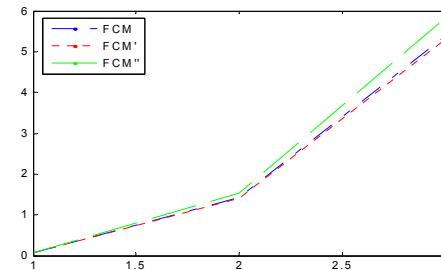
	FCM	FCM'	FCM"
PI	0.0304793609	0.0270630851	0.0059829215
EPI	0.0266828235	0.0236782147	0.0063280158
Validation	0.0255000616	0.0207776458	0.0059138139

〈표 5〉 가스로 성능

	FCM	FCM'	FCM"
PI	0.0702438090	0.0691243009	0.0745598019
EPI	1.4304777418	1.4135013230	1.5255778626
Validation	5.3911614702	5.3091817118	5.8479568155



<그림 4> 수처리 성능



<그림 5> 가스로 성능

x축 1: PI, 2: EPI, 3: Validation, y축 각 성능 값

4. 결 론

이번 논문은 FCM클러스터링으로 RBFNNs의 은닉층 중심 값을 찾을 때 데이터의 최대 값과 최소 값을 혼합함에 따른 효과를 알아보기 위한 실험이었다. FCM클러스터링 시 학습 데이터의 최대 값과 최소 값을 고정해 놓고 찾아낸 RBFNNs의 중심 값을 사용 시 일반적인 방법의 PI, EPI 와 Validation 보다 전반적으로 더 좋은 성능을 보여준다.

감사의 글

본 연구는 중소기업청에서 지원하는 2010년도 산학연 공동 기술개발 사업(No. 00043125)의 연구수행으로 인한 결과물임을 밝힙니다. 그리고 이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2009-0074928)

[참 고 문 헌]

- [1] S. K Oh, W. Pedrycz, H. S. Park, "A granular-oriented development of functional radial basis function neural networks", Neurocomputing 72, pp. 420-435, 2008.
- [2] S. K Oh, W. Pedrycz, "genetic optimization-driven multi-layer hybrid fuzzy neural networks", Simulation Modelling Practice and Theory, Vol. 14, pp. 627-642, 2003.

2.2 PSO알고리즘

PSO 알고리즘은 진화연산의 결합에 의한 기술이다. PSO는 물고기, 새떼와 같은 행동양식을 바탕으로 이루어진다. RBFNNs에서 입력 데이터의 수, 입력 데이터의 선택, FCM의 폐지화계수, 은닉층의 수와 후반부 추론방법을 찾아낸다.

3. 실험 및 결과 고찰

본 논문의 사용하는 하수처리 시스템의 데이터를 주로 사용하되 비교를 돋기 위해 가스로 데이터도 사용한다. 데이터는 학습 : 트레이닝 : 검증으로 나누어 5 : 3 : 2 구성한다. 모델구성 및 최적화 시 학습데이터와 트레이닝 데이터를 사용하며 최적화된 파라미터를 적용하며 모델구성 시 모델의 평가는 검증데이터를 사용한다. 검증데이터는 모델의 구성 시 어떠한 가담 하지 않는다.

3.1 PSO알고리즘 최적화 조건 설정

앞 절에서 본 것과 같이 PSO최적화 알고리즘을 이용하여 찾아낸 파라미터들은 <표 1>과 같다. 데이터 선택에 있어서는 중복 선택이 가능하다.

〈표 1〉 PSO알고리즘 최적화 범위

입력 수	데이터선택	폐지화계수	은닉층수	추론방법
2-5	1-5	1-3	10-40	간략,선행

3.2 최적화에 따른 모델 파라미터

다음 <표 2>과 <표 3>는 최적화알고리즘을 이용하여 찾아낸 각 모델의 파라미터 값이다. 가스로데이터의 FCM"을 나머지는 은닉층의 수가 비교적 비슷하게 나타남을 볼 수 있다.

〈표 2〉 수처리 데이터 최적화 파라미터

	입력 수	데이터선택	폐지화계수	은닉층수	추론방법
FCM	4	1,3,4,5	1	25	선행
FCM'	4	1,3,4,5	1	25	선행
FCM"	5	1,2,4,5,1	2	28	선행

〈표 3〉 가스로 데이터 최적화 파라미터

	입력 수	데이터선택	폐지화계수	은닉층수	추론방법
FCM	2	1,5	1.054423933068	31	간략
FCM'	2	1,5	2.132545434500	28	간략
FCM"	2	1,5	1	10	선행

FCM : FCM클러스터링만을 사용

FCM' : FCM클러스터링 시 Min-Max값 고정

FCM" : FCM클러스터링 시 총 은닉층의 반은 Min-Max 균등분할

3.3 각 모델의 성능

다음 <표 4>과 <표 5>는 수처리 데이터와 가스로 데이터라 모델링 시 성능을 보여주는 표이다. 그리고 <그림 4>와 <그림 5>는 <표 4>과 <표 5>의 값을 보기 쉽게 그래프로 나타낸 것이다. 수처리 성능과 가스로 성능의 공통점은 일반 FCM클러스터링을 사용하는 것 보다 FCM를