

논문 2000-9-2-06

신경회로망을 이용한 순환식 돈분처리 시스템의 모니터링

손준일*, 이민호*, 최정혜**, 고성철**

Monitoring of Recycling Treatment System for Piggery Slurry
Using Neural Networks

Jun-il Sohn*, Minho Lee*, Junghea Choi**, and Sung-Cheol Koh**

요약

이 논문에서는 신경회로망을 이용하여 순환식 돈분처리 시스템의 실시간 모니터링을 궁극적으로 구현할 수 있는 새로운 방법을 제안하였다. 즉 미생물 군집내의 개체군밀도에 따른 각 처리조(유입수, 발효조, 폭기조, 1차 침전조 및 4차 침전조)에서의 폐수처리 과정을 모델을 시도하였다. 측정 데이터에 대해 우선 principle component analysis(PCA) 분석을 적용하여 각 처리조에서의 입력(미생물 밀도와 처리요소)과 출력간의 상관관계를 파악하고, 각각의 처리조마다 독립된 신경회로망을 적용하여 폐수처리 과정을 모델링하였다. 신경회로망의 입력으로 현재 탱크에서의 미생물의 개체군밀도를 직접 이용하는 대신 PCA 분석 결과를 이용함으로써, 비교적 적은 수의 데이터로 효과적인 모니터링 시스템을 구현할 수 있었다. 즉 각 처리조별로 학습된 신경회로망들을 연결하여 분석한 결과 2일 동안의 폐수 처리 변화를 비교적 정확히 예측할 수 있었다.

Abstract

We propose a novel monitoring system for a recycling piggery slurry treatment system through neural networks. Here we tried to model treatment process for each tank(influent, fermentation, aeration, first sedimentation and fourth sedimentation tanks) in the system based on population densities of heterotrophic and lactic acid bacteria. Principle component analysis(PCA) was first applied to identify a relation between input(microbial densities and parameters for the treatment) and output, and then multilayer neural networks were employed to model the treatment process for each tank. PCA filtration of input data as microbial densities was found to facilitate the modeling procedure for the system monitoring even with a relatively lower number of input. Neural networks independently trained for each treatment tank and their subsequent combinatorial data analysis allowed a successful prediction of the treatment system for at least two days.

* 경북대학교 센서공학과 / 센서기술연구소(Dept. of Sensor Eng., Kyungpook National Univ./Sensor Technology Research Center, Kyungpook National Univ.)

** 한국해양대학교 토목환경공학부(Division of Civil and Environmental Engineering, Korea Maritime Univ.)

<접수일자 : 2000년 2월 8일>

I. 서론

축산분뇨는 고농도의 유기성 폐수로서 처리되지 않은 상태로 수계로 유입되면 하천의 수질악화와 호소의 부영양화를 초래하며, 분뇨에 포함된 병원성 미생물에 의한 지하수 오염도 가져 올 수 있다⁶⁾. 전국의 축산농

가에서 하루 발생하는 축산폐수 발생량은 약 197천m³ 으로서 이중 법규제 대상미만 축산폐수가 50%를 차지하고 있다. 축산폐수의 발생량은 산업폐수 및 생활하수에 비해 비교적 소량이지만 유기물질의 농도가 높아 (BOD 20,000 ppm이상) 수계에 대한 오염부하량 측면에서 그 의미는 중대해진다⁷⁾. 공공수계에 대한 축산 폐수의 오염부하는 수역에 따라 다르게 나타나지만 최고 전체 오염부하의 19.9%를 차지하는 경우도 있다⁹⁾. 제도적으로는 법규제 규모미만의 소규모 축산농가가 많고 규제대상 농가도 규제기준이 낮은 실정이고, 축산폐수처리 관리상으로는 축산농가의 환경에 대한 인식부족과 운영능력 미흡 등으로 축산폐수처리시설의 운영관리가 부실하고, 이에 대한 지도·점검·인력도 턱없이 부족하여 효율적인 관리가 되고 있지 못한 실정이다. 본 연구의 궁극적 개발 대상이 되고있는 순환식 돈분처리 시스템은 규제대상에서 제외된 소규모의 농가에 적합한 시스템으로서 사실상 무방류 시스템이다⁸⁾.

인간의 정보 처리 방식을 공학적으로 모델링한 신경회로망은 자기 조직화, 대용량의 병렬처리 및 임의의 비선형 함수를 근사화할 수 있으며 적응적 학습기능 등의 장점들을 가지고 있어 기존의 방법으로 해결하기 어려웠던 여러 가지 문제들을 정확한 수학적 모델링이나 시스템의 파라미터에 대한 상세한 정보 없이도 원하는 결과들을 얻을 수 있어 패턴 인식, 비선형 동적 시스템의 동정화와 제어 등에 이용되고 있다^{2,4,5)}.

본 연구에서는 돈분폐수의 생물학적처리에 있어서 미생물의 밀도 그리고 처리효율평가에 중요한 요인들 즉 부유고형물(suspended solids: SS), 총질소(total-N), 암모니아태질소(NH₃-N), 총인(total-P; T-P), 무기인(ortho-P), COD 등을 입력 또는 출력변수로 하여 비선형함수를 잘 모델화할 수 있는 다층구조 신경회로망기법을 적용한 폐수 처리시스템의 에뮬레이터를 구축하여 궁극적으로 최적폐수처리의 실시간 모니터링 시스템을 구현하고자 하였다. 이를 위해, 우선 얻은 데이터를 PCA (Principle Component Analysis)를 이용하여, 신경회로망의 학습에 필요한 최적의 입력들을 선정하였다. 개발된 모니터링 시스템은 수 일 후의 환경 변수의 변화를 비교적 정확히 예측할 수 있었다. 따라서 본 모델은 실제 돈분 처리 시스템에서 원하는 기준의 방류수를 얻기 위한 최적의 입력조건 (미생물밀도 등)을 결정하는데 있어서 에뮬레이터로 사용될 수 있을 것으로 기대된다.

II. 순환식 돈분 처리 시스템


1. 시스템 개요

그림 1은 미생물을 이용한 pilot 순환식 돈분 처리시스템의 개략도를 나타낸다. 여기서 1번 탱크는 돈사로부터 나온 분뇨와 돈사내 세척수로 사용된 처리된 일부 방류수가 모이는 곳이며 이 유입수는 발효조(fermentation tank; 2번 탱크; 15L)로 유입된다. 3번 탱크는 폭기조(aeration tank; 15L)로서 송풍기(blower)에 의해 공기가 주입(7.8v/v/m)되었으며 폭기조의 폐수는 침전조인 6번과 7번 탱크에서 침전과정을 거치고 8번 저장탱크에 저장되며 그 일부는 돈사를 세척하는데 이용되었다. 본 연구에 사용된 돈분폐수는 김해 축산폐수 공동처리장의 혼합저류조에서 채취하였으며 성상은 약 COD 4000 (mg/L), BOD 7000(mg/L), T-N 2100(mg/L), T-P 172(mg/L)였다. 매 8 일마다 유입수를 원수 : 방류수 : 수도수 = 33% : 57% : 10% 섞어서 공급 하였다. 이 때 포도당을 첨가하여 C/N 비를 100 : 15로 조절하였고 현장조건을 고려하여 유입수 및 폭기조에 미생물 체제 1%(w/v)를 첨가하였다. 발효조 및 폭기조의 수리학적 체류시간은 4일 이었고 47일간 운전하였다.

처리시스템의 미생물, 즉 유산균 및 종속영양세균의 밀도는 각각 MRS 배지 및 TSA(trypticase soy agar)를 사용하여 Krieg 및 Gerhardt 등이³⁾ 제시한 spread plate 방법에 따라 실시하였다. 그리고 SS, NH₃-N, COD, 총인 및 무기인의 분석은 Standard Methods for the Examination of Water and Wastewater¹⁾의 방법으로 분석하였다. 즉 COD 분석(Cr 법)은 Closed Reflux, Titrimetric Method를, 총인 및 무기인은 Ascorbic Acid Method를 이용하여 분석하였으며, 부유고형물은 총부유고형물 건조 방법으로 그리고 NH₃-N은 indole phenol법으로 측정하였다. 돈분처리 시스템의 특성 모델링을 위해 초기단계(예, 유입수)내의 각 미생물밀도 (TSA-1, MRS type1 등)와 SS, NH₃-N, COD 등을 신경회로망의 입력으로하여 그 출력이 다음 단계(예, 발효조)의 실제 측정치와 동일하게 되도록 신경회로망의 연결 강도를 조절하였다.

2. 미생물의 군집밀도 변화 및 COD 처리효과

그림 2는 47일 동안 처리 시스템내의 대표적 유산균의 밀도변화를 각 탱크별로 나타낸 것으로서 유입수



1 Influent, 2 Fermentation tank, 3 Aeration tank, 4 Blower, 5 Antifoaming device, 6 Sediment tank, 7 Reservoir, 8 Storage tank, 9 Recycling flow, 10. For fertilizer

그림 1. 미생물을 이용한 순환식 돈분 처리 시스템의 개략도
Fig. 1 Recycling treatment system for piggery slurry

및 발효조에서 폭기조 및 침전조에 비해 우점종으로 나타나고 있는데 이는 유산균의 조건적 혐기성특성을 나타내는 것이라 할 수 있다. 그리고 호기성 균주로서는 TSA-3가 폭기조에서 우점종으로 나타났다. 그림 3은 47일 동안 처리 시스템내의 COD 변화를 각 탱크 별로 나타낸 것으로서 전체적으로 약 54%의 처리효율을 보였다.

III. 신경회로망을 이용한 돈분폐수 처리 시스템의 모델링

최적의 돈분 처리를 위해서는 처리 시스템에서의 호기성·혐기성, 미호기성 타가영양균 그리고 자가 영양균의 성질 및 그들간의 상호관계 파악이 필수적이거나 이들의 상호관계는 그림 2와 3에서 보는 것처럼 매우 복잡하여 시스템을 수학적으로 모델링하기는 매우 어렵다. 본 연구에서는 이처럼 복잡한 특성을 갖는 시스템을 모델링하기 위해 오차 역전파 학습 알고리즘을 갖

는 다층구조 신경회로망을 이용하였다. 다층구조 신경회로망은 비선형 함수를 이용하여 출력의 범위를 제한할 수 있으며 하나 이상의 은닉층을 갖고 있으며 은닉층의 수와 각 층에서의 유닛의 수를 조절하므로써 수렴 성능과 일반화 능력을 향상시킬 수 있어 돈분 처리 시스템과 같이 복잡한 특성을 갖는 시스템의 모델링에 적합한 신경회로망이다.

순환식 돈분 처리 시스템의 모델링에서는 하나의 은닉층을 사용하였으며 은닉층은 30개의 유닛으로 구성되었고 비선형 함수로는 출력값이 -1에서 +1범위를 가지는 시그모이드 함수를 사용하였으며 실제 시스템에서 47일 동안 측정된 데이터를 이용하여 각 데이터에 대한 오차를 줄이는 과정을 반복함으로써 신경회로망이 시스템을 그대로 학습하게 된다. 신경회로망은 현재 탱크에서의 미생물로서 MRS type1과 TSA type 1, 2, 3 그리고 COD, 총인, 무기인, SS 및 NH₃ 값이 입력으로 작용하여 다음 탱크의 COD, 총인, 무기인, SS 및 NH₃에 대한 예상 결과를 출력하고 대상 target인 다음 탱크에서의 COD, 총인, 무기인, SS 및 NH₃의 실측값

과 비교하여 오차를 구하고, 이 오차에 대해 신경망의 연결 강도를 조절하며, 이러한 과정을 여러 차례 반복함에 따라 신경회로망의 출력은 보다 정확히 다음 탱크에서의 COD, 총인, 무기인, SS 및 NH₃값들을 출력한다.

신경망의 학습은 하나의 신경망으로 전체의 처리 시스템을 모델링할 수도 있으나, 실제 시스템에서 각각의 탱크마다 전달함수가 다르며, 특히 저류조1과 저류조4는 그 기능이 유사하고 COD, 총인, 무기인, SS 및 NH₃값의 변화가 적으나 저류조4에서 유입수로의 과정은 새로 돈분이 유입되어 이전 탱크에서의 경향과는 전혀 다른 특성을 가지므로 하나의 신경망으로 전체 시스템의 특성을 학습한다는 것은 매우 어렵다.




그림 2 47일 동안의 COD의 변화
Fig. 2 COD value for 47 days

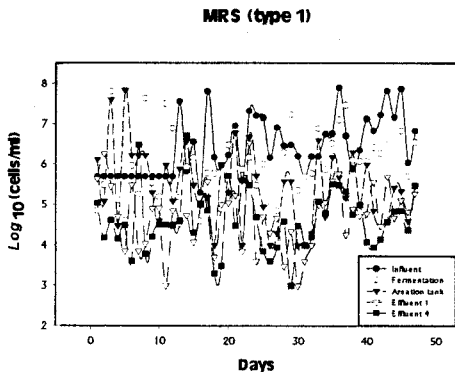


그림 3. 47일 동안의 MRS type1의 변화
Fig. 3 MRS type1 data for 47 days

따라서, 본 연구에서는 각각의 탱크마다 신경망을 따로 사용하여 각 탱크에서 일어나는 현상을 보다 더 정확히 학습하고 이들 신경망을 다시 연결함으로써 전체

의 시스템을 모델링하는 방법을 사용하였다. 실제 실험을 통해 각각의 탱크를 따로 학습하는 것이 보다 더 용이하고 일반화 능력 또한 개선되는 것을 확인하였다.

한편, 돈분 처리 시스템의 모델링에서 입력 유닛이 9개인 것에 비해 47개에 불과한 학습 데이터는 복잡한 실제 시스템의 입출력 관계를 파악하기에는 불충분하며 일반화 능력 또한 기대하기 어렵다. 그리고 미생물이나 그 밖의 데이터는 측정 과정에서 여러 가지의 과정을 거치므로 여러 가지 부가적인 변수로 인한 노이즈를 포함하고 있을 가능성이 높다. 따라서, 본 연구에서는 PCA(Principle Component Analysis)를 이용하여 입력의 차원을 3차원으로 줄여 일반화 성능을 향상시키고 입력 및 출력 데이터를 2차원의 좌표평면 위에 표시하여 거리가 가까운 입력 데이터 중에서 출력이 다른 곳에 위치하는 데이터는 노이즈로 판단하고 학습에서 제외하였다.

실제로 PCA를 사용하지 않은 모델에 비해 PCA를 적용한 모델이 더 좋은 성능을 나타내는 것을 확인하였다. PCA는 고차원의 데이터를 저차원으로 투사하는 것으로 데이터의 분산이 가장 잘 표현될 수 있는 몇 개의 직교 좌표축을 설정하여 각각의 데이터를 새 좌표축에 투사한다. 직교 좌표축을 설정하는 방법은 먼저 47×9 크기의 측정 데이터로부터 9×9 상관행렬을 구하고 상관 행렬로부터 eigenvalue를 얻으며 크기가 큰 3개의 eigenvalue에 대한 eigenvector를 구함으로써 얻을 수 있다. PCA에 의해 매핑된 결과값은 2차원 그래프상에 표시가 가능하므로 데이터의 상호 관계 파악이 용이하여 패턴 인식이나 신호 분리 등의 응용 분야 등에 널리 이용되고 있다. PCA의 축의 개수는 많을수록 데이터의 손실이 적으나 필요 이상으로 많으면 PCA의 결과 역시 경향을 파악하기 힘들다.




그림 4. 유입수에서 입력에 대한 PCA 결과
Fig. 4 PCA result of input in influent




그림 5. 유입수에서 출력에 대한 PCA 결과
Fig. 5 PCA result of output in influent

본 연구에서는 세 개의 축을 이용하여 데이터를 표현하였으며 그림 4는 유입수에서 측정된 데이터에 PCA를 적용한 결과를 2차원의 좌표상에 각각 나타낸 것으로 가로축은 첫 번째 eigenvector에 의해 맵핑된 값이며 세로축은 두 번째 eigenvector에 의한 맵핑 결과를 나타내며 각 점에서의 숫자는 측정을 시작한 날로부터의 경과를 의미한다. 그림 5는 유입수 입력에 대한 목표 값의 PCA 결과로서 각 축의 의미는 그림 4와 동일하다. 그림 4에서 첫째 날부터 넷째 날에 해당되는 데이터는 동일한 지점에 위치하나 그림 5에서 해당 목표 값들은 서로 다른 점에 위치함을 알 수 있다. 이러한 데이터는 one-to-many mapping 문제의 대표적인 경우로 학습에서 제외하였다. 그림 6은 PCA를 이용한 신경회로망의 학습 과정을 나타내는 블록다이어그램이다. PCA에 의해 9차원의 입력은 3차원의 입력으로 축소되고 target 데이터는 COD, T-P, ortho-P, SS, NH₃ 값을 그대로 이용하였다.

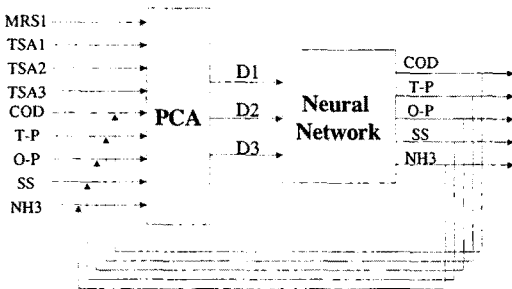


그림 6. 신경망 학습을 위한 블록다이어그램
Fig. 6 Block diagram for training of neural network

IV. 결과 및 고찰

순환식 돈분 처리시스템을 모델링하기 위해 47일 간의 측정 데이터 중에서 6, 11, 16, 21, 26, 31, 36 41일째 데이터와 46일과 47일째 데이터는 학습이 끝난 후 완성된 모델의 성능을 평가하기 위한 테스트 데이터로 사용하기 위해 학습에서 제외하였다. 학습에 사용된 신경회로망의 형태는 하나의 은닉층을 가지는 구조를 이용하였고 각각의 연결강도는 오류역전과 알고리즘에 의해 수정되었다.

표 1. 이틀 동안의 예상 결과

Table 1. Prediction results for 2 days

		COD	T-P	O-P	SS	NH ₃
46	06 25	3517.986	36	30.426	0.560002	1730
		3525.532	35.95342	31.00742	0.563237	1685.274
46	06 25	3433.98	27.9995	27.3112	0.305	1210.01
		3485.2	27.7	27.2	0.32	1207.3
46	06 25	1497.99	20.9999	21.9996	0.185	915.008
		2874.1	21.8	18.1	0.13	734.9
46	06 25	1442.98	21.9997	21.0001	0.175	890
		1949.9	24.1	23.1	0.22	825
46	06 25	1205.35	20	23.0004	0.18	844.992
		1105.9	34.1	38.9	0.21	886.9
47	06 26	3943	49	53.842	0.88	1470
		3907.8	28.5	33.8	0.172	1024.8
47	06 26	2883.03	36.0005	43.8514	0.39499	1250
		2663.7	39.1	31.5	0.183	1248.8
47	06 26	1948.97	23.9996	39	0.275	1100
		1049	22	24.7	0.269	1029.8
47	06 26	1470.98	21.9997	36.0004	0.295	960
		1791	21.4	23.5	0.13	803.23
47	06 26	1277.34	25	39	0.23	770
		980.3	21.6	27.1	0.155	973.9

신경회로망을 이용한 각 탱크 특성 모델링은 각각의 탱크에서 복잡한 함수관계를 잘 근사화 하여 실제 측정치와 유사한 값을 출력하고, 학습하지 않은 테스트 데이터에 대해서도 어느 정도 추정할 수 있음을 확인할 수 있었다. 각각의 탱크 특성을 모델링하는 신경회로망을 연결하여 순환식 돈분 처리 시스템의 모니터링을 위한 전체 시스템을 구성하고 46일째 유입수의 데이터로부터 이틀 동안의 시스템의 출력을 예상한 결과를 표 1에 나타내었다. 표 1에서 각 테스트 날짜의 첫 행은 목표 값을 나타내고, 둘째 행은 신경회로망의 추정치를 나타낸 것이다. 그림 7과 8에서는 표 1에서의 COD와 NH₃를 그래프로 나타내었다. 여기서 가로축의 숫자는 46일과 47일째 날 시스템에서의 각각의 탱크를

의미하며 그림 7과 그림 8의 MSE는 각각 240930, 31459이다. 표 1과 그림 7과 8에서 보는 것처럼 제안한 방법을 이용한 순환식 돈분 폐수 처리 모니터링 시스템이 수일 동안 실제 측정치와 유사함을 알 수 있다.




그림 7. COD의 2일 동안의 예상 결과
Fig. 7 Prediction results for COD during 2 days




그림 8. NH₃의 2일 동안의 예상 결과
Fig. 8 Prediction results for NH₃ during 2 days

V. 결론

본 연구에서는 순환식 돈분 폐수 처리 시스템에서의 미생물 분포에 따른 폐수 처리 효과를 모델링하기 위해 신경회로망과 PCA를 이용하는 새로운 방법을 제안하였다. PCA 분석 결과를 바탕으로 신경회로망의 최적 입력 조건을 찾고, 실측 데이터를 이용하여, 폐수 처리 시스템의 각 탱크를 별도로 학습함으로써 비교적 적은 수의 데이터에도 불구하고 정확한 모델링 결과를 얻었다. 제안한 시스템은 폐수 처리 시스템의 효과적인 모니터링 시스템으로 사용할 수 있으며, 향후 실제 돈분 처리 시스템에서 원하는 기준의 방류수를 얻기 위한 최적의 입력조건 (미생물밀도 등)을 결정하는데 있어서 예플레이터로 사용될 수 있을 것으로 기대된다.


감사의 글

본 연구는 1998년도 학술진흥재단연구비 (관리번호: 1998-024-G-00041)로 수행되었기에 이에 감사드립니다.

참고문헌

- [1] American Public Health Association, American Water Works Association and Water Environment Federation, 1992. Standard Methods for the Examination of Water and Wastewater, 18th ed., Washington, D.C.
- [2] Barto, A.G., R.S. Sutton, and C.W. Anderson, 1983, "Neuronlike adaptive elements that can solve difficult learning control problems," *IEEE Trans. on Systems, Man, and Cybernetics*, vol. SMC-13, no. 5, pp. 834-846.
- [3] Krieg, N.R. and P. Gerhardt, 1994, Solid, liquid/solid, and semisolid culture, In, *Methods for General and Molecular Bacteriology*, pp. 216-223, American Society for Microbiology, Washington, D.C.
- [4] Morgan, D. and C. Scofield, 1991, *Neural networks and speech recognition*, Kluwer Academic Publishers.
- [5] Weigend, AS., N.A. Gershenfeld, 1994, *Time series prediction: Forecasting the future and Understanding the past*, Addison-Wesley Publishing Co.
- [6] 정연구, 1990, 상수원 보호를 위한 축산분뇨의 적정관리방안. 한국과학기술원.
- [7] 최경민 등, 1996, 광합성 세균을 이용한 돈분 폐수처리에 관한 연구, 폐기물 자원화 제 4권 제 2호, p. 1121.
- [8] 최정혜, 정영륜, 고성철, 1999, 산소 및 무산소조건

著 者 紹 介



손 준 일 (孫 峻 壹)
 1971년 10월 15일생.
 1997년 대구대학교 정보통신공학과 졸업(공학사), 1999년 대구대학교 대학원 정보통신공학과 졸업(공학석사), 1999년 ~ 현재 경북대학교 대학원 센서공학과 박사과정, 주관심분야 : 신경회로망, 적응신호처리.

이 민 호

「센서학회지 제8권 제1호」 논문99-8-1-07, p.52 참조
 현재 경북대학교 센서기술연구소 센서공학과 전임강사



최 정 혜 (崔 正 惠)
 1976년 8월 3일생.
 1999년 한국해양대학교 토목환경공학과 졸업(공학사), 1999년 3월 ~ 현재 한국해양대학교 대학원 토목환경공학과 석사과정, 주관심분야 : 환경미생물, 미생물생태학



고 성 철 (高 星 澈)
 1956년 8월 13일생
 1980년 서울대학교 농학과 졸업, 1983년 서울대학교 대학원 식물병리학과 졸업(석사), 1994년 Univ. of Tennessee-Knoxville 미생물생태학과 졸업(박사), 현재 한국해양대학교 공과대학 토목환경공학부 조교수, 주관심분야 : 환경미생물, 미생물생태학, 폐기물, 청정기술, 수질오염