

하수처리 공정을 위한 Type-2 RBF Neural Networks 모델링 설계

Design of Type-2 Radial Basis Function Neural Networks Modeling for Sewage Treatment Process

이 승 철* · 권 학 주* · 오 성 권*
(Seung-Cheol Lee · Hak-Joo Kwun · Sung-Kwun Oh)

Abstract - In this paper, The methodology of Type-2 fuzzy set-based Radial Basis Function Neural Network(T2RBFNN) is proposed for Sewage Treatment Process and the simulator is developed for application to the real-world sewage treatment plant by using the proposed model. The proposed model has robust characteristic than conventional RBFNN. architecture of network consist of three layers such as input layer, hidden layer and output layer of RBFNN, and Type-2 fuzzy set is applied to receptive field in contrast with conventional radial basis function. In addition, the connection weights of the proposed model are defined as linear polynomial function, and then are learned through Back-Propagation(BP). Type reduction is carried out by using Karnik and Mendel(KM) algorithm between hidden layer and output layer. Sewage treatment data obtained from real-world sewage treatment plant is employed to evaluate performance of the proposed model, and their results are analyzed as well as compared with those of conventional RBFNN.

Key Words : Type-2 RBFNNs, KM algorithm, Back-propagation, Sewage treatment process

1. 서 론

도시를 중심으로 많은 지역에서 물 수요가 급증함에 따라 하수의 재이용에 대한 중요성이 높아지고 있고, 산업화의 성장에 의한 수질 악화와 환경오염으로 인해 맑은 하천, 해안, 맑은 물의 중요성이 부각되고 있다. 또한 최근 하수도법이 강화되어 하수의 질소(N)와 인(P)을 효과적으로 처리하는 방법이 중요시 되고 있다. 하지만 하수를 처리하는 유기화합물의 종류가 다양해지고 하수처리과정이 복잡해졌기 때문에 질소와 인을 효과적으로 처리하지 못하고 있다.

그리고 현재 하수처리 자동화 시스템은 복잡한 시스템과 생물학적 특성으로 인해 정확도가 떨어져 사용자에게 의해 수동으로 실시되고 있는데, 현재 하수처리 공정을 수동으로 운전할 수 있는 사용자도 많지 않다. 또한 수동으로 운전 시 하수처리장의 온도, 대기변화, 호기조의 유입 등 여러 변수에 의하여 하수처리에 영향을 미치는 용존 산소량을 정확히 예측하기 어렵다. 이로 인해 하수처리의 공정 효율이 낮고, 방류수 수질이 개선되지 않고 있다. 게다가 이러한 문제를 가지고 있는 국내의 하수처리 기업 대부분

은 국내에서 개발한 하수처리 시스템이 아닌 캐나다 Hydromantis에서 개발한 GPS-X에 의존하여 하수처리장을 운영하고 있다. GPS-X는 수학적 모델로 복잡한 데이터를 이용하여 공정하기에는 한계가 있고, 국내 기술이 아닌 외국 기술이기 때문에 가격이 비싸다는 단점을 가지고 있다. 이와 같은 문제를 해결하기 위해 하수처리 자동화 시스템과 효과적인 하수처리 공정 방법에 대한 연구가 활발히 이루어지고 있다[9].

하수처리 시스템은 유입되는 하수를 1차, 2차, 3차 처리 및 고도처리 등으로 정화하여 방류 수질 법적 기준치에 적합할 때 방류하는 시스템이다. 1차 처리는 최초 침전지에서 하수의 부유물질을 물리적으로 제거하고, 2차 처리는 물리·화학적 처리와 생물학적 처리를 할 수 있는 환경을 만들어 준다. 3차 처리 및 고도 처리는 질소와 인을 제거한다. 여기서 고도처리 공정은 물리·화학적 처리 방법과 생물학적 처리 방법(활성오니 공정)으로 나누어져 있다. 물리·화학적 처리 공정은 약품을 이용하여 하수를 정화시키는 방법으로 환경 친화적 기술에 부합하지 않고, 비용이 비싸다는 단점이 있어 하수처리 시스템에는 일반적으로 생물학적 처리 방법이 사용된다[10]. 생물학적 처리 방법은 비선형적 특성이 강해 수학적 모델로는 공정하기가 어렵다. 이러한 비선형적 특성을 가지는 하수처리 공정을 최적으로 모델링하기 위해서는 정확한 모델 구축이 필요하다. 따라서 본 연구에서는 보다 효율적으로 실제 하수처리 시스템에 적용하기 위해 생물학적 처리 방법을 지능형 알고리즘을 이용하여 모델링하고, 최종적으로 방출되는 유출수와 방류 수질 법적 기준치와 비교하여 방류하기에 적

† 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
Received : November 11, 2014; Accepted : September 23, 2015

합한 물인지를 판단하는 시스템을 제작한다.

본 연구에서는 하수처리 공정을 위한 Type-2 퍼지 집합 기반 방사형 기저함수 신경회로망을 제안한다. 제안된 모델은 기존의 Type-1 방사형 기저함수 신경회로망과 동일하게 입력층, 은닉층, 출력층으로 구성되어 있지만, 은닉층 활성화함수에 Type-2 퍼지집합을 적용시키고, 은닉층과 출력층 사이에 Type Reduction 역할을 하는 Karnik and Mendel(KM) 알고리즘을 사용하여 최종 출력을 구한다[3, 4]. 은닉층 활성화함수의 중심점은 Min-Max 방법을 이용하여 입력 데이터를 균등하게 분할하여 결정하였고, 분포 상수는 입력 데이터간의 표준편차를 이용하여 결정하였다[1, 5]. 또한 제안된 모델의 연결가중치는 1차 선형식(Linear)으로 정의되며, 연결가중치의 파라미터 값은 제안된 모델의 특성으로 인해 최소사승법(LSE : Least Square Estimation) 사용이 불가능하여 Back-Propagation(BP)학습을 통해 구하였다[2, 6].

본 논문 2장에서는 하수처리 공정 방법의 전체적인 흐름과 모델링 하고자 하는 고도처리 공정의 생물학적 처리 시스템(활성오니 공정)에 대해 설명하고 주요인자 선정 방법에 대해서도 설명한다[8]. 3장에서는 하수처리 공정 모델링을 위한 Type-2 방사형 기저함수 신경회로망의 구조에 대해 설명하고, 은닉층과 출력층 사이에서 Type Reduction 역할을 하는 Karnik and Mendel (KM) 알고리즘에 대해 설명한다. 그리고 4장에서 제안된 하수처리 공정 시스템의 구조에 대해 설명하고, 5장에서는 실험에 사용한 파라미터 및 실험 과정에 대해 설명한다. 제안된 모델의 성능 확인을 위해 기존의 Type-1 방사형 기저함수 신경회로망 모델과 성능을 비교하여 설명한다. 마지막으로 결론에 대하여 설명한다.

2. 하수처리 공정 방법 및 주요 인자 선정

2장에서는 1차, 2차, 3차 처리 및 고도처리 등으로 분류 되어 있는 하수처리 시스템에 대해 설명한다. 그리고 고도처리 공정 방법 중에서 생물학적 처리 방법에 대해 자세히 설명하고 모델링 하기 위한 주요 인자 선정에 대해 설명한다.

2.1 하수처리 공정 방법

표 1 방류수 수질 기준 값

Table 1 Standard value of effluence water quality

	1일 하수처리 용량 (50m3이상)	1일 하수처리 용량 (50m3미만)
생물학적 산소 요구량 BOD (mg/l)	10 이하	10 이하
화학적 산소 요구량 COD (mg/l)	40 이하	40 이하
부유물질 SS (mg/l)	10 이하	10 이하
총 질소 T-N (mg/l)	20 이하	40 이하
총 인 T-P (mg/l)	2 이하	4 이하
총 대장균수 (개/ml)	3,000 이하	3,000 이하

그림 1은 전체적인 하수처리 시스템 과정 및 생물학적 처리 시스템을 나타낸다. 1차 처리는 최초 침전지에서 하수의 부유물질을 물리적으로 제거한다. 2차 처리는 유기물을 처리하고, 화학적 처리와 생물학적 처리가 쉽게 될 수 있는 환경을 만들어 준다. 3차 처리 및 고도 처리는 질소(N)와 인(P)을 제거하는 기술로서 물리·화학적 처리 방법과 생물학적 처리 방법(활성오니 공정)이 있다. 최종적으로 하수는 표 1과 같이 방류수 수질 기준 값에 적합할 때 방류하게 된다.

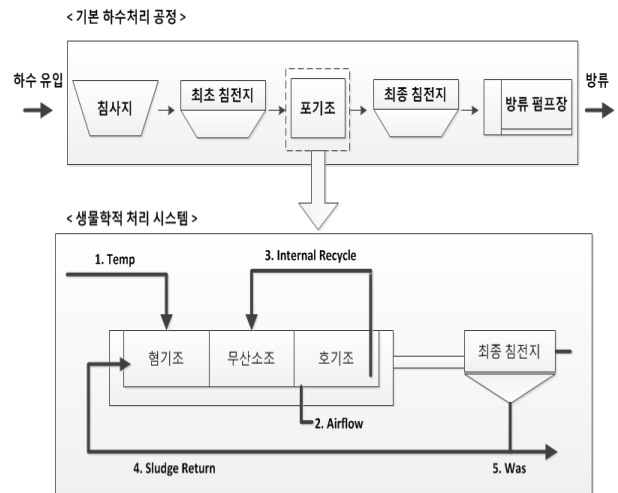


그림 1 하수처리 공정 시스템

Fig. 1 Sewerage treatment process systems

2.2 활성오니 공정 시스템

고도처리 공정은 기본 하수처리 공정에서 포기조의 역할을 세분화 한 것을 말하고, 물리·화학적 처리 시스템과 생물학적 처리 시스템(활성오니 공정 시스템)으로 나눌 수 있다. 물리·화학적 처리 시스템은 약품주입을 통해 하수를 정화하는 시스템이고, 활성오니 공정 시스템은 물의 순환과 산소 주입 등으로 하수를 정화하는 시스템이다[8]. 일반적으로 하수처리 공정은 물리·화학적 처리 시스템과 생물학적 처리 시스템을 병행하여 공정한다. 하지만 본 연구에서는 물리·화학적 처리 시스템에 비해 자연친화적이고 저렴한 활성오니 공정만을 이용하여 하수처리 공정 시스템을 설계하였다[9].

활성오니 공정 시스템에서 각 조의 역할은 다음과 같다. 혐기조는 유기물의 인 방출량을 증가시키고, 무산소조는 호기조에서 내부 반송하여 유입되는 질산성 질소(NO3)를 질소가스(N2)로 바꾸어 질소를 제거하는 역할을 한다. 호기조에서는 무산소조와 혐기조에서 처리되지 않은 유기물질을 제거하고, 암모니아성 질소(NH3)를 질산성 질소(NO3)로 산화시키기 위하여 호기성 상태를 유지하는 역할을 한다. 각 조에서 조작되는 것은 총 5개로 Temp, Airflow, Internal Recycle, Sludge Return, Was 이다. Temp는 물의 용존산소량과 미생물 생성에 영향을 주는 역할로 유입되는 물의 양을 조절하고, Airflow는 암모니아성 질소(NH3)를 질산성

질소(NO3)로 산화시키는 역할로 호기조의 공기량을 조절한다. Internal Recycle은 산화된 질산성 질소(NO3)를 무산소조로 이동시키는데 이때의 물의 양을 조절한다. 그리고 Sludge Return은 침전지에 남아있는 부유물의 일정 부분을 공정의 초기 부분으로 순환시키는 역할로 이때의 물의 양을 조절한다. 마지막으로 Was는 침전지에서 남아있는 부유물의 폐기량을 조절한다[10].

2.3 활성오니 공정의 주요인자 선정

활성오니 공정의 주요인자는 2가지 측면에서 선정한다. 첫 번째는 수질에 관한 인자이고, 두 번째는 조작에 관한 인자이다. 방류수의 수질이 방류수 수질 기준 값에 적합하지 않으면 방류를 할 수 없기 때문에 활성오니 공정 시스템에서 가장 중요한 부분은 방류수의 수질 인자와 유입수의 수질을 변화시키는 조작 인자이다. 그렇기 때문에 수질에 관한 활성오니 공정의 주요 인자로서 방류 수질 법적 기준표를 참고하여 유입되는 물의 양(Q), 생물학적 산소 요구량(BOD), 부유물질(SS), 총 질소(T-N), 총 인(T-P)을 선정한다. 그리고 조작에 관한 활성오니 공정의 주요 인자로 Temp, Airflow, Internal Recycle, Sludge Return, Was를 선정한다. 또한 방류 수질 법적 기준치에 중대한 비중을 차지하고 있는 질소(N)와 인(P)을 암모니아성 질소(NH3)와 질산성 질소(NO3), 인산염(PO4)으로 세분화 하여 주요인자로 선정한다. 최종적으로 활성오니 공정의 주요인자는 총 13개로 선정하였다. 수질인자와 조작인자로 이루어진 주요인자는 생물학적 처리 시스템에서 미생물의 생성과 유지에 직접적으로 영향을 미친다.

3. Type-2 RBFNNs 모델링 설계

3장에서서는 활성오니 공정을 위한 Type-2 RBFNNs 구조에 대해 자세히 설명하고, Type-1 RBFNNs과 Type-2 RBFNNs의 차이점에 대해 설명한다. 그리고 연결가중치 학습을 위해 사용한 Back-Propagation(BP) 알고리즘에 대해 설명한다. 마지막으로 은닉층과 출력층 사이에 Type Reduction 역할을 하는 Karnik and Mendel(KM) 알고리즘에 대해 설명한다.

3.1 다항식 기반 Type-2 RBFNNs 구조

Type-2 방사형 기저함수 신경회로망은 일반적인 신경회로망의 구조를 기반으로 하여 입력층, 은닉층, 출력층으로 나누어진다 [1]. 그리고 은닉층과 출력층 사이에 Type Reduction 역할을 위해 KM알고리즘을 사용하여 출력을 Type-2에서 Type-1으로 바꿔준다. 그림 2는 전체적인 Type-2 방사형 기저함수 신경회로망 구조를 나타낸다.

입력층에서는 기존의 Type-1 방사형 기저함수 신경회로망과 동일하다. 각 입력이 은닉층의 각 노드로 들어가며, 은닉층 중심점 및 분포상수는 입력변수에 의해 결정된다[2]. 하지만 제안된 모델의 은닉층 활성화함수는 Type-2 퍼지 집합을 사용하며 활성화함수는 그림 3과 같이 방사형 기저함수의 형태로서 가우시안 형태




그림 2 Type-2 방사형 기저함수 신경회로망 구조

Fig. 2 Architecture of Type-2 Radial Basis Function Neural Networks

를 사용한다[3, 5]. 가우시안 함수식은 식 (1)과 같고, 제안된 모델에서 사용한 가우시안 함수는 식 (1)을 변형한 형태로 식 (2)와 같다. 식 (2)는 표준편차 σ 가 각 입력변수마다 다르게 설정된다. 여기서, x 는 입력변수, v 는 중심점, σ 는 분포상수를 나타낸다. 그리고, j 는 은닉층의 노드 번호를 나타내며, k 는 입력변수의 번호를 각각 나타낸다. 본 연구에서는 입력공간을 동일한 공간으로 나누는 방법인 Min-Max 방법을 이용하여 중심점을 구하였고, 분포상수는 입력변수의 표준편차를 사용하여 구하였다.

$$R_j(x) = e^{-\frac{\|x_i - v_j\|^2}{2\sigma_j^2}} = e^{-\frac{1}{2} \left(\frac{(x_1 - v_{1j})^2}{\sigma_{1j}^2} + \frac{(x_2 - v_{2j})^2}{\sigma_{2j}^2} + \dots + \frac{(x_k - v_{kj})^2}{\sigma_{kj}^2} \right)} \quad (1)$$

$$R_j(x) = e^{-\frac{\|x_i - v_j\|^2}{2\sigma_j^2}} \approx e^{-\frac{1}{2} \left(\frac{(x_1 - v_{1j})^2}{\sigma_{1j}^2} + \frac{(x_2 - v_{2j})^2}{\sigma_{2j}^2} + \dots + \frac{(x_k - v_{kj})^2}{\sigma_{kj}^2} \right)} \quad (2)$$

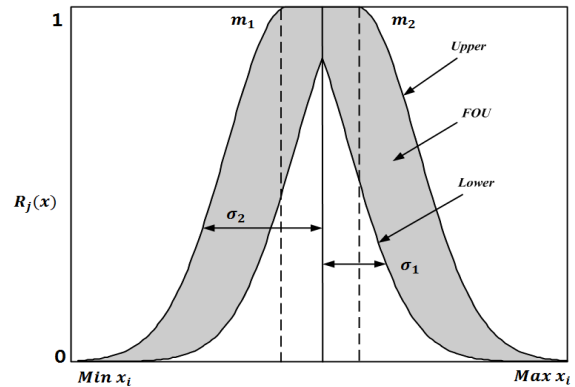


그림 3 은닉층의 Type-2 활성화함수

Fig. 3 Type-2 Activation function in Hidden layer

Footprint of Uncertain(FOU)의 영역은 $\sigma_1, \sigma_2, m_1, m_2$ 의 값에 따라 결정된다. σ 는 표준편차, m 은 활성화함수의 중심점을 나타내고, $\sigma_1, \sigma_2, m_1, m_2$ 은 식 (3)~(6)와 같이 표현된다. 여기서 α 값

($0 < \alpha < 1$)에 따라 FOU영역이 결정되고 최종적으로 출력에 영향을 미친다. α 값은 경험에 의해 선택하거나 최적화 알고리즘을 통해 최적의 값을 찾을 수 있다. 본 연구에서는 사용자 경험에 의해 선택 되었다.

$$\sigma_1 = \sigma - (\sigma \times \alpha) \tag{3}$$

$$\sigma_2 = \sigma + (\sigma \times \alpha) \tag{4}$$

$$m_1 = m - (m \times \alpha) \tag{5}$$

$$m_2 = m + (m \times \alpha) \tag{6}$$

연결가중치는 1차 선형식으로 구성하였고, 식 (7)과 식 (8)과 같이 y_l 과 y_r 로 나누어 표현한다. 여기서, $j(j=1, \dots, h)$ 는 은닉층 노드 수를 나타내고, $i(i=1, \dots, k)$ 는 입력변수의 수를 나타낸다. a_0^j 와 a_i^j 는 연결가중치의 파라미터 계수를 나타내며, s_0^j 와 s_i^j 는 y_l 과 y_r 사이의 파라미터 계수의 간격을 나타낸다. 모델의 최종 출력식은 식 (9)이며, y_l 과 y_r 의 평균값으로 구해진다. 그리고 기존의 Type-1 방사형 기저함수 신경회로망은 최소자승법(LSE: Least Square Estimation) 또는 가중최소자승법(WLSE: Weighted Least Square Estimation)을 사용하여 파라미터 계수를 구하였지만, Type-2 방사형 기저함수 신경회로망은 모델의 특성상 최소자승법 및 가중최소자승법을 사용할 수 없기 때문에 BP (Back-Propagation)를 사용하여 파라미터 계수를 구한다. 본 연구에서는 연결가중치의 초기 값을 랜덤하게 생성하지 않고, 기존의 Type-1 방사형 기저함수 신경회로망에서 구한 연결가중치를 초기 값으로 설정하였다.

$$y_l^j = a_0^j - s_0^j + \sum_{i=1}^k a_i^j x_i - \sum_{i=1}^k s_i^j |x_i| \tag{7}$$

$$y_r^j = a_0^j + s_0^j + \sum_{i=1}^k a_i^j x_i + \sum_{i=1}^k s_i^j |x_i| \tag{8}$$

$$Y = \frac{y_r + y_l}{2} \tag{9}$$

3.2 오류역전파 알고리즘(Back-Propagation)

오류역전파 알고리즘은 실제출력 y 와 모델의 최종출력 \hat{y} 의 오차가 최소가 되도록 연결가중치를 조절하는 학습방법이다[6, 7]. 식 (10)은 오차에 관한 식이다.

$$E_p = \frac{1}{2} (y_p - \hat{y}_p)^2 \tag{10}$$

여기서 E_p 는 p 번째 데이터에 대한 모델의 오차이며, y_p 는 p 번째 입력에 대한 원 출력이다. 그리고 \hat{y}_p 는 p 번째 입력에 대한 추론된 모델의 출력이다. 학습을 통한 새로운 파라미터는 식 (11),(12)와 같고, a 는 연결 가중치, η 는 학습률을 나타낸다. 학습률은 오류역전파 알고리즘의 수렴 속도를 조절할 수 있는 값으로 중요한 요소가 되며, 학습률에 따라 성능에도 영향을 미친다.

$$a_{ji}^l(t+1) = a_{ji}^l(t) + \eta^l \cdot \Delta a_{ji}^l \tag{11}$$

$$a_{ji}^r(t+1) = a_{ji}^r(t) + \eta^r \cdot \Delta a_{ji}^r \tag{12}$$

여기서, Δa_{ji}^l 과 Δa_{ji}^r 을 구하기 위해 식 (13),(14)와 같이 오차를 연결가중치로 미분한다.

$$\Delta a_{ji}^l = - \frac{\partial E_p}{\partial a_{ji}^l} = - \frac{\partial E_p}{\partial y} \cdot \frac{\partial \hat{y}}{\partial y^l} \cdot \frac{\partial y^l}{\partial w_{ji}^l} \cdot \frac{\partial w_{ji}^l}{\partial a_{ji}^l} \tag{13}$$

$$\Delta a_{ji}^r = - \frac{\partial E_p}{\partial a_{ji}^r} = - \frac{\partial E_p}{\partial y} \cdot \frac{\partial \hat{y}}{\partial y^r} \cdot \frac{\partial y^r}{\partial w_{ji}^r} \cdot \frac{\partial w_{ji}^r}{\partial a_{ji}^r} \tag{14}$$

3.3 KM 알고리즘을 통한 Type Reduction

제안된 Type-2 방사형 기저함수 신경회로망의 최종 출력은 Type-2 형태이기 때문에 Type-1 형태로 바꿔주는 것이 필요하다. 은닉층과 출력층 사이에서 Karnik and Mendel(KM) 알고리즘은 Type-2 형태를 Type-1 형태로 바꿔주는 Type Reduction 역할을 한다. KM 알고리즘의 연산과정은 다음과 같이 y_l 과 y_r 로 나누어 설명 할 수 있다.

- y_l 을 구하기 위한 KM 알고리즘

[Step 1] y_l^j 을 $y_l^1 < y_l^2 < \dots < y_l^h$ 와 같이 오름차순으로 정렬한다. 마찬가지로 정렬된 순서를 기준으로 *Upper*와 *Lower* 적합도를 다시 정렬한다.

[Step 2] *Upper*와 *Lower*의 적합도의 평균을 구하여 Type-1 형태의 적합도로 환산한다. 계산된 적합도 $R^j(x)$ 와 y_l^j 을 이용하여 최종 출력 y_l^j 을 계산한다.

$$R^j(x) = \frac{R_j(x) + \bar{R}_j(x)}{2} \tag{15}$$

$$y_l^j = \frac{R^j(x) \times y_l^j}{\sum_{j=1}^h R^j(x)} \tag{16}$$

[Step 3] 다음 식을 만족하는 스위칭 포인트 $p(1 \leq p < h-1)$ 를 찾는다.

$$y_l^p \leq y_l^j \leq y_l^{p+1} \tag{17}$$

[Step 4] 스위칭 포인트를 기준으로 *Upper*와 *Lower* 적합도의 위치를 서로 바꾼다. 바꾼 후의 적합도를 이용하여 다시 출력을 구하고, 그 출력을 y_l^j 으로 한다.

$$R_i^j(x) = \begin{cases} \bar{R}_j(x), & j \leq p \\ \underline{R}_j(x), & j > p \end{cases} \tag{18}$$

$$y_i'' = \frac{R_i^j(x) \times y_r^j}{\sum_{j=1}^h R_i^j(x)} \quad (19)$$

[Step 5] $y_i' = y_i''$ 이 같으면 y_i'' 이 최종 출력이 되고 알고리즘을 종료한다. 같지 않으면 $y_i' = y_i''$ 을 놓고 [Step 3]으로 이동하여 알고리즘을 반복 수행한다.

- y_r 을 구하기 위한 KM 알고리즘

[Step 1] y_r^j 을 $y_r^1 < y_r^2 < \dots < y_r^h$ 와 같이 오름차순으로 정렬한다. 마찬가지로 정렬된 순서를 기준으로 Upper와 Lower 적합도를 다시 정렬한다.

[Step 2] Upper와 Lower의 적합도의 평균을 구하여 Type-1 형태의 적합도로 환산한다. 계산된 적합도 $R^j(x)$ 와 y_r^j 을 이용하여 최종 출력 y_i' 을 계산한다. ($R^j(x)$ 식은 식 (15)와 동일)

$$y_i' = \frac{R^j(x) \times y_r^j}{\sum_{j=1}^h R^j(x)} \quad (20)$$

[Step 3] 다음 식을 만족하는 스위칭 포인트 $p (1 \leq p < h - 1)$ 를 찾는다.

$$y_r^p \leq y_i' \leq y_r^{p+1} \quad (21)$$

[Step 4] 스위칭 포인트를 기준으로 Upper와 Lower 적합도의 위치를 서로 바꾼다. 바꾼 후의 적합도를 이용하여 다시 출력을 구하고, 그 출력을 y_i'' 으로 한다.

$$R_i^j(x) = \begin{cases} \underline{R}_i^j(x), & j \leq p \\ \overline{R}_i^j(x), & j > p \end{cases} \quad (22)$$

$$y_i'' = \frac{R_i^j(x) \times y_r^j}{\sum_{j=1}^h R_i^j(x)} \quad (23)$$

[Step 5] $y_i' = y_i''$ 이 같으면 y_i'' 이 최종 출력이 되고 알고리즘을 종료한다. 같지 않으면 $y_i' = y_i''$ 을 놓고 [Step 3]으로 이 동하여 알고리즘을 반복 수행한다.

KM 알고리즘을 통해 최종 출력 y_i 과 y_r 을 계산한 후, 출력층에서 y_i 과 y_r 의 평균을 모델의 최종 출력으로 결정한다. Type-1 방식형 기저함수 신경회로망의 출력층에서는 출력의 합을 통해 모델의 최종 출력을 구하지만 제안된 Type-2 방식형 기저함수 신경회로망의 출력층에서는 y_i 과 y_r 의 평균을 이용한다는 차이점

이 있다[4].

4. 제안된 활성오니 공정 시스템의 구조

4장에서는 제안된 활성오니 공정 시스템의 구조에 대해 설명한다. 구조는 그림 4와 같이 학습 모델과 테스트 모델로 나누어져 있다. 제안된 Type-2 방식형 기저함수 신경회로망을 이용하여 활성오니 공정을 위한 학습 모델을 구축하고, 테스트 데이터의 방류 수질을 예측한다. 그리고 최종 출력이 방류 수질 법적 기준치에 적합한지를 판단한다.

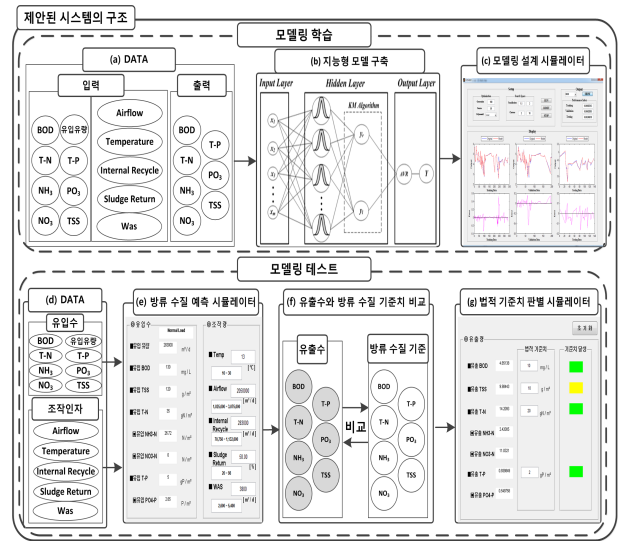


그림 4 제안된 시스템의 구조

Fig. 4 Architecture of proposed system

4.1 활성오니 공정을 위한 학습 모델

그림 4의 (a)~(c)는 활성오니 공정을 위한 학습 모델을 나타낸다. 먼저 (a)는 학습 모델의 입력과 출력을 나타낸다. 입력은 활성오니 공정에 많은 영향을 미치는 수질 인자와 조작 인자 측면으로 나누어 선정한다. 수질 인자는 방류 수질 기준치에 따라 유입유량, BOD, TSS, T-N, T-P, NO3, NH3, PO4를 선정하고, 조작 인자는 활성오니 공정의 조작 과정에 따라 Temp, Airflow, Internal Recycle, Sludge Return, Was를 선정한다. 그리고 조작 인자를 통해 변화되는 수질인자를 출력으로 선정한다. 입력과 출력을 선정한 후, 활성오니 공정의 분석계를 통해 수질 인자와 조작 인자 데이터를 취득하고 (b)와 같이 제안된 Type-2 방식형 기저함수 신경회로망과 KM알고리즘을 이용하여 활성오니 공정을 위한 지능형 학습 모델을 구축한다. 마지막으로 지능형 모델을 통해 하수처리 데이터를 학습시키고, (c)와 같이 학습 시뮬레이터를 제작하여 실제출력과 모델출력을 그리고 오차를 그래프로 표기한다.

4.2 유출수 예측 및 법적 기준치 판별을 위한 테스트 모델

유출수 예측 및 법적 기준치 판별을 위한 테스트 모델은 그림 4의 (d)~(g)와 같이 나타낸다. (d)는 테스트 데이터를 나타내고 (e)는 제안된 Type-2 방사형 기저함수 신경회로망의 구조가 내포되어 있는 유출수 예측 시뮬레이터이다. 테스트 데이터 입력 시 학습 모델에서 구한 파라미터와 예측 시뮬레이터를 이용하여 테스트 데이터의 최종 출력 BOD, TSS, T-N, T-P, NO₃, NH₃, PO₄를 예측하고, 이를 (f)와 같이 모델의 유출수와 방류 수질 법적 기준치와 비교한다. 마지막으로 (g)와 같은 판단 시뮬레이터를 통해 모델 출력의 결과가 기준치의 95% 이하이면 녹색으로 표시하고, 95%~100% 사이는 황색, 기준치를 초과하면 적색으로 표시하여 나타낸다. 녹색과 황색은 방류를 해도 무방한 상태이지만, 기준치를 초과한 적색은 물을 방류하기에 부적합한 상태로 (d)에서 조작인자의 값을 변경시켜 유출수를 조절해야 한다.

5. 시뮬레이션 및 결과 고찰

5.1 실험의 전체 개요

본 논문에서는 불확실한 정보와 외란이 포함되어 있는 입력 정보에 대한 Type-1 방사형 기저함수 신경회로망의 성능을 보완하기 위해 Type-2 방사형 기저함수 신경회로망을 이용하여 활성오니 공정을 모델링 한다. 제안된 Type-2 방사형 기저함수 신경회로망과 KM알고리즘을 이용하여 활성오니 공정을 모델링하고, 그에 따른 시스템 성능을 평가한다. 성능 평가는 기존의 Type-1 방사형 기저함수 신경회로망과 제안된 Type-2 방사형 기저함수 신경회로망의 성능을 비교하였고, 실제출력과 Type-1 그리고 Type-2 방사형 기저함수 신경회로망 모델의 출력을 그래프로 나타내어 비교하여 나타내었다. 마지막으로 활성오니 공정을 위한 학습 시뮬레이터 및 최종출력이 방류 수질 기준치에 적합한지 판단하는 시뮬레이터를 제작하였다.

5.2 데이터 구성 및 파라미터 설정

데이터 구성은 활성오니 공정의 주요인자 선정에 의해 구성하였다. 수질 인자 측면과 조작 인자 측면에서 Q, BOD, TSS, T-N, T-P, NH₃, NO₃, PO₄, Temp, Airflow, Internal Recycle, Sludge Return, Was 총 13개를 입력 인자로 구성하고, 방류수 수질 기준에 따라 BOD, TSS, T-N, T-P, NH₃, NO₃, PO₄ 총 7개를 출력 인자로 구성하였지만, 본 연구의 실험에서 취득한 입력 인자 13개 중에서 Q와 NO₃의 값에 변화가 없이 일정하여 입력 인자에서 제외하였다. 최종적으로 11입력 7출력으로 데이터 구성을 하였다. 실험을 위한 데이터는 샘플링 데이터로 총 674개로 구성 되어 있으며, 최적화 알고리즘을 사용하지 않았기 때문에 검증데이터 없이 학습 데이터 337개, 테스트 데이터 337개로 나누었다. 표 3은 초기 파라미터 설정값을 나타내고, 표 4는 실험에 사용된 샘플링 데이터의 범위이다. 데이터는 Min-Max 방법을 이용하여 0~1 사이의 값으로 정규화하여 사용하였다.

표 2 활성오니 공정의 데이터 구성

Table 2 Data set of Activated sludge process

입 력		출 력
수질 인자	조작 인자	수질 인자
BOD	Temp	BOD
TSS	Airflow	TSS
T-N	Internal Recycle	T-N
T-P	Sludge Return	T-P
NH ₃	Was	NH ₃
PO ₄		NO ₃

표 3 초기 파라미터 설정

Table 3 Set of Initial parameters

Back-Propagation	
No. of Iterations	300
Weighted Learning(η)	0.001
FOU Range(α)	0.01

표 4 샘플링 데이터의 범위

Table 4 Ranges of Sampling data

Data	Range
BOD	[70 190]
TSS	[70 140]
T-N	[25 45]
T-P	[20 34]
NH ₃	[3 7]
PO ₄	[1.73 3.81]
Temp	[11 30]
Airflow	[1166666 4200000]
Internal Recycle	[124348 1132000]
Sludge Return	[0.3 1.0]
Was	[2098 4900]

연결가중치 학습률의 경우 파라미터를 구할 때 중요한 요소로 작용한다. 그리고 FOU 영역은 데이터, 노드수마다 최적의 값이 다르다. 본 연구에서는 최적화 알고리즘을 사용하지 않았기 때문에 FOU 영역과 연결가중치 학습률을 사용자 경험에 의해 초기 값을 설정 하였다. 또한 성능지수가 연속적으로 5번 감소하면 학습률을 10% 증가시키고, 반대로 증가하면 학습률을 10% 감소시키는 Heuristic rule 방법을 이용하여 연결 가중치 학습률을 고정시키지 않고 변화하도록 설계하였다. Heuristic rule 방법에서 연속적으로 변화하는 횟수도 사용자의 경험에 의하여 횟수를 5번으로 지정하였다.

5.3 활성오니 공정 모델의 Type-1, Type-2 방사형 기저함수 신경회로망 성능비교

표 5 실험에 사용된 모델

Table 5 Models used in the experiment

Models		
Type-1 RBFNNs	은닉층	Min-Max
	연결가중치 동정	LSE
Type-2 RBFNNs	은닉층	Min-Max
	연결가중치 동정	BP

제안된 Type-2 방사형 기저함수 신경회로망의 성능을 평가하기 위해 기존의 Type-1 방사형 기저함수 신경회로망의 성능과 비교하였다. 표 5는 실험에 사용된 모델을 나타낸다. 은닉층은 Min-Max 방법을 이용하여 조건을 동일하게 하였다. 하지만 연결가중치 학습에서 제안된 Type-2 방사형 기저함수 신경회로망은 LSE 사용이 불가능하기 때문에 BP를 사용하였다. 표 6은 Type-1, Type-2 방사형 기저함수 신경회로망의 성능지수를 나타내는 표이다. 성능지수는 Mean Square Error(MSE)를 사용하여 나타내었으며 식 (24)와 같다. N은 데이터 수를 나타내고, y 는 실제출력 그리고 \hat{y} 는 모델 출력을 나타낸다. PI는 학습데이터에 관한 MSE 성능지수를 나타내고, EPI는 테스트데이터에 관한 MSE 성능지수를 나타낸다.

$$MSE = \frac{1}{N} \sum_{q=1}^N (y - \hat{y})^2 \quad (24)$$


표 6 Type-1, Type-2 방사형 기저함수 신경회로망 성능 비교

Table 6 Comparison of performance Type-1 RBFNNs and Type-2 RBFNNs

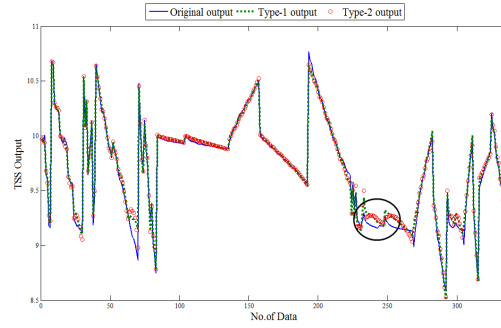
	Type-1 RBFNNs		Type-2 RBFNNs	
	PI	EPI	PI	EPI
BOD	0.008496	0.002151	0.007885	0.002236
TSS	0.012885	0.002763	0.011244	0.002713
T-N	0.057795	0.043002	0.046577	0.034212
NH3	0.093668	0.098365	0.079676	0.088491
NO3	0.107818	0.081826	0.095208	0.080982
T-P	0.053296	0.045956	0.047006	0.043308
PO4	0.066311	0.057211	0.058619	0.054334

5.4 활성오니 공정 모델 출력과 실제 출력의 비교


실제출력과 제안된 Type-2 방사형 기저함수 신경회로망의 출력 그리고 기존의 Type-1 방사형 기저함수 신경회로망의 출력을 그래프로 비교하여 설명한다. 성능지수는 Type-1과 Type-2의 차이가 크지 않지만 그림 5와 같이 출력 그래프를 살펴볼 때, 비




(a) BOD




(b) TSS




(c) T-N




(d) NH3



(e) NO3



(f) T-P



(g) PO4

그림 5 실제출력과 모델출력의 비교

Fig. 5 Comparison of real output and model output

선형성이 강하고 변화가 심하게 일어나는 부분(동그라미 부분)에서 견실성이 강한 Type-2 모델이 Type-1 모델보다 오차를 어느 정도 감소시키는 효과를 확인 할 수 있었다. 하수처리 공정에서는 작은 오차에도 방류 수질 기준에 적합한지 안한지 결정될 수 있기 때문에 오차를 조금이라도 줄이는 것이 매우 중요하다. 실험에 사용된 하수처리 샘플링 데이터처럼 비선형성이 강한 데이터에는 Type-2 모델이 Type-1 모델보다 효과적이다. 그리고 실험에 사용된 데이터에서 NO3의 정보가 부족하여 다른 출력에 비해 실제 출력과 오차가 많음을 확인 할 수 있었다.

5.5 활성오니 공정 시뮬레이터

본 연구에서는 하수처리 시스템의 일부인 활성오니 공정 시뮬레이터를 제작하였다. 제작된 시뮬레이터는 학습 시뮬레이터와 방류 수질 법적 기준치에 적합한지를 판단하는 시뮬레이터로 나누어져 있다. 그림 6은 제작된 활성오니 공정 학습 시뮬레이터이다. 학습 시뮬레이터에는 제안된 Type-2 방사형 기저함수 신경 회로망 구조가 내포되어 있다. FOU, 학습률 그리고 BP의 학습 반복 횟수와 같은 초기 파라미터는 사용자에게 의해 설정할 수 있다. 시뮬레이터 화면에는 실제출력과 제안된 Type-2 모델 출력을 그래프로 나타내었고, 실제출력과 모델출력간의 오차와 모델의 성능지수도 나타내었다.

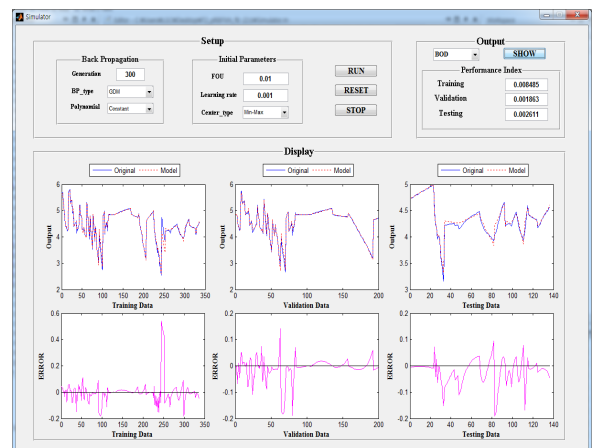


그림 6 활성오니 공정 시뮬레이터

Fig. 6 Simulator of activated sludge process

그림 7은 최종적으로 나오는 모델 출력이 방류 수질 기준 값에 적합한지를 판단하는 시뮬레이터이다. 시뮬레이터는 유입수, 조작량, 유출량, 설정 부분으로 구성된다. 유입수는 수질인자를 표시하고, 조작량은 조작인자를 표시한다. 그리고 유출량은 출력을 나타낸다. 모델 출력이 기준 값의 95% 이하이면 녹색으로 표시하고, 95%~ 100% 사이는 황색, 기준 값을 초과하면 적색으로

표시한다. 녹색의 경우 방류 수질 기준치에 적합하여 방류해도 무관한 상황이고, 황색은 방류 수질 기준치에 적합하지만 주의가 필요한 경우이다. 마지막으로 적색은 방류 수질 기준치에 적합하지 않아 방류할 수 없는 경우이며, 이때는 설정을 통해 조작량을 변경하여 유출수가 기준치에 적합할 수 있도록 변경해주어야 한다.



그림 7 방류 수질 예측 시뮬레이터
 Fig. 7 Prediction simulator of effluence water quality

6. 결 론

하수처리 데이터 특성상 외란과 불확실한 정보가 많기 때문에 본 연구에서는 하수처리 공정을 위한 Type-2 방사형 기저함수 신경회로망을 제안하였다. 성능 확인을 위해 기존의 Type-1 방사형 기저함수 신경회로망 모델과 성능을 비교하였고, 실제 출력과 Type-1 모델 출력, Type-2 모델 출력을 그래프로 나타내어 비교 설명 하였다. 실험을 통해 제안된 Type-2 방사형 기저함수 신경회로망이 BOD를 제외한 TSS, T-N, NH3, NO3, T-P, PO4에서 Type-1 방사형 기저함수 신경회로망 모델 보다 성능이 조금 더 좋은 것을 확인할 수 있었다. 또한 그래프를 통해 비선형성이 강하고 오차가 심한 부분에서 Type-1 방사형 기저함수 신경회로망 보다 견실성이 강한 Type-2 방사형 기저함수 신경회로망이 오차를 조금 더 줄여주는 것을 확인할 수 있었다. 본 연구의 실험에서 사용된 데이터는 학습 데이터 337개, 테스트 데이터 337개로 비교적 적은 데이터였지만, Type-2 방사형 기저함수 신경회로망 모델의 효과를 확인할 수 있었다. 그렇기 때문에 더 많은 데이터를 이용하였을 때 제안된 Type-2 모델이 좋은 성능을 보일 것이라 생각된다. 마지막으로 Type-2 방사형 기저함수 신경회로망의 구조가 내포되어 있는 학습 시뮬레이터와 모델의 출력이 방류 수질 기준 값에 적합하지를 판단하는 시뮬레이터를 제작하였다. 모델 출력이 방류 수질 법적 기준치에 95% 이하면 녹색으로 표현하고, 95%~ 100%는 황색, 기준치를 초과하면 적색으로 나타내었다.

감사의 글

본 연구는 경기도의 경기도지역협력연구센터사업의 일환으로 수행하였음[GRRC 수원2015-B2, U-city 보안감시 기술협력센터] 그리고 미래창조과학부의 정보통신방송연구개발사업[과제번호:I0144-14-1016]과 창조비타민 프로젝트의 일환으로 수행하였음.

References

- [1] S. K. Oh, W. Pedrycz, B. J. Park, "Polynomial-based Radial Basis Function Neural Net works realized with the Aid of Particle Swarm Optimization," Fuzzy Sets and Systems, Vol. 163, pp. 54-77, 2011.
- [2] S-K. Oh, W-D. Kim, and W. Pedrycz,"Polynomial based radial basis function neural networks (P-RBFNNs) realized with the aid of particle swarm optimization," Fuzzy Sets and Systems, Vol. 163, No. 1, pp. 54-77, 2011.
- [3] A. Sharifian, S. Sharifian "A new power system transient stability assessment method based on Type-2 fuzzy neural network estimation" International Journal of Electrical Power & Energy Systems, Vol 64, pp. 71-87, January 2014.
- [4] P. Melin, O. Castillo "A review on the applications of type-2 fuzzy logic in classification and pattern recognition" Expert Systems with Applications, Vol 40, Issue 13, pp. 5413-5423, 1 October 2013.
- [5] Janusz T. Starczewski "Centroid of triangular and Gaussian type-2 fuzzy sets" Information Sciences, Vol 280, pp 289-306, 1 October 2014.
- [6] F. Gaxiola, P. Melin, F. Valdez, Oscar Castillo "Interval type-2 fuzzy weight adjustment for backpropagation neural networks with application in time series prediction" Information Sciences, Vol 260, pp 1-14, 1 March 2014.
- [7] J. Yang, W. Yang, W. Wu "A remark on the error-backpropagation learning algorithm for spiking neural networks" Applied Mathematics Letters, Vol 25, pp 1118-1120, Issue 8 August 2012.
- [8] M. Revilla, J. Viguri, B. Galán "Simulation and Optimization of Biofilm Activated Sludge Process for the Biological Treatment of Effluents from Cellulose and Viscose Industry" Computer Aided Chemical Engineering, Vol 33, pp 1117-1122, 2014.
- [9] T. Yang, W. Qiu, Y. Ma, M. Chadli, L. Zhang "Fuzzy model-based predictive control of dissolved oxygen in

activated sludge processes" Neurocomputing, Vol 136, pp 88-95, 20 July 2014.

- [10] J. Moya, C. Huiliñir, K. Peredo, E. Aspé, M. Roeckel "Modeling of simultaneous denitrification - Anaerobic digestion - Organic matter aerobic oxidation and nitrification in an anoxic - anaerobic - aerobic compact filter reactor" Journal of Biotechnology, Vol 160, pp 176-188, Issues 3 - 4, 31 August 2012.

저 자 소 개



이 승 철 (Seung-Cheol Lee)

2014년 : 수원대학교 전기공학과 졸업.
2014년~현재 : 동 대학원 석사과정
관심분야 : 뉴럴 네트워크, 퍼지 추론 시스템, 패턴 분류
Phone : +82-31-222-6544
E-mail : lsc225@suwon.ac.kr



권 학 주 (Hak-Joo Kwun)

2014년 : 수원대학교 전기공학과 석사 졸업
2014년~현재 : 동 대학원 박사과정
관심분야 : 뉴럴 네트워크, 퍼지 추론 시스템, 패턴 분류
Phone : +82-31-222-6544
E-mail : uplude@suwon.ac.kr



오 성 권 (Sung-Kwun Oh)

1981년 : 연세대학교 전기공학과 공학사.
1983년~1989년 : 금성산전연구소 (선임연구원). 1993년 : 연세대학교 전기공학과 공학박사. 1996년~1997년 : 캐나다 Manitoba 대학 전기 및 컴퓨터 공학과 Post-Doc.
1993년~2004년 : 원광대학교 전기전자 및 정보공학부 교수. 2005년~현재 : 수원대학교 전기공학과 교수.
2002년~현재 : 대한전기학회, 퍼지 및 지능시스템학회 편집위원. 2013년~현재 : Information Sciences 편집위원
관심분야 : 퍼지 시스템, 퍼지-뉴럴 네트워크, 자동화 시스템, 고급 Computational Intelligence, 지능제어 등.
Phone : +82-31-229-8162
E-mail : ohsk@suwon.ac.kr