

질소제거를 위한 SBR 공정운전에서 ORP 모델링에 관한 연구: 다항식 뉴럴네트워크 기법 중심

論文

53D-4-3

A Study on the ORP Modeling in SBR Process for Nitrogen Removal: Polynomial Neural Network Is Employed

金東源* · 朴永煥** · 朴貴泰***
(Dong-Won Kim · Young-Whan Park · Gwi-Tae Park)

Abstract – This paper shows the application of artificial intelligence technique such as polynomial neural network in modeling and identification of sequencing batch reactor (SBR). A wastewater treatment process for nitrogen removal in the SBR is presented. Simulation results have shown that the nonlinear process can be modeled reasonably well by the present scheme which is simple but efficient.

Key Words: sequencing batch reactor, wastewater treatment, nitrogen removal, modeling, identification, PNN

1. 서 론

물은 수많은 인간의 활동에 필요한 존재며, 산업용 혹은 농업용 등으로 사용된 후에는 폐수로 버려진다. 폐수는 자연환경으로 돌아가기 전에 공해화학물질이나 박테리아, 바이러스 등 위험한 물질이 제거되어야 한다 [1-3]. 현재까지 하수처리 시설은 시단위 이상의 대규모 시설에 편중되어 사업이 시행되어 왔다. 이로 인해 농촌지역의 소규모 오수처리 시설이 위치한 지역은 오수발생 부하의 변화가 심하고, 계절별 변화가 도시하수처리장에 비해 심함으로 이들 하수를 완전히 처리하지 못한 채 방류되어 수자원 관리에 많은 어려움이 있다. 또한 소규모 오수처리 시설과 같이 원수성상의 변화가 심하고, 운전요원이 상주하지 않는 곳에서는 유입부하 변화에 연동하면서 동시에 유지관리가 간편한 운전방법이 필요하게 된다. 특히 유기물질의 제거뿐만 아니라, 질소나 인과 같은 영양소 제거도 가능한 수준의 처리방법이 요구되고 있는 데, sequencing batch reactor (SBR) 공정은 시설 및 운전이 간단하고 유기물질의 제거뿐만 아니라 영양소까지 제거 가능함으로 읍, 면 단위의 소규모 하수처리시설로써 적당하다. 그러나 장치는 간단하나 그 반응기내에서 일어나는 각각의 반응은 복잡하고 다양한 메커니즘을 가지고 있으며, 이러한 각각의 반응은 반응기내 반응 물질의 농도에 따라 다양하게 변화한다. 그러므로 운전조건의 변화에 따라 다양한 질소제거 특성을 나타나게 된다. 또한 특성인자의 변화로 인해 SBR 공정의 적정운전조건을 찾아 유기물질과

영양소를 최적으로 처리할 수 있는 환경을 구현하는 데는 많은 노력이 따른다.

최근 들어 질소제거를 위한 SBR 공정에서 반응물질의 농도에 따라 다양하게 변화하는 공정특성을 분석하고 이해하기 위해 SBR 공정을 모델링한 연구가 진행되고 있다 [10], [10]에서 이용한 모델링 방법은 일반적인 고차다항식이며, 이를 통하여 질소제거 공정의 다양한 메커니즘을 묘사하였다. 그러나 모델의 정밀도가 우수하지 못하여 정확한 공정분석이 이루어 지지 못하였다. 본 논문에서는 이러한 문제점을 해결하기 위해 다항식 뉴럴네트워크 [4]를 이용하여 SBR 반응조의 질소제거 공정을 모델링 하였다. 다항식 뉴럴네트워크 구조는 기존의 신경 회로망처럼 층과 노드로 구성되어 있으나, 그 구조가 미리 정해져 있지 않으며 계속해서 생성과 제거가 되는 자기 구성형태이다. 또 각 노드의 출력은 다수의 입력변수들의 1차, 2차, 및 변형된 2차 다항식으로 계산되므로 입출력 변수 사이에서 선형적인 경험이나 지식을 사용하지 않고 중요한 입력변수를 선택할 수 있는 것이 특징이다. 그러므로 설계자의 경험과 사전지식에 의존하여 모델설계를 행하던 기존의 방법에 비하여 커다란 장점을 가진다. 본 논문에서는 질소제거를 위한 DO (dissolved oxygne), ORP (dcidation reduction potential), pH의 실시간 변화를 관찰하여 질소제거특성을 검토하였으며 이를 통해 얻은 실제의 입출력데이터를 가지고 SBR 반응조의 질소제거 공정을 모델링 하였다.

2. 질소제거를 위한 SBR공정

Sequencing batch reactor (SBR) 공정은 소규모 오수처리 시설에 적용되는 공정의 하나로 운전방법의 변화에 따라 유기물질의 제거뿐만 아니라, 영양소까지 제거되는 공정이다. 활성오니에 있는 박테리아는 유해한 성분을 물이나 질소가스 등의 무해한 성분으로 바꾸며 반응조에서 폐수는 활

* 正會員 : 高麗大學校 工科大學 電氣工學科 博士課程

** 正會員 : 忠州大學校 情報制御工學科 助教授 · 工博

*** 正會員 : 高麗大學校 工科大學 電氣工學科 教授 · 工博

接受日字 : 2003年 6月 27日

最終完了 : 2004年 2月 14日

성오니와 섞여진다. 그러므로 활성오니는 폐수와 섞인 상태로 유지되기 위해 혼합작업이 필요하다. SBR 공정에서 폐수처리 작업은 반응조에 폐수를 공급하면서 혼합하는 단계와 산소를 공급하는 단계, 혼합과 산소공급을 중단하는 단계, 그리고 마지막으로 정화된 물을 반응조에서 배출하는 단계로 구분할 수 있다.

전체 시스템의 구성은 다음과 같다. 본 논문에서 사용된 반응조는 단일 반응조에서 무산소, 협기, 호기반응이 연속적으로 일어나는 SBR 반응조이다. 반응조는 아크릴로 제작하였으며 반응조의 용적과 실용적은 각각 15L 와 10L이며, 처리용량은 3L 이다. 미생물의 혼합은 반응조내에 설치된 60rpm의 믹서를 이용하였고 동시에 반응조 바닥에 설치된 산소주입 포기장치에 의해 혼합이 이루어 진다. 유출수는 슬레노이드 밸브를 달아 자동으로 조절되고 유입수량은 masterflux tubing pump (cole parmer model 7553-80)를 이용하여 조정되었으며 이들은 타이머에 의해 제어되었다. ORP, pH, DO 센서를 반응조의 벽면에 일정하게 고정시켜 Track Study시 연속모니터링 하였고 2주에 한번씩 보정하였다. 전체동작은 6시간을 한 주기 (1cycle)로 해서 운전이 이루어진다. 무산소, 협기 시간은 운전시간이 고정되어 있지 않고 반응조 센서들의 실시간 모니터링 자료에 의해 변화운전되었다. 아울러 배수, 휴지기 시간은 각각 0.33hr, 0.17hr로 고정하였다. 반응조의 실험장치와 운전조건은 각각 그림 1과 표 1과 같다.

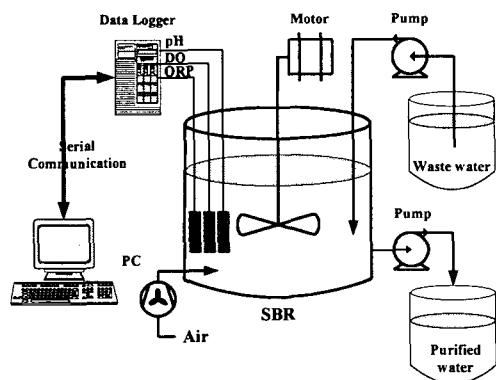


그림 1. 질소제거를 위한 반응조의 실험장치

Fig. 1. Experimental setup of SBR for nitrogen removal

표 1. SBR의 운전조건

Table 1. Working condition of SBR

Parameter	Average
volume	10 l
SRT	30 d
MLSS	2500 mg/l
MLVSS/MLSS	0.701
Temperature	23 ± 2 ° C

그림 1에서 반응조인 SBR은 원통형으로 센서부와 구동부의 기기들이 장치되어 있다. 센서부는 항상 폐수에 잠겨 있으며, ORP, DO, pH값을 주기적으로 읽어 들인다. 데이터 수집기는 센서부에서 측정된 값을 직렬통신으로 PC로 전달 한다. SBR 상단에는 폐수를 공급하는 펌프가 있으며, 하단

에는 정화수를 배출하는 펌프와 산소를 공급하는 펌프가 각각 연결되어 있다. 믹서는 모터와 연결되어 폐수를 저어서 생물화학적 반응을 촉진시키는 역할을 한다. 각각의 펌프와 모터는 전기계전기와 연결되어 있으며 PC에서 내보내는 제어신호에 의해 on/off 된다.

실험에 사용한 시료는 충주 처리장에 유입되는 생활하수로서 시료의 종류와 상태는 표 2와 같다.

표 2. 시료의 종류와 상태

Table 2. Constituent and state of material

Constituent	Range	Average	Standard deviation
pH	6.7~7.5	7.1	0.12
BOD ₅	50~85	63	14.4
COD _{cr}	112~152	131	18.8
TSS	31~52	45	6.9
VSS	23~46	36	7.4
NH ₄ -N	18~28	22	3.5
TP	2.18~2.22	2.3	0.05

수질분석 항목으로는 BOD, COD_{cr}, TSS/VSS, TKN, NH₄⁺-N, NO₂⁻-N, NO₃⁻-N, TP 등으로 모든 분석방법은 수질오염공정시험법과 standard methods 및 일부 기기분석법에 의해 수행되었다. ORP, DO, pH의 실시간 측정은 ALMEMO사의 센서 (pH : FY8PHK, ORP: FYA8RXEN, DO:FYA64002)를 사용하여 data logger (ALMEMO 20090-8)에 연결하여 측정하였다. 실험주기는 유입수는 일주일에 1회, 유출수는 2일에 1회, 반응조 MLSS분석은 3일에 1회 분석하였고, SRT는 3일에 한번씩 슬러지 인출을 통해서 일정하게 유지하였다.

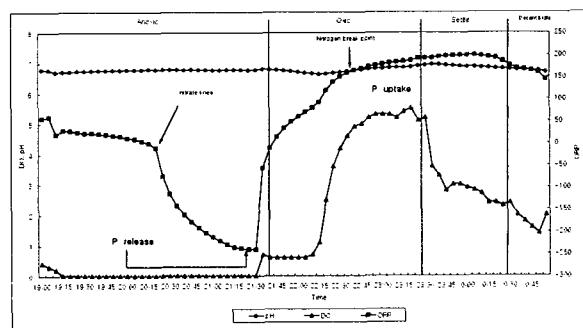


그림 2. ORP, DO, pH의 변화곡선

Fig. 2. ORP, DO and pH variation curves

반응조내의 ORP와 pH 변화에 따른 질소와 인의 거동분석은 다음과 같다. 일반적으로 ORP 곡선상에서 탈질의 종료 지점으로 알려진 nitrate knee에서의 ORP는 그림 2와 같이 -100 ~ 100mV의 값을 나타내고 있었고, 질산화 종료지점의 변곡점인 nitrogen break point에서 ORP는 100 ~ 250mV 값을 보이고 있다. 아울러 탈질이 종료된 후 ORP값이 -220 ~ -300mV까지 계속 하향곡선을 보이고 있는데 이때에는 인의 방출현상이 발생하고 있다. Nitrogen break point가 ORP를 이용하여 질산화의 종료를 의미하고 있다면

ammonia valley는 pH를 이용하여 질산화 종료지점을 나타내는 것으로서, 그림 3과 같이 pH 곡선 상에서 pH 6.5~7.0 사이에서 ammonia valley가 나타나고 있다. 그림 3에서 pH 값은 무산소에서 탈질시 알칼리도가 형성됨으로써 증가양상을 나타내다가 호기조건에서 질산화에 의해 알카리도가 소모됨으로써 pH값이 떨어지는 것을 볼 수 있다.

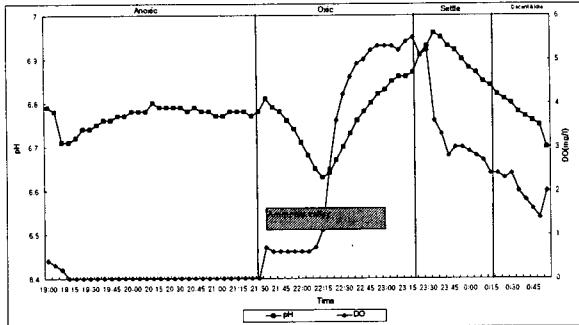


그림 3. DO와 pH의 변화곡선

Fig. 3. DO and pH variation curves

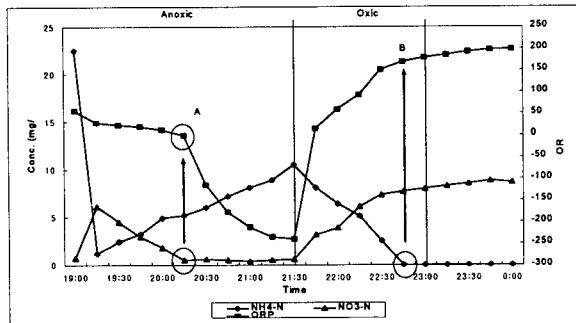
그림 4. ORP, NH₄⁺-N and NO₃⁻-N 변화 곡선Fig. 4. ORP, NH₄⁺-N and NO₃⁻-N variation curves

그림 4는 SBR 반응조에서 ORP와 NH₄⁺-N, NO₃⁻-N의 시간별 거동분석을 나타낸 것이다. ORP의 A부분은 무산소 조건이 시작과 함께 ORP가 꾸준히 감소되고 NO₃⁻-N농도는 6.5 mg/L에서 0.1 mg/L까지 떨어지면서 완전한 탈질이 이루어지고 있다. 탈질의 완료지점인 nitrate knee에서부터는 더 이상의 NO₃⁻-N 농도의 감소현상이 발생하지 않았으나 ORP의 경우 꾸준히 감소되고 있다. 한편 반응조의 조건이 무산소에서 호기조건으로 전환되면서 ORP는 급격히 증가하다가 B지점에 이르러 증가양성이 둔화되면서 일정한 값을 나타내고 있는 것을 볼 수 있다. 이 지점이 nitrogen break point가 나타나는 부분으로 반응조내의 NH₄⁺-N 농도가 질산화에 의해 완전히 제거되고 있다. 이 부분에서 인의 섭취 현상이 동시에 발생하는 것으로 알려져 있다 [9]. 이와 같이 인의 방출과 섭취가 교대로 일어나면서 인의 제거가 이루어지고 있고 이를 ORP 거동분석을 통해 간접적으로 알 수 있다.

3. 다항식 뉴럴네트워크

다항식 뉴럴네트워크 (polynomial neural network: PNN)[4]는 GMDH (group method of data handling) [5,7,8] 알고리즘에 기반한 것으로 유용한 근사방법의 하나이다.

PNN의 구조는 다항식 노드를 가진 전방향 뉴럴네트워크와 유사하며, 각 노드의 출력은 1차 다항식 (linear), 2차 다항식 (quadratic), 변형된 2차 다항식 (modified quadratic)을 이용하여 얻는다. 이러한 다항식을 일컬어 부분표현식 (partial description: PD)이라 한다. PNN 알고리즘은 다음과 같은 여러 단계의 설계순서로 이루어 지며, 이를 간략히 기술하면 다음과 같다.

단계 1- 입력변수를 설정하는 단계로, 출력변수 y 에 관련된 임의의 N 개의 입력변수를 설정한다.

단계 2- 시스템을 통해 얻은 데이터를 학습용 데이터와 평가용 데이터로 분할하는 단계로, 학습용 데이터는 모델동정을 위해 사용하고, 평가용 데이터는 동정된 모델을 평가하기 위해 사용된다.

단계 3- PNN 구조를 선택하는 단계로, PNN 구조는 첫 번째 층과 그 이후 층의 부분표현식을 구성하는 방법에 따라 그 구조가 정해진다. 첫 번째 층과 그 이후 층의 각 노드의 입력변수 수가 동일한 경우 (기본 PNN)와 그렇지 않은 경우 (변형된 PNN)의 두 구조로 분류되며, 또 각 구조는 노드의 부분표현식의 차수에 따라 각각 Case 1과 Case 2로 다시 세분화된다. Case 1은 모든 층에서 노드의 PD가 동일 차수를 가지는 구조이며, Case 2는 첫 번째 층과 그 이후 층의 노드의 PD가 서로 다른 차수를 가지는 구조이다.

단계 4- 노드의 차수 및 입력변수 수를 선택하는 단계로, N 개의 입력변수 중에서 각 노드에 사용할 입력변수 수와 차수를 선택한다. N 에서 r 개의 변수를 각 노드의 입력으로

선택하면 필요한 총 노드의 개수는 $\frac{N!}{r!(N-r)!}$ 가 되며, N 은 전체 입력변수의 수이고, r 은 설계자가 택한 입력변수의 수이다. 예를 들어, 노드의 입력 수로 2 입력을 선택했을 때 PD로 나타날 수 있는 형태는 다음과 같다.

- Type 1= $c_0 + c_1x_1 + c_2x_2$
- Type 2= $c_0 + c_1x_1 + c_2x_2 + c_3x_1^2 + x_2^2 + c_5x_1x_2$
- Type 3= $c_0 + c_1x_1 + c_2x_2 + c_5x_1x_2$

여기서, c_i 는 PD의 매개변수이다.

단계 5- 부분표현식의 매개변수를 추정하는 단계로, 단계 4에서 노드의 PD형태가 정해지면 학습용 데이터를 사용하여 매개변수 (c_1, c_2, \dots)값을 추정한다. 최소자승법에 의해 식 1이 최소가 되는 매개변수 값을 구한다.

$$E_k = \frac{1}{n_r} \sum_{i=1}^{n_r} (y_i - z_{ki})^2, k=1, 2, \dots, \frac{N!}{r!(N-r)!} \quad (1)$$

여기서 z_{ki} 는 k 번째 노드의 PD에서 i 번째 입력 데이터를 사용했을 때의 값을 나타낸다.

단계 6- 주어진 성능지수로 각 PD를 평가 후 좋은 성능의 노드를 선택하는 단계로, 단계 5에서 구한 매개변수로 이루어진 각 노드의 PD에 평가용 데이터를 사용하여 주어진 성능지수를 계산한다. 여기서 얻은 결과값으로 값이 작은 순으로 정렬하고 이를 중 값이 작은 순으로 w 개의 노드를 선택하고 나머지는 버린다. 여기서, w 는 적용 대상에 따라 달라질 수 있으며, 본 논문에서 설계자가 정한 값은 20이다.

단계 7- 마지막 단계로 PNN 알고리즘의 종료판정을 결정한다. PNN 구조는 설계자가 미리 정한 층까지 노드의 PD

가 결정되었을 때 종료된다. 만약 종료조건을 만족하지 않을 경우, 전 층의 출력값이 다음 층의 입력값이 되어 새로운 입력출력 데이터를 구성하고, 단계 4로 다시 돌아간다.

다항식 뉴럴네트워크의 구체적인 내용은 [4,6,8]에서 자세히 살펴볼 수 있다.

4. 시뮬레이션 및 결과고찰

위에서 언급한 SBR 공정에서 ORP를 모델링하기 위해 그림 1과 같이 질소제거를 위한 반응조의 실험장치를 갖추었다. 이때 반응조의 DO, ORP, pH의 실시간 변화를 관찰하여 실제의 입력출력 데이터를 얻었으며, 이것을 이용하여 PNN모델링을 수행한다.

시스템의 입력변수로는 반응조에 팔린 각 펌프를 on/off시키는 스위치와 이에 따라 변화하는 ORP, DO, pH값이 사용되었으며, 출력변수로는 비선형성과 불확실성이 강한 ORP값이 사용되었다. 입력변수로 사용된 ORP는 출력변수로 사용된 것보다 한 샘플링이 지연된다. 총 데이터 개수는 71개가 사용되었으며, 모두 학습용 데이터로 이용하였다. 모델의 정밀도와 성능을 평가하기 위한 성능지수 (PI)는 평균자승오차 (mean squared error: MSE)를 사용하였으며, 다음과 같이 계산된다.

$$PI = \frac{1}{71} \sum_{i=1}^{71} (y_i - \hat{y}_i)^2 \quad (2)$$

여기서, y_i 는 실제 측정치이며, \hat{y}_i 는 PNN의 출력값이다.

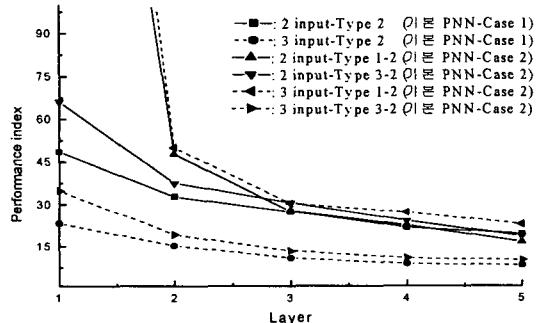


그림 5. 부분표현식의 입력변수와 차수에 따른 기본 PNN의 결과 비교

Fig. 5. Performance comparisons of basic PNN according to the number of inputs and order of PD

부분표현식의 입력변수와 차수에 따른 기본 PNN에 대한 결과는 그림 5와 같다. PNN 구조에서도 알 수 있듯이, 입력변수와 차수의 조합에 따라 많은 경우의 수가 생성될 수 있다. 하지만 본 논문에서는 최적의 모델정밀도를 위해 입력변수의 수는 2입력과 3입력을 사용했을 때로 구분되며, 차수는 1층에서 Type 1 혹은 Type 3을 사용하고 2층 이상에서 Type 2를 사용하는 경우만을 고려한다. 가장 우수한 결과는 기본 PNN-Case 1 (3 input-Type 2)일 때 5층에서 8.3696을 얻었다. 변형된 PNN의 결과는 그림 6과 같다. 입력변수의 수는 2입력에서 3입력으로 변하거나 혹은 반대의 경우이며, 차수는 기본 PNN의 경우와 마찬가지로 Type 1에서 Type 2로 혹은 Type 3에서 Type 2로 변한다. 변형된 PNN에서 가장 우수한 결과는 4.6742이며, PD의 입력변수가 1층에선

2개, 2 층 이상에선 3으로 변하며, 차수는 1층에서 Type 3, 2층 이상에선 Type 2인 변형된 PNN-Case 2일 때이다.

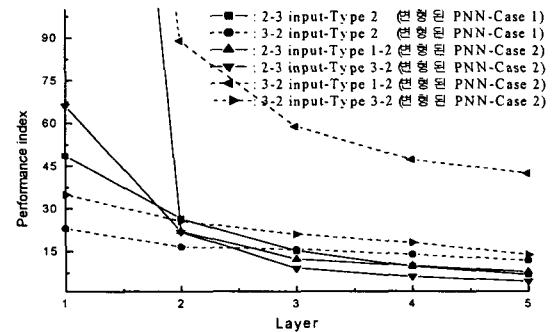


그림 6. 부분표현식의 입력변수와 차수에 따른 변형된 PNN의 결과 비교

Fig. 6. Performance comparisons of modified PNN according to the number of inputs and order of PD

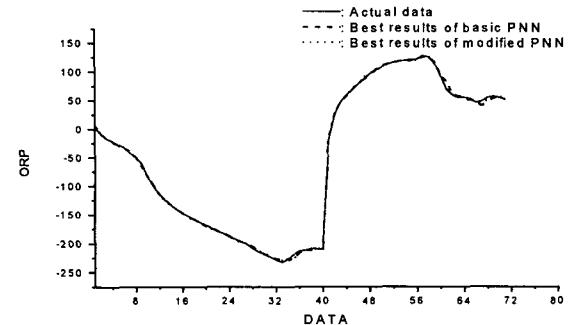


그림 7. 실제데이터와 기본PNN 및 변형된PNN의 결과값비교

Fig. 7. Comparison results of actual data and basic & modified PNN

실제의 출력값과 PNN모델의 출력값 비교를 그림 7에서 나타내었다. 기본 PNN과 변형된 PNN의 가장 우수한 결과값을 실제의 값과 비교하였다. 이때 오차는 그림 8와 같다.

기존의 고차다항식 [10]과 비교하기 위해 표 3에서 성능지수를 나타내었다. 표에서 보듯이 PNN은 구조에 따라 다양한 결과값이 생성되었으며 결과값이 기존의 모델에 비해 더욱 우수함을 알 수 있다.

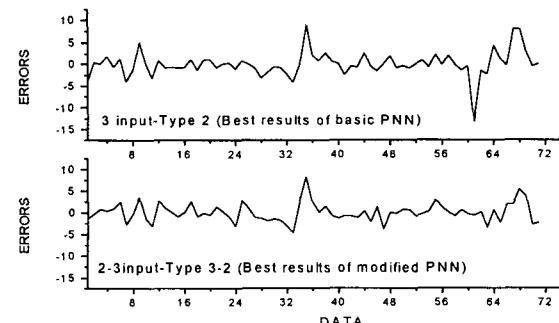


그림 8. 실제데이터와 기본PNN 및 변형된PNN 사이의 오차

Fig. 8. Errors between actual data and basic & modified PNN

표 3. 기존 고차 다항식 모델과의 동정 오차비교
Table 3. Comparison of identification error with high order polynomials

Model	MSE
[10]	Type 1
	Type 2
	Type 3
	Type 4
Basic PNN	8.369
Modified PNN	4.674

4. 결론 및 향후과제

본 논문에서는 질소제거를 위한 SBR 공정에서 운전조건의 변화에 따라 다양한 질소제거 특징을 보이는 시스템을 모델링 하기 위해 PNN 알고리즘이 사용되었다. PNN 알고리즘은 입력변수와 차수에 따라 다양한 형태의 구조와 이에 따른 성능의 차이가 있음을 알 수 있다. 시뮬레이션 결과에서 보듯이 PNN과 같은 인공지능 기법을 통하여 비선형 시스템을 합리적이고 효율적으로 모델링 할 수 있었다. 앞으로의 과제는 유전알고리즘을 이용하여 다항식 뉴럴 네트워크의 구조를 최적화 하여 비선형 시스템에 대한 최상의 모델을 얻는 것이며, 또한 퍼지시스템이나 신경회로망과 같은 다른 형태의 지능기법을 이용하여 모델링을 수행하고 이의 결과를 비교 분석하는 것이다. 이와 함께 모델의 일반화 능력을 검증할 수 있도록 질소제거를 위한 SBR 공정운전에서 생성된 데이터를 학습용 데이터와 평가용 데이터로 분할하여 성능비교가 이루어지는 것도 앞으로의 과제이다.

참 고 문 헌

- [1] 김창원, “활성슬러지 공정 연속호흡을 측정기 및 MLSS meter와 이를 이용한 활성슬러지 공정제어,” Eco-2 상하수도 정보화 세미나, 2001.
- [2] H. Kim, and O. J. Hao, “pH and oxidation-reduction potential control strategy for optimization of nitrogen removal in an alternating aerobic anoxic system,” *Water Environ Res*, vol. 73, pp. 95-102, 2001.
- [3] 이호식, “TKN/COD비가 높은 소규모지역 오수의 생물학적 영양소 제거,” 충주대학교 논문집, 2001.
- [4] 오성권, 김동원, 박병준, “다항식 뉴럴네트워크 구조의 최적 설계에 관한 연구,” *Trans. KIEE*, vol. 49D, no. 3, pp. 145-156, 2000.
- [5] A. G. Ivakhnenko, “Polynomial theory of complex systems,” *IEEE Trans. Syst., Man, Cybern.*, vol. SMC-1, no. 1, pp. 364-378, 1971.
- [6] 김동원, “자기구성 다항식 뉴럴네트워크의 진화론적 설계,” Master’s thesis, Dept. Control Instrum., Wonkwang Univ., 2002 (in Korean)
- [7] D. W. Kim, and G. T. Park, “Identification of Non-

linear System using Self-generating Polynomial Neural Network,” *SCIS & ISIS 2002*, Oct., 2002.

- [8] 김동원, 박귀태, “다항식 뉴럴 네트워크의 최적화: 진화론적 방법,” *Trans. KIEE*, vol. 52D, no. 7, 2003.
- [9] B.C. Cho, S.I. Liaw, C.N. Chang, R.F. Yu, and B.R. Chiou, “Development of a Real-Time Control Strategy with Artificial Neural Network for Automatic Control of a Continuous-Flow Sequencing Batch Reactor,” *Wat Sci & Tech*, vol. 44, no. 1, pp. 95-104, 2001.
- [10] 김동원, 박장현, 이호식, 박영환, 박귀태, “이차다항식을 이용한 질소제거 SBR공정의 모델링,” *Proceedings of KFIS Fall Conference*, pp. 145-148, 2003.

저 자 소 개



김동원 (金東源)

1994년 3월 13일생. 2002년~현재 고려대학교 대학원 전기공학과 박사수료.
관심분야: GMDH 탑입 알고리즘, 소프트 컴퓨팅기반 뉴로-퍼지 시스템, 시스템 모델링 및 지능제어.
E-mail : upground@korea.ac.kr



박영환 (朴永煥)

1961년 1월 28일생. 1998년~현재 충주대학교 정보제어공학과 조교수.
관심분야: 적응제어, 비선형제어, 지능제어 이론.
E-mail : pyh@mail.chungju.ac.kr



박귀태 (朴貴泰)

1947년 10월 25일생. 1975년 고려대학교 전기공학과 졸업. 1977년 동 대학원 전기공학과 졸업(석사). 1981년 동 대학원 전기공학과 졸업(공박). 1975~1978 한국 원자력 연구소 연구원. 1981년~현재 고려대학교 전기공학과 교수. 2000~현재 (사) IBS KOREA 회장.

관심분야: 퍼지 및 신경망, 컴퓨터 비전, 지능제어, 인텔리전트 빌딩시스템 및 정보통신.
E-mail : gtpark@korea.ac.kr