

실규모 하수처리공정에서 동력학적 동특성에 기반한 인공지능 모델링 및 예측기법

Artificial Neural Network Modeling and Prediction Based on Hydraulic Characteristics in a Full-scale Wastewater Treatment Plant

김민한, 유창규*
(Min-Han Kim and ChangKyoo Yoo)

Abstract: The established mathematical modeling methods have limitation to know the hydraulic characteristics at the wastewater treatment plant which are complex and nonlinear systems. So, an artificial neural network (ANN) model based on hydraulic characteristics is applied for modeling wastewater quality of a full-scale wastewater treatment plant using DNR (Daewoo nutrient removal) process. ANN was trained using data which are influents (TSS, BOD, COD, TN, TP) and effluents (COD, TN, TP) components in a year, and predicted the effluent results based on the training. To raise the efficiency of prediction, inputs of ANN are added the influent and effluent information that are in yesterday and the day before yesterday. The results of training data tend to have high accuracy between real value and predicted value, but test data tend to have lower accuracy. However, the more hydraulic characteristics are considered, the results become more accuracy.

Keywords: ANN (Artificial Neural Network), DNR process, hydraulic characteristics, nonlinear modeling

I. 서론

하수처리공정에서 오염물질의 제거 효율을 높이기 위하여 많은 연구가 진행되고 있으나, 실질적으로 실제 공정을 대상으로 직접적인 실험을 하는 데에는 경제적, 시/공간적인 제약이 따른다. 이러한 한계를 극복하기 위하여 모델링 기법이 많이 사용되고 있다[1-3]. 기존의 모델링 연구를 살펴보면, 수학적 계산에 의한 모델링 연구로서 이론적인 반응식을 바탕으로 하여 운전변수와 매개변수 같은 공정 변수들에 대한 반응 결과를 제시한 연구와 실험 결과를 바탕으로 모델식을 선정하고 여러 조건에서의 결과 예측 및 최적화 등의 연구를 들 수 있다[1,4]. 이러한 기존 연구는 복잡한 실험과정을 거치지 않고도 하수처리공정에서 발생하는 여러 상황에 대한 전산모사를 가능하게 하지만, 공정변수의 시변성에 따른 동특성을 정확히 반영하는 데에는 한계가 있다. 특히, 일반적으로 하수처리공정에서의 유입수는 수량, 수질의 변동이 크고 불규칙하다. 또한 처리과정은 생물학적, 물리·화학적인 처리로써 각각의 반응들이 복잡하게 서로 연계되어 있어 수학적 모델로는 그 현상을 정확하게 나타내기가 어렵거나 수학적 모델링의 경우 모델링에 많은 시간이 필요하며 각 처리장의 적합한 모델 변수를 보정해야 하는 단점이 있다.

따라서 인공신경망기법 (artificial neural network)을 사용하여 이와 같은 단점을 보완하고자 하였으며, 인공신경망기법은 인간의 신경체계와 유사한 성능특성을 갖는 일종의 정보처리 시스템으로 과거의 데이터를 통한 학습을 통하여 예측이 가능하고 공정의 비선형적인 특성을 잘 모사할 수 있어 최근

환경모델링 분야에서의 문제 해결에 많이 사용되고 있다[4]. 하수처리공정 모델링에 있어서 인공신경망기법은 수학적 모델에 비해 모델링에 소요하는 시간이 줄어들고, 새로운 조건이 생기면 해당 조건의 데이터를 다시 학습시켜 주면 되므로 융통성이 뛰어나다는 장점이 있다[5].

기존 연구에서 이미 Hack and Kohne [6], Pai [7] 등은 인공신경망 기법을 적용하여 하폐수처리시스템의 공정 예측에 대한 연구가 이루어졌다. 수집된 데이터를 바탕으로 학습데이터를 사용하여 인공신경망의 학습을 진행하고, 테스트 데이터에서의 예측값과 실제값을 비교하는 방법으로 이루어졌다. Martinez and Wilson [8], Lee [9] 등은 인공신경망 기법만으로는 시변성이 많고 측정 오차가 많은 데이터에는 부족하기 때문에 혼합 인공신경망구조를 제안하였고 수식기반 모델과 인공신경망 기법을 함께 사용하여 모델링의 정확도를 향상시켰다.

본 연구에서는 실규모 하수처리장의 유입수와 유출수에 대한 데이터를 바탕으로 처리공정의 유출 오염물질의 농도와 제거율을 인공신경망의 학습을 통해 예측하는 인공지능 모델의 개발을 목표로 하였다. 특히, 시계열 데이터의 연관성이 크고 시변적이며 불규칙적인 특징을 갖는 하수처리 시스템에 적합하고, 과거 데이터를 바탕으로 학습을 통한 인공지능 모델 구성을 위해 하루 전, 이틀 전의 유입/유출 정보를 인공신경망의 입력에 추가하여 동특성을 고려한 신경망 구조를 설정하고 분석을 실시하였다.

II. 인공신경망

인공신경망이란 인간의 신경체계와 유사한 특성을 갖는 일종의 정보처리시스템으로서 신호처리, 제어, 패턴인식, 음성·문자인식, 예측 등의 분야에서 널리 응용되고 있다. 인간의 신경체계는 뉴런이라는 기본 단위가 병렬적으로 연결된 형태로 구성되어 있으며, 인공신경망은 이러한 뉴런의 구

* 책임저자(Corresponding Author)

논문접수: 2008. 11. 17., 채택확정: 2009. 2. 9.

김민한, 유창규: 경희대학교 환경응용과학과

(werver0311@khu.ac.kr/ckyyoo@khu.ac.kr)

※ 본 연구는 Brain Korea 21프로젝트, 한국학술진흥재단(KRF-2007-331-D00089), 서울시정개발연구원의 산학협력과제(CS070160)의 지원을 받아 수행되었음.

조를 단순화한 인공뉴런이 병렬적으로 연결되어 있는 형태이다. 인공신경망의 종류는 크게 단층 전방향 신경망, 다층 전방향 신경망, 순환 신경망, 격자 신경망으로 나뉜다[10,11].

본 연구에서 사용한 신경망은 다층 전방향 신경망으로써, 하나 이상의 은닉층(hidden layer)이 존재함으로써 선형적으로 분리 불가능한 문제를 비선형적으로 해결할 수 있게 해주며, 복잡한 시스템의 모델링이 가능하다. 네트워크의 각 은닉층은 같은 유형의 전달함수를 가지며, 출력층의 전달함수는 시그모이드 또는 선형을 사용한다. 시그모이드(sigmoid) 형의 뉴런에 관한 출력은 쌍곡선 탄젠트인 경우 [-1,1]로 제한되고, 로그 시그모이드의 경우에는 [0,1]로 제한된다. 선형 출력의 뉴런은 제한을 받지 않으며, 어떠한 크기의 값도 출력할 수 있다. 은닉층에 어느 정도의 뉴런들이 필요하고, 바람직한 오차의 크기를 갖는 가중 행렬이 무엇인지는 규명되지 않았지만, 네트워크의 크기는 함수 및 관심 영역의 복잡성에 종속되므로 네트워크의 학습은 계산적으로 조절할 수 있다[4,9-11]. 다층 전방향 신경망에서 신호가 출력되는 과정은 다음과 같다. 입력층의 신호는 입력층과 첫번째 은닉층 사이의 연결강도에 의해 가중합되어 출력값으로 나가게 된다. 첫번째 은닉층의 출력값은 첫번째 은닉층과 두번째 은닉층 사이의 연결강도에 의해 가중합되어 두번째 은닉층의 입력신호로 전달이 되고 이러한 과정이 출력층까지 반복되면 출력층에서 최종적으로 신경망의 출력값을 내보내게 된다[9,11].

학습은 입력층의 각 뉴런에 입력 패턴을 주면, 이 신호는 각 뉴런에서 변환되어 중간층에 전달되고 최후에 출력층에서 신호를 출력하게 된다. 이 출력값과 기대값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해나간다. 이렇게 훈련이 종료된 후에 실제 적용에 있어서는 전방향 계산만 사용된다[11,12].

그림 1은 일반적인 다층 신경망 구조를 나타내며, 뉴런이 갖는 입력과 가중치 벡터를 곱해서 더한 결과를 하나의 전달함수에 적용하는 방식으로 계산되는 처리요소로써, x_i , $i=1,2,\dots,n$ 는 대응되는 가중치 w_i 와 곱해지고, 또 다른 입력 1은 하나의 임계값 b 와 곱해져서 더해진다. 더해진 출력 net 을 네트워크 입력으로 일컬어지며, 식 (1)과 같이 전달함수 f 를 통과하여 뉴런 출력 y 를 생성한다[10,13].




그림 1. 다층 신경망의 구조.

Fig. 1. The structure of multi-layer neural network.

$$y = f(net) \tag{1}$$

$$net = \sum_{k=1}^n x_k w_k + b_k$$

여기서, n 은 입력층, 은닉층, 출력층의 뉴런의 개수, y 는 공정 출력, f 는 전달함수, w_k 는 신경망 가중치, b_k 는 임계값을 나타낸다.

실제 시스템의 입력과 출력과의 관계를 인공신경망을 통해서 모델링 하는 것은 인공신경망의 구조, 활성화함수, 그리고 학습 규칙에 의해 결정된다. 본 연구에서의 인공신경망 학습 규칙은 가장 많이 사용되고 있는 역전파 학습규칙(backpropagation learning rule)을 사용하였다. 역전파 학습규칙의 기본적인 알고리즘은 최급하강법(gradient descent method)을 사용하여 인공신경망에 의해 계산된 출력값과 목표값 차이의 제곱합을 최소화하는 가중치 벡터(w_k)를 계산하게 된다. 최급하강법의 단점인 국소최소점(local minimum)을 완화하기 위해 모멘텀 상수(momentum coefficient)를 포함하는 generalized delta rule을 사용하였다. Generalized delta rule의 모멘텀 항은 가중치의 변화가 국소 기울기 뿐만 아니라 최근의 가중치의 변화 방향에도 영향을 받게끔 하여 가중치의 학습이 국소최소점에 머무르게 되는 가능성을 완화시켜 준다.

역전파 훈련 기법을 적용하기 위한 고려사항으로는 데이터의 변화, 인공신경망의 구조, 훈련에 관한 측면으로 나눌 수 있다. 훈련의 속도를 증가시키기 위해 변수들을 일정 범위 내로 변환되어야 하고, 변수들의 측정단위가 다르기 때문에 실제값을 그대로 사용하였을 경우 각 변수들이 인공신경망에 미치는 영향이 서로 다르게 되어 학습시간이 오래 걸리기 때문에 가급적 같은 범위로 변환하는 것이 좋으며, 일반적으로 식 (2)를 사용하여 (-1,1) 범위로 변환 또는 정규화(normalize)된다.

$$X_i = \frac{(x_i - x_o)}{\delta x} \tag{2}$$

일반적으로 인공신경망의 구조는 은닉층의 수와 입력, 은닉층, 출력의 뉴런 수에 의해 결정된다. 은닉층의 수와 은닉 뉴런의 수에 따라 인공신경망의 성능이 크게 좌우되지만, 이를 결정하기 위한 명확한 방법은 알려진 것이 없으나, 많은 경험과 실험으로부터 하나 또는 두개의 은닉층을 사용하면

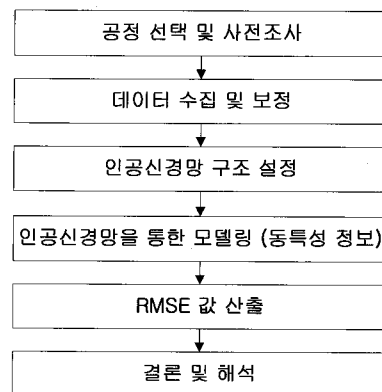


그림 2. 동특성 정보에 기초한 신경망 모델링 및 예측 순서도
Fig. 2. The procedure of neural network modeling and prediction based on hydraulics information.

비선형적인 시스템의 모델링에 충분하다고 알려져 있다[10].

본 연구에서는 다층 인공신경망 구조로 역전파 규칙을 사용하여 학습데이터에 의한 인공신경망의 학습과 테스트 데이터를 이용한 실제 적용에 의한 단계로 하수처리장 예측 모델링이 진행되었다.

III. 재료 및 방법

1. 실험 방법

그림 2는 본 논문에서 사용된 신경망 모델링 및 예측의 연구방법의 개략도를 나타낸 것이다. 첫 번째는 본 연구의 목적에 맞는 공정을 선택하고, 그에 대한 사전 조사가 필요하다. 본 연구에서는 실제 Daewoo Nutrient Removal (DNR)공정으로 운전 중인 경기도 N 시의 H-하수처리장을 선택하였다. 두 번째로, 데이터 수집은 H 하수처리장에서 2007년 3월 9일 ~ 2008년 2월 29일까지의 데이터를 수집하였으며, 유입수의 TSS, BOD, COD, TN, TP와 유출수의 COD, TN, TP를 사용하였다. 하지만 수집 기간의 모든 데이터가 존재하지 않았고 데이터의 유효성이 검증되지 않았기 때문에, 3 시그마 기법과 보간법을 사용하여 데이터의 이상치(outlier)를 제거하는 등의 보정과정을 통하여 데이터를 수집하였다.

세 번째로, 인공신경망 구조를 설정하고 인공신경망을 통한 모델링을 실시하였다. 이 때, 모든 데이터들을 -1과 1 사이의 값으로 정규화(normalize)하여 분석하였으며, 학습 데이터를 바탕으로 모델링을 학습시키고, 테스트 데이터를 이용하여 인공신경망 모델링의 정확성을 평가하였다. 또한 결과는 식(3)에 의해 추정된 농도값과 실측값과의 Root Mean Square Error (RMSE) 값을 사용하여 비교하였다.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n-1}} \quad (3)$$

하수처리장이 미생물에 많이 의존하므로 미생물의 온도영향을 고려하기 위해 계절별로 데이터를 분류한 사례 1과 시

표 1. 동특성에 따른 신경망 모델링의 4가지 연구.

Table 1. Four case studies of NN modeling incorporating hydraulics.

	Input	Output
CASE 1	X_t	Y_t
CASE 2-1	X_t	Y_t
CASE 2-2	X_t, X_{t-1}, Y_{t-1}	Y_t
CASE 2-3	$X_t, X_{t-1}, X_{t-2}, Y_{t-1}, Y_{t-2}$	Y_t




그림 3. 동력학적 특성을 고려한 신경망 모델.
Fig. 3. Neural network model based on hydraulic characteristic.

계열 모델링 목적의 사례 2로 크게 분류하였다. 사례 1과 사례 2의 2가지 경우에 대한 예측 모델링을 분석하였고, 각 사례연구의 구분은 다음과 같다.

- 사례 1 (계절별 영향을 고려)
 - 학습 데이터: 3, 5, 6, 8, 9, 11, 12, 2월
 - 테스트 데이터: 4, 7, 10, 1월
- 사례 2 (시계열 분석 목적)
 - 학습 데이터: 3 ~ 10월
 - 테스트 데이터: 11 ~ 2월

특히, 시계열 분석이 목적인 사례 2의 경우 사례 2-1, 2-2, 2-3으로 분류하여 분석하였는데, 사례 2-1의 경우 일반적인 시계열 분석을 나타냈고, 사례 2-2는 하루 전의 유입과 유출 데이터를 인공신경망의 입력에 포함하였고, 사례 2-3은 하루 전과 이틀 전의 유입과 유출 데이터를 입력에 포함시킴으로써 표 1과 같이 하수처리장의 동특성 정보를 반영하여 모델링 하였다. 즉, 인공신경망의 입력변수에 사례 2-1은 유입수의 5개 항목 (TSS, BOD, COD, TN, TP) 을 사용하였고, 사례 2-2는 하루 전의 유입 5개 항목, 3개의 유출수 항목 (COD, TN, TP)이 추가되어 13개 항목, 사례 2-3은 이틀 전의 유입, 유출수 항목이 추가되어 총 21개 항목이 사용되었고, 그림 3은 사례 2-3에서의 인공신경망 구조를 나타낸 것이다.

본 연구의 신경망 구조는 2개의 은닉층을 가지고 각각의 은닉층의 개수는 cross validation set의 RMSE를 최소화한 구조로 설정하였다. 즉, 각각의 사례연구에서 신경망 구조는 $I - H_1 - H_2 - O$ (I 는 사례연구마다의 입력변수 개수, H_1 과 H_2 는 각각의 은닉층 노드 수, O 는 출력변수 개수)의 구조를 가진다. 가중치벡터학습은 학습속도상수 (learning rate parameter, η)는 0.01, 모멘텀 상수 (momentum coefficient, α)는 1.0 을 사용하였고, 입력층과 출력층은 선형 전달함수 (linear transfer function), 2개의 은닉층은 hypertangential 함수를 사용하여 신경망 구조를 설정하였다.

2. 실험모 하수처리장

본 연구의 목적에 따라 실험모 하수처리장의 인공신경망 모델링 분석을 위해 경기도 N시의 H 하수처리장의 연평균 데이터를 사용하였다. 시설 용량은 총 43,000 m³/d 이고, 수처리 방식으로는 그림 4와 같이 1차 처리 (침전), 2차 처리 (DNR 공정), 3차 처리 (여과시설)로 이루어져 있다.

DNR 공정은 표준활성슬러지법을 근간으로 하여 포기조에 혐기조와 무산소조 조건을 추가함으로써 미생물의 특성을 이용하여 생물학적으로 질소 및 인을 동시에 처리할 수 있는 공법이다. 기존의 대표적인 활성슬러지 공정인 A₂O 공법은




그림 4. H-하수처리장의 도식도.
Fig. 4. The layout of H-wastewater treatment plant.

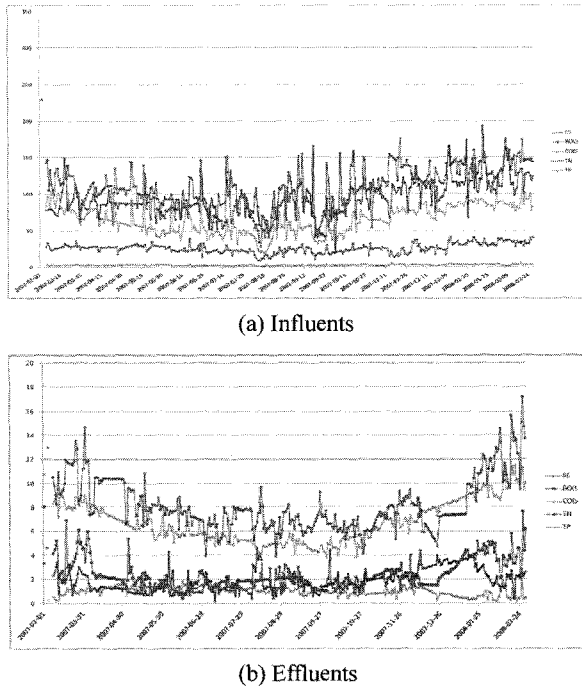


그림 5. H-하수처리장의 유입/유출의 시계열 데이터.
Fig. 5. Time series plot of influents and effluents in H- wastewater treatment plant.

표 2. H 하수처리장의 유입/유출 정상.
Table 2. The components of influent and effluents of H wastewater treatment plant.

		TSS	BOD	COD	TN	TP
Influent	Max.	98.22	103.68	64.76	25.58	2.67
	Min.	194.00	175.20	132.00	41.29	4.80
	Ave.	20.00	28.20	19.40	8.60	0.94
Effluent	Max.	1.87	2.36	6.73	8.18	1.00
	Min.	4.60	7.60	11.50	17.14	2.03
	Ave.	0.20	0.50	3.80	3.90	0.12

반송슬러지 내의 질산성 질소로 인한 혐기조에서 인 방출시 저해 영향을 많이 받아 인 제거율 뿐만 아니라 질소 및 유기물 제거율이 저조하고, MUCT (Modified University of Cape Town), VIP (Virginia Initiative Plant) 공법은 반송슬러지 내의 질산성 질소를 제거하기 위해 무산소조로 반송하여 탈질화한 후 내부반송을 통해 혐기조로 미생물을 공급하게 되는 데에 따른 내부 순환펌프의 추가 설치로 경제성 저하 뿐만 아니라 유지관리의 복잡성으로 적용상 어려운 단점이 있다. DNR 공법은 이러한 단점을 보완하기 위해 무산소의 슬러지 탈질조를 추가한 신공법으로 반송슬러지 내의 질산성 질소 제거 및 유지관리의 편리성을 도모하기 위하여 개발되었다[14].

본 연구에서는 인공신경망 프로그램으로 Matlab version 7.1을 사용하였고, 데이터의 변환 또는 정규화를 위해 premmx와 postmmx 함수를 사용하였으며, 인공신경망의 구성을 위해 neural network toolbox에 포함된 net 함수를 사용하였다[5]. 변수 결정을 위해 임의로 은닉층의 개수와 각 층의 node 개수를 변경하면서 validation이 포함된 학습데이터의 출력변수 중 가장 높은 정확성을 갖는 신경망 구조를 선정하였다.

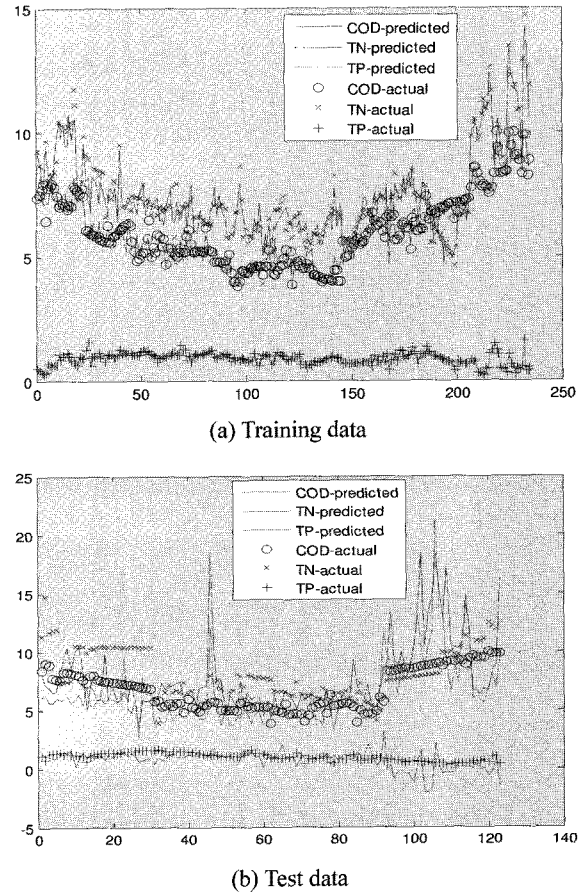



그림 6. 사례 1의 신경망모델링 결과.
Fig. 6. The NN modeling results of CASE 1.

IV. 결과 및 고찰

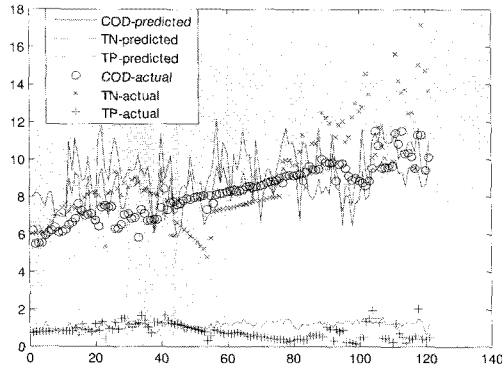
데이터 보정 작업을 걸쳐 H 하수처리장의 2007년 3월 9일 ~ 2008년 2월 29일의 데이터를 그림 5와 같이 나타내고, 표 2는 유입/유출수의 평균값과 최소, 최대값을 나타내었다. 유입수의 총질소(TN: Total Nitrogen)와 총인(TP: Total Phosphorus)는 대체적으로 일정한 값을 나타냈고, 유입/유출수의 TSS와 BOD, COD는 서로 비슷한 경향을 가졌으며 평균적으로 여름에 낮고, 겨울에 높은 값을 나타냈다.

인공신경망기법을 사용하여 H-하수처리장에서의 구성성분 농도의 예측 가능성 평가를 계절별 영향을 고려한 사례 1과 시계열 분석 목적인 사례 2로 구분하여 모델링하였다.

먼저 하루동안의 시계열 데이터를 사용한 사례 1의 결과는 그림 6에 나타내었다. 이하 모든 그림에서의 실제값은 도형으로, 예측값은 실선으로 표시하였다. 그림 6(a)는 학습 데이터에 대한 결과를 나타낸 것으로 비교적 정확한 수준으로 235개의 학습데이터에 대한 예측이 가능하였다. 하지만 그림 6(b)의 테스트 데이터의 경우에는 예측값과 실제값이 차이가 나는 것을 알 수 있다. RMSE 값은 학습 데이터의 경우에는 COD의 경우 0.436; TN의 경우 0.795; TP의 경우 0.094로 예측값과 실제값의 차이가 적게 나타났으나, 테스트 데이터의 경우 COD (1.605); TN (2.975); TP (0.596)로 다소 높게 나타난 경향이 있었다. 하지만 사례 1의 경우 테스트 데이터를 통해서도 계절별 특성을 알 수 있는 장점이 있음을 알 수 있었다.




(a) Training data




(b) Test data

그림 7. 사례 2-1의 신경망 모델링 결과.

Fig. 7. The NN modeling results of CASE 2-1.




(a) Training data



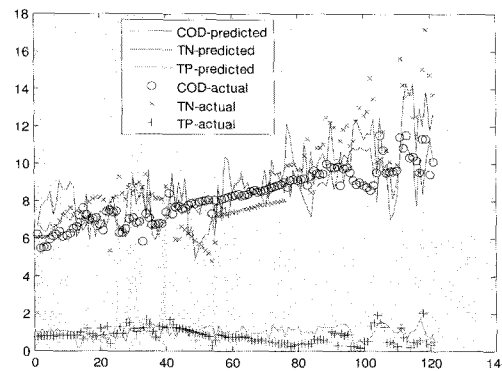
(b) Test data

그림 9. 사례 2-3의 신경망 모델링 결과.

Fig. 9. The NN modeling results of CASE 2-3.



(a) Training data



(b) Test data

그림 8. 사례 2-2의 신경망 모델링 결과.

Fig. 8. The NN modeling results of CASE 2-2.

그림 7-9는 동특성 정보가 포함된 신경망 모델링인 사례 2-1, 2-2, 2-3에 대한 결과를 나타낸 것으로써, 일일 데이터, 하루 전의 데이터, 이틀 전의 데이터를 포함함에 따라 모델 예측 효율이 어떻게 변화하는지를 살펴볼 수 있다. 각각의 모델링시 학습 데이터의 경우는 인공신경망의 학습에 사용했던 데이터에 대한 예측을 나타내는 것이기 때문에 거의 정확한 수준으로 예측이 가능하였으나, 테스트 데이터의 경우 학습데이터보다는 정확도가 낮게 나타났으며 그림 7에서 그림 9로 갈수록 예측값과 실제값의 차이인 모델링 에러가 감소하는 것을 알 수 있었다. 즉, 동특성 정보를 반영함에 따라 보다 좋은 예측 효율을 나타냄을 알 수 있다. 이러한 결과는 같이 하루 전, 이틀 전의 데이터를 포함함에 따라 테스트 데이터의 COD에 대한 RMSE 값이 사례 2-1 (1.854); 사례 2-2 (1.485); 사례 2-3 (0.957)로 작아지는 것으로도 확인할 수 있었고, 표 3은 사례 2의 전 항목에 해당하는 RMSE 값을 나타낸 것이다.

전체적으로 본 연구에서의 예측 결과는 유출수의 경향을 파악하는 데에는 무리가 없으나 정확한 수치를 예측하기에는 부족함이 있었다. 이에 대한 한계점으로 수집된 데이터의 부적절성과 고려인자의 부족, 인공신경망기법의 한계로 들 수 있다. 수집된 데이터의 경우 수집 기간의 60%만 존재하였고, 보정 과정에서 유효하지 않거나 없는 데이터에 대해서는 3 시그마와 보간법을 이용하여 보정을 하였으나, 그것만으로는 궁극적인 데이터의 유효성을 높일 수가 없음을 알 수 있었다.

표 3. 사례 2의 학습데이터와 테스트데이터의 RMSE값.
Table 3. The RMSE values of training and test data in CASE 2.

	Training data			Test data		
	COD	TN	TP	COD	TN	TP
CASE 2-1	0.484	0.768	0.081	1.854	2.581	0.530
CASE 2-2	0.301	0.736	0.075	1.485	2.414	0.628
CASE 2-3	0.249	0.707	0.096	0.957	1.645	0.441




그림 10. 온도에 따른 질산화 효율.
Fig. 10. The nitrification efficiency as a function of temperature.

그리고 생물학적 처리공정에서의 유기물 제거 효율에 가장 많은 영향을 주는 미생물의 생장에 영향을 미치는 온도에 대한 정보가 있었다면 보다 나은 결과를 얻을 수 있을 것이다. 왜냐하면 미생물에 의한 생물학적 처리의 특성상, 온도에 따라 제거 효율이 변화하고, 모델링 결과 또한 그와 같이 나타났기 때문이다. 그림 10은 온도에 따른 질산화 효율 그래프를 나타낸 것인데, 온도가 낮아짐에 따라 미생물의 성장율이 저하되어 질산화 효율이 낮아지는 것을 알 수 있고, 즉, 유출수의 질소 농도는 제거되지 않아 높아지는 것을 알 수 있다. 따라서 온도는 생물학적 처리 공정에서 질소 제거에 가장 많은 영향을 주는 요인인 것을 알 수 있다.

또한 인공신경망 모델의 경우 과도하게 학습시킬 경우 오히려 예측능력이 저하되는 현상이 나타났는데, 인공신경망은 입력과 출력 데이터만을 사용하는 블랙박스 모델이기 때문에 폐수처리장과 같이 잡음이 많고 측정 오차가 많은 데이터의 모델링에는 인공신경망이 한계가 있음을 알 수 있었고, 학습반복횟수를 적절하게 줄이기 위한 방법이 요구되었다[15].

V. 결론

본 연구에서는 실규모 하수처리장에서의 복잡하고 비선형적인 요소가 많은 시스템의 특성을 파악하기 위한 방법으로 인공신경망 기법을 적용하였다. 실제 가동중인 H 하수처리장의 동특성을 고려하여 5개의 유입수 성분과 3개의 유출수 성분의 데이터를 가지고 학습을 시키고, 학습 내용을 바탕으로 새로운 유입수 성분에 대하여 유출수 성분을 예측할 수 있었다. 특히, 하루 전과 이틀 전의 데이터를 인공신경망 모델의 입력변수에 포함한 동역학적 특성을 고려할수록 모델링의 정확도가 높아짐을 알 수 있었다.

본 연구에서 제시한 방법을 통하여 유출수의 예측 경향을 파악하는 데에는 무리가 없으나 정확한 수치를 예측하기에는 다소 부족함이 있었다. 그 이유로는 수집된 데이터의 부적절성과 고려인자의 부족, 인공신경망이 갖는 한계점 등이

원인이라 할 수 있겠다. 또한, CASE 2-3의 경우 이틀 전까지의 데이터를 포함함으로써 보다 많은 동특성을 고려하려고 했음에도 불구하고 너무 많은 유입 인자를 사용함으로써 구동 시간이 오래 걸리고, 최적의 신경망을 구조하는 데에 있어서 어려움이 있었을 뿐만 아니라, 불필요한 인자까지 고려함에 있어 오히려 모델의 예측 효율을 낮추는 원인이라 할 수 있겠다. 따라서 공정의 비선형적 특성, 측정 데이터 내에 존재하는 잡음과 오차 등으로 인해 인공신경망뿐만 아니라 어느 한가지 방법만으로 접근하여서는 적절한 모사가 어려운 경우 기존의 방법들의 장점을 결합하여 모델링 하는 방법을 필요함을 알 수 있었다. 특히, 추후에 인공신경망 모델링 전 단계로 주성분 분석이나 민감도 분석을 통하여 불필요한 인자를 제거하여 모델의 효율을 높일 수 있는 추가 연구가 필요함을 알 수 있었다.


본 연구에서 지정된 데이터를 학습시키고, 그것을 바탕으로 예측할 수 있었지만, 나아가 시간대별로 하수의 특성을 학습시키고 실시간으로 측정 가능한 인자를 바탕으로 하수 구성 성분의 농도를 예측할 필요가 있다. 이러한 문제점이 해결된다면, 인공지능모델링 기법은 하수처리 시스템에서의 공정의 예측이나 이상 진단 등에 실용적으로 사용될 수 있을 것이고 더 나아가 신경망 구조 자체에 동특성이 포함된 recurrent neural network 적용이 가능할 것이다.

참고문헌

- [1] G. Olsson and B. Newell, *Wastewater Treatment System - Modelling, Diagnosis and Control*, IWA, UK, 1999.
- [2] J. R. Kim, "Model optimization and model based supervisory local control for activated sludge process," Korea, Pusan university, Ph. D. thesis, 2006.
- [3] 김민한, 유창규, "모델링 기법을 이용한 하수처리 공정 설계와 환경성 및 경제성 평가," *한국화학공학*, 제46권 제3호, pp. 610-618, June 2008.
- [4] 최동진, 박희경, "혼합신경망 모델을 이용한 폐수처리공정의 수질인자의 추정," *한국물환경학회*, 제17권 제1호, pp. 87-98, Jan. 2001.
- [5] M. S. Park, *Application of Artificial Neural Nets in Bioprocess System*, Korea, KAIST, Ph. D thesis, 1997.
- [6] M. Hack and M. Kohne, "Estimation of wastewater process parameters using neural networks," *Wat. Sci. Tech.*, vol. 33, no. 1, pp. 101-115, 1996.
- [7] T. Y. Pai, "Gray and neural network prediction of effluent from the wastewater treatment plant of industrial park using influent quality," *Environ. Eng. Sci.*, vol. 25, no. 5, pp. 757-766, 2008.
- [8] E. C. Martinez and J. A. Wilson, "A hybrid neural network-first principles approach to batch unit optimization," *Comp. Chem. Eng.*, vol. 22, pp. S894-S896, 1998.
- [9] D. S. Lee, C. O. Jeon, J. M. Park, and K. S. Chang, "Hybrid neural network modeling of a full-scale industrial wastewater treatment process," *Biotech. and Bioeng.*, vol. 78, no. 6, pp. 671-682, 2002.
- [10] H. Demuth, M. Beale, and M. Hagan, *Neural Network Toolbox 5 - User's Guide*, Mathworks, USA, 2007.
- [11] Y. S. Kim, *Comparisons of Partial Least Squares Method and Artificial Neural Network for Analyzing Process Monitoring*


Data, Korea, KAIST, Ph. D thesis, 1998.

- [12] S. J. Chae, *Optimal Design of Artificial Neural Network Model Using the Taguchi's Method*, Korea, Dong Eui university, Ph. M thesis, 2001.
- [13] K. V. Shetty, S. Nandennavar, and G. Srinikethan, "Artificial neural networks model for the prediction of steady state phenol biodegradation in a pulsed plate bioreactor," *J. Chemical Technol. Biotechnol.*, vol. 83, pp. 1181-1189, 2008.
- [14] 서창원, 란 티 뉴엔, 정형석, 이상민, 이의신, 신항식, "슬러지 침전성이 DNR 공정에 미치는 영향 평가," 대한상하수도학회, 제20권 제2호, pp. 273-280, 2006.
- [15] H. S. Jeong, S. H. Lee, H. S. Shin, and E. Y. Song, "Analysis and prediction of sewage components of urban wastewater treatment plant using neural network," *J. of KSEE*, vol. 28, no. 3, pp. 308-315, 2006.



김민한

2008년 경희대학교 환경응용화학부 환경공학 학사. 2008년~현재 경희대학교 환경응용과학과 석사과정. 관심분야는 환경시스템공학, 환경 모니터링 및 제어, 환경 모델링, 환경 최적화.



유창규

1993년 연세대학교 화학공학과 학사. 1995년 포항공대 화학공학과 석사. 1998년 두산기술원 전임연구원. 2002년 포항공대 화학공학과 박사. 2004년 벨기에 겐트대학교 BIOMATH 학과 Post-doc. 2006년 포항공대 환경공학과 연구조교수. 2006년~현재 경희대학교 환경응용화학대학 교수. 관심분야는 공정제어, 데이터마이닝, 시스템즈 생물학 (생명정보학), 환경시스템공학, 환경관리시스템, 환경통합관리, 원격모니터링 및 제어, 환경 최적화, 환경 정보학.