

인공 신경망(ANN)에 의한 하수처리장의 유입 유량 및 유입 성분 농도의 예측

문태섭 · 최재훈 · 김성희 · 차재환 · 염훈식 · 김창원[†]

부산대학교 사회환경시스템공학부

Prediction of Influent Flow Rate and Influent Components using Artificial Neural Network (ANN)

Taesup Moon · Jaehoon Choi · Sunghui Kim · Jaehwan Cha · Hoonsik Yoom · Changwon Kim[†]

Department of Civil and Environmental Engineering, Pusan National University

(Received 19 November 2007, Accepted 27 December 2007)

Abstract

This work was performed to develop a model possible to predict the influent flow and influent components, which are one of main disturbances causing process problems at the operation of municipal wastewater treatment plant. In this study, artificial neural network (ANN) was used in order to develop a model that was able to predict the influent flow, COD_{Mn}, SS, TN 1 day-ahead, 2day-ahead and 3 day ahead. Multi-layer feed-forward back-propagation network was chosen as neural network type, and tanh-sigmoid function was used as activation function to transport signal at the neural network. And Levenberg-Marquart (LM) algorithm was used as learning algorithm to train neural network. Among 420 data sets except missing data, which were collected between 2005 and 2006 at field plant, 210 data sets were used for training, and other 210 data sets were used for validation. As result of it, ANN model for predicting the influent flow and components 1-3day ahead could be developed successfully. It is expected that this developed model can be practically used as follows: Detecting the fault related to effluent concentration that can be happened in the future by combining with other models to predict process performance in advance, and minimization of the process fault through the establishment of various control strategies based on the detection result.

keywords : Artificial neural network, Influent prediction, Modeling, Wastewater treatment plant

1. 서론

환경 규제가 점차적으로 강화됨에 따라, 하수처리장의 안정적이고 경제적인 운영을 위한 ICA(Instrumentation, Control and Automation) 기술들은 빠르게 발전해 왔다. 이러한 ICA 기술의 발전과 함께, 효과적인 공정 진단과 제어를 위한 하나의 수단이 되는 하수처리공정을 대상으로 한 모델에 대한 연구도 활발하게 진행되어왔다(Kim, 2006). 이러한 모델은 결정론적 모델로써 기본적으로 공정과 관련된 메커니즘과 물질 수지식 등에 기반하여 일반적으로 미분 방정식의 형태로 표현되는 white-box 모델, 공정으로부터 확보된 측정 데이터에 기반하여 주어진 입력 변수와 목표 변수 간의 변화 패턴만을 고려하여 생성되는 black-box 모델, 그리고 white-box 모델과 black-box 모델이 연속적으로 또는 병렬하게(Parallel) 결합된 grey-box 모델로 구분되어 발전해 왔다고 할 수 있고(Gernaey et al., 2004; Shioya et al., 1999), IWA task group에 의해 제안된 활성슬러지모델(Activated Sludge Model, ASM)과 인공신경망(Artificial Neural

Network, ANN) 모델은 각각 white-box 모델과 black-box 모델의 대표적인 예가 될 수 있다(Yoo et al., 2003). 이들 모델들은 하수처리장 건설을 위한 다양한 설계안들의 시뮬레이션에 의한 평가를 의미하는 공정 설계, 다양한 시나리오 분석을 통한 하수처리플랜트의 공정의 향상 및 공정 이상 발생 시 적절한 대안 제시를 의미하는 공정의 최적화 및 제어라는 측면에서 유용하게 활용되고 있다(Gernaey et al., 2004). 공정의 최적화 및 제어라는 측면에서 모델의 활용은 현재 시점을 기준으로 한 활용 즉 공정의 이상이 발생한 후 정상화하는 데 있어서의 활용에 국한되고 있다고 할 수 있고, 이들 모델들은 공정 상태의 이상을 사전에 감지하여 발생할 수 있는 문제를 사전에 방지하기 위한 도구로써는 활용되지 못하고 있다. 이러한 현재 기존 모델의 한계점을 극복하기 위해서는 적절한 유입수 예측 모델의 개발이 필요하고, 개발된 유입수 예측 모델이 기존의 공정 성능 예측모델과 결합이 된다면 공정의 미래 상태에 대한 정보가 사전에 제공될 것이고 발생할 수 있는 문제가 사전에 감지되어 공정 이상이 발생하기 이전에 조치가 취해짐으로써 공정의 안정적인 운영에 기여할 수 있을 것이라고 기대된다.

몇몇 연구자들(Cartensen et al., 1998; Grieu et al., 2005;

[†] To whom correspondence should be addressed.

cwkim@pusan.ac.kr

Kim et al., 2006)에 의해 유입수 예측 모델의 개발이 시도되었으나 이들에 의해 개발된 대부분의 모델들은 시간에 따라 변화하는 많은 변수들을 가짐으로 보정(calibration)하기 어렵다는 단점을 가지는 결정론적 모델들이었다. 물론 다른 형태의 모델인 black-box 모델을 사용한 연구 결과가 보도가 되기도 하였지만(El-Din and Smith, 2002), 이는 예측 대상이 유입 유량에만 국한되어 있어 공정의 이상을 초래하는 인자가 될 수 있는 다른 유입 성분의 변화를 반영하지 못한다는 한계점을 가진다.

본 연구에서는 유입수 예측 모델의 필요성에 대한 인식을 바탕으로 실제 하수처리장의 유입 유량뿐만 아니라 유입수 성상을 예측 가능하면서, 앞에서 언급한 결정론적 모델의 한계점을 극복할 수 있는 예측 모델, 즉 보정하기 쉬운 예측 모델을 개발하고자 하였다. 이를 위해 black-box 모델인 인공신경망을 사용하였으며, 그 결과 하수처리장으로부터 확보된 유입 데이터 및 기상자료들만을 활용하여, 현재 시점 기준 1일 뒤, 2일 뒤, 3일 뒤 유입 유량, COD_{Mn}, SS, TN 등이 예측 가능한 모델을 개발하였다.

2. 연구방법

2.1. 자료수집

표준 활성슬러지 공정으로 설치 운영되고 있는 B시 A하수처리장을 인공신경망을 활용한 유입수 예측모델 개발 대상 하수처리장으로 선정하였다. 대상 하수처리장에서 실제 측정된 2005년부터 2006년까지의 유입 수질 데이터들(유량, pH, DO, 온도, BOD, COD_{Mn}, SS, TN, TP)과 기상 데이터들(강우량, 습도 및 기온 등)을 수집하였고, 데이터 전처리를 거친 420개의 데이터 셋을 예측 모델 개발을 위해 사용하였다. 이 중 210개의 데이터 셋을 신경망의 훈련을 위해 사용하였고, 나머지 210개의 데이터 셋을 훈련된 신경망의 예측 성능을 검증하기 위해 사용하였다. Table 1은 대상 하수처리장 유입수의 통계학적 특성을 보여주고 있다.

2.2. 데이터 전처리

하수처리장으로부터 확보된 데이터들 중 데이터의 신뢰성을 떨어뜨릴 수 있는 이상치(Outlier)는 정확한 예측 모델을 개발하는 데 있어 방해 요인이 되므로 제거하였다. 본 연구에서는 이상치 제거를 위하여 관리도 기법을 사용하였다. 식 (1)에서와 같이 관리 상한선(Upper control limit, UCL)과 관리 하한선(Lower control limit, LCL)을 설정하고, UCL과 LCL을 벗어나는 값들은 이상치로 간주하고 제

거하였다. 여기서, \bar{X} 는 평균값, σ 는 표준편차, A는 상수로서 본 연구에서는 Mjalli 등(2007)에 의해 제안된 값을 참조로 하여 상수를 3으로 사용하였다.

$$UCL = \bar{X} + A\sigma \quad LCL = \bar{X} - A\sigma \quad (1)$$

측정된 시계열 데이터 간의 선형적 또는 비선형적 상관성을 파악하고 연속된 데이터들의 시간에 따른 경향을 파악하기 위해 일반적으로 다양한 통계학적 처리가 이루어진다(Mjalli et al., 2007). 본 연구에서는, 다양한 통계학적 기법 중 하나로 식 (2)와 같이 표현될 수 있는 5-day moving average 기법을 사용하였고, 이를 통해 확보된 장기간의 데이터 셋들에서 단기간의 변동의 감소 및 제거가 이루어졌다. 여기서, X_i 는 측정 변수들, i 는 현재 시점(Current time period)이다. 그리고, 이렇게 전처리 된 데이터들 간의 상관관계를 그래프를 통해 정성적으로 평가하였고, 예측하고자 하는 변수들 즉, 유입유량, COD_{Mn}, SS, TN 등과 상관관계가 높은 변수들을 신경망의 입력 변수로 사용하였다.

$$\hat{X}_i = \frac{1}{5} (X_{i+2} + X_{i+1} + X_i + X_{i-1} + X_{i-2}) \quad (2)$$

마지막으로 수행된 데이터의 전처리 작업은 신경망의 데이터 준비의 기본 단계인 데이터 표준화 작업이다. 각각 다른 스케일(Scale)로 분포하고 있는 모든 데이터들(X_i)이 0과 1사이의 값의 분포를 가질 수 있게 식 (3)을 이용하여 표준화하였다. 여기서, $X_{i,\min}$ 은 최소값이고, $X_{i,\max}$ 는 최대값이다.

$$X_{i,n} = \frac{X_i - X_{i,\min}}{X_{i,\max} - X_{i,\min}} \quad (3)$$

2.3. 인공신경망(Artificial Neural Network, ANN): 개념 및 방법

인공신경망은 인간의 뇌에 존재하는 생물학적 신경 세포와 이들의 연결 관계를 단순화시켜 수학적으로 모델링하여 인간의 두뇌가 나타내는 지능적 형태를 구현하는 것이다. 현재 인공신경망은 시스템 규명, 예측, 패턴 인식, 분류 및 공정 제어 등의 분야들에서 많이 활용되고 있다(Mjalli et al., 2007). 인공신경망은 그 구조에 따라 single layer feed-forward network, multi-layer feed-forward network, feed-back

Table 1. Statistical properties of influent composition for target WWTP

	Rain (mm)	Hum. (%)	Flow (m ³ /d)	Temp. (°C)	pH (-)	DO (mg/L)	BOD (mg/L)	COD _{Mn} (mg/L)	SS (mg/L)	TN (mg/L)	TP (mg/L)
Max.	50.0	90	42,478	29.3	7.9	1.5	241	139	238	44.4	5.3
Min.	0.0	20	32,419	16.1	7.0	0.6	147	85	146	28.3	3.5
Mean	2.1	60	36,412	22.5	7.5	1.1	189	108	186	35.8	4.3
S.D.	6.7	10	1,901	3.8	0.2	0.2	20	11	16	3.3	0.4

Where, Hum.: Humidity; Temp.: Temperature; Max.: Maximum value; Min.: Minimum value; S.D.: Standard deviation

network, recurrent network, self-organized network으로 분류되고, 신경망의 사용목적에 따라 적절한 형태의 신경망 구조를 선택하게 된다. 본 연구는 유입수 예측을 목적으로 함으로, 모델링과 예측 분야에서 가장 일반적으로 사용되고 있는 Multi-layer feed-forward back-propagation network을 사용하였다. Fig. 1은 일반적인 Multi-layer feed-forward back-propagation network의 구조를 보여준다. Fig. 1을 통해 알 수 있듯이, 뉴런들이 각 층들 즉 입력 층(Input layer), 은닉 층(Hidden layer), 출력 층(Output layer)에 배열되고, 각 층의 뉴런들은 연결 가중치에 의해 연결된다. 표준화된 입력 데이터가 입력 층의 뉴런들에 입력되고, 은닉 층을 통해 출력 층으로 전달된다. 앞의 층의 뉴런으로부터 다음 층의 뉴런으로의 신호 전달은 Fig. 2와 같이 표현될 수 있으며, 본 연구에서는 식 (4)와 같이 표현되는 tanh-sigmoid function을 신호전달을 위한 전달함수(Transfer function)로 사용하였다.

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$

신경망에서 학습(Learning)이란 각 뉴런들 간에 연결된 가중치의 조절을 통해 실측치와 신경망을 통해 계산된 출력치 간의 오차를 최소화 시키는 것을 의미한다. 본 연구에서는 오차공간(Error space)에서 지역극소(Local minimum)에 빠졌을 때, 더 이상 학습을 수행할 수 없다는 단점을 가진 역전파(Back-propagation) 알고리즘(Choi and Park, 2001) 대신에, 역전파 알고리즘의 단점을 극복하고 더 빠른 학습이 가능한 Levenberg-Marquart(LM) 알고리즘(Hagan et al., 1996)을 학습 알고리즘으로 사용하였다.




Fig. 1. Typical structure of Multi-layer feed-forward back-propagation network (El-Din and Smith, 2002).




Fig. 2. Signal transport at Multi-layer feed-forward network (Jang et al., 1997).

신경망의 성능을 결정하는 주요한 인자는 신경망의 구조, 신경망의 학습 종료 시점(즉, epoch 수) 및 주어지는 가중치의 값이다. 신경망의 구조와 학습을 위한 epoch 수와 가중치 값을 결정하는 데 있어 절대적인 방법은 없다. 따라서, 본 연구에서는 시행착오법(Trial and error method)에 의해 적절한 신경망의 구조와 epoch 수를 결정하였고, 선택된 신경망의 구조와 epoch 수를 바탕으로 훈련된 신경망을 일반화하기에 충분하게 가중치 값들을 결정하였다. 본 연구에서 상용 소프트웨어인 MATLAB에서 제공되는 neural network toolbox(The MathWorks Inc., 2000)를 이용해서 모든 시뮬레이션 작업을 수행하였다.

3. 결과 및 고찰

3.1. 현재 시점 기준 1일 뒤 예측

현재 시점을 기준으로 해 1일 뒤 유입 유량, COD_{Mn}, SS, TN 농도를 예측이 가능한 각각의 인공 신경망 모델이 개발이 본 연구에서 이루어졌다. 앞에서 언급하였듯이, 전처리된 데이터의 그래프를 통한 정성적 평가 결과를 반영하여 예측하고자 하는 변수에 대한 적절한 입력 변수들을 선택하였다. Fig. 3은 이러한 정성적 상관관계 평가의 한 예로 강수량과 유입 유량, 그리고 습도와 유입 유량과의 관계, 다른 예측하고자 하는 변수들과 COD_{Mn}과의 관계를 그래프를 통해 보여주고 있다. Fig. 3을 통해 볼 때, 강수량 및 습도의 증가는 유입 유량의 증가를 초래하고 이들의 감소는 유입 유량의 감소를 초래한다는 것을 알 수 있다. 이는 유입 유량과 강수량 및 습도와 변화 거동이 비슷하다는 것을 의미한다. 이와 같은 그래프를 통한 정성적 상관관계 평가를 통해 유입 유량의 예측을 위한 입력 변수들로서 습도와 강수량을 선택하였으며 그리고 시계열적 특성을 고려하여 1일 전 유입 유량을 선택하였다. 그리고, Fig. 3을 통해 볼 때, 다른 예측하고자 하는 변수들, 즉 목표 변수들과 유입 COD_{Mn} 농도와 변화 거동 또한 비슷하다는 것을 알 수 있고 이를 바탕으로 각각의 목표 변수들에 대한 입력변수로서 다른 변수들보다는 유입 COD_{Mn} 농도를 선택하였다. Fig. 4는 현재 시점 기준 1일 뒤 유입 유량의 예측하기 위해 시행 착오법(Trial and error method)에 의해 결정되어 구성된 신경망의 구조를 보여준다. Fig. 4를 통해 알 수 있듯이, 유입 유량의 예측을 위한 인공신경망은 하나의 입력 층, 두개의 은닉 층, 하나의 출력 층으로 구성되고, 입력 층에는 4개의 뉴런, 두 개의 은닉 층에는 각 층에 5개의 뉴런 그리고 출력 층에는 하나의 뉴런이 배치되게 구성하였다. Table 2는 현재 시점 기준 1일 뒤 COD, SS, TN 농도를 예측하기 위해 구성된 신경망의 구조에 대한 정보를 보여주고 있다. Fig. 4와 Table 2에서 설명된 것과 같은 구조를 가지는 신경망을 epoch 수를 100으로 고정된 뒤 가중치의 변화를 통해 훈련 데이터 셋을 이용하여 신경망의 학습을 수행하였고, 검증 데이터 셋을 이용하여 훈련된 신경망의 예측 성능을 평가하였다. 본 연구에서 epoch 수를 100으로 선택한 이유는 epoch 수가 100 이상으로 주




Fig. 3. Estimation of qualitative relationship between input variables and target variables. (a) Relationship between flowrate and rainfall, (b) Relationship between flowrate and humidity, (c) Relationship between COD_{Mn} and SS, (d) Relationship between COD_{Mn} and TN




Fig. 4. Structure of ANN for 1 day-ahead prediction of flowrate (Where, t: Present, t-1: Before 1 day, t+1: After 1 day).

어졌을 때는 가중치의 변화에 상관없이 과도한 훈련(Training)으로 인해, 과적합(Overfitting)의 문제가 발생하였기 때문이다.

Fig. 5는 각 목표 변수들의 현재시점 기준 1일 뒤 예측을 위해 210개의 데이터 셋을 이용하여 신경망이 훈련된 결과와, 나머지 210개의 검증(Validation) 데이터 셋을 이용하여 훈련된 신경망에 의해 예측된 결과를 보여준다. 신경망을 이용한 대상 하수처리장의 유입수 예측 성능의 정량적 평가는 시뮬레이션을 통해 도출된 예측 값과 실측 값 간의 오차에 의해 평가될 수 있다. 따라서 본 연구에서 개발된 신경망 모델의 정량적인 예측 성능 평가를 위하여 아래의 식 (5)와 같이 표현되는 평균 상대 오차율(Average relative difference)을 사용하였다. 여기서, N은 비교된 총 변수의 수, $X_{m,i}$ 는 i번째 측정 값, $X_{p,i}$ 는 i번째 예측 값이다. 예측 변수별 평균 상대 오차율은 Table 3에 나타내었다.

$$\text{Average relative difference(\%)} = \frac{1}{N} \sum_{i=1}^N \frac{|X_{m,i} - X_{p,i}|}{X_{m,i}} \times 100 \quad (5)$$

Table 2. ANN structure for 1day-ahead prediction with target variables

Target variables	Input variables	Number of neuron			
		Input layer	Hidden layer I	Hidden layer II	Output layer
COD _{t+1}	COD _{t-1} , COD _t , Flow _t , SS _t	4	5	5	1
SS _{t+1}	SS _{t-1} , SS _t , COD _t	3	5	5	1
TN _{t+1}	TN _{t-1} , TN _t , COD _t	3	5	5	1

Where, t: Present; t-1: Before 1 day; t+1: After 1 day

Table 3. Average relative difference for 1 day-ahead prediction with ANN

-	Average relative difference (%)	Flow	COD _{Mn}	SS	TN
1 day ahead	Training	0.57	0.003	2.67	1.68
	Validation	0.65	1.69	3.16	1.96

Fig. 5와 Table 2를 통해 현재 시점 기준 1일 뒤 각 유입 성분들을 예측하기 위해 인공 신경망의 훈련이 적절하게 이루어졌음을 확인할 수 있었고, 훈련에 사용되지 않은 데이터를 사용하여 훈련된 인공 신경망의 성능을 검증한 결과, 각 목표 변수들의 실측값들의 변화 거동을 훈련된 인

공 신경망이 잘 묘사하고 있을 뿐만 아니라, 상대 오차율이 유량의 경우 0.65%, COD_{Mn}의 경우 1.69%, SS의 경우 3.16%, TN의 경우 1.96% 정도로 일반적인 95% 신뢰구간에 포함되는 5%미만의 낮은 값을 나타낸다는 것을 알 수 있었다. 이러한 검증 결과를 통해 평가할 때, 현재 시점 기




Fig. 5. 1 day-ahead prediction with ANN. (a) Prediction of flowrate, (b) Prediction of COD_{Mn}, (c) Prediction of SS, (d) Prediction of TN

Table 4. Average relative difference for 2 day-ahead prediction with ANN

-	Average relative difference (%)	Flow	COD _{Mn}	SS	TN
2 day ahead	Training	0.93	1.60	3.91	2.44
	Validation	1.93	2.61	4.36	2.91

Table 5. Average relative difference for 3 day-ahead prediction with ANN

-	Average relative difference (%)	Flow	COD _{Mn}	SS	TN
3 day ahead	Training	1.07	1.77	4.42	3.04
	Validation	1.66	2.74	5.29	3.93

준 1일 뒤 유입 유량 및 유입 성분들의 농도를 예측하기 위해 개발된 인공 신경망 모델이 대상 하수처리장에 한해서는 일반화되어 사용될 수 있다고 사료된다.

3.2. 현재 시점 기준 2일, 3일 뒤 예측

현재 시점 기준 2일 뒤, 3일 뒤 각 유입 유량, COD, SS, TN의 예측을 위해 epoch 수를 100으로 고정된 후, 가중치 값의 변화만을 통해 현재 시점 기준 1일 뒤 예측을 위해 사용된 인공신경망과 같은 입력 변수들과 구조를 가지는

인공 신경망의 학습이 이루어졌다. Fig. 6과 7은 현재 시점 기준 2일 뒤, 3일 뒤 예측을 위한 인공 신경망의 학습된 결과와 검증 결과를 보여준다. Table 4와 Table 5는 개발된 인공 신경망의 예측 성능 평가를 위한 정량적 지표로 사용된 상대 오차율을 보여준다. 이를 통해, 현재 시점 기준 2일 뒤, 3일 뒤 예측을 위해 개발된 인공 신경망 모델은 과적합(Overfitting)의 문제를 발생시키지 않으면서 각 목표 변수들의 변화 거동을 적절하게 예측하고 있다는 것을 알 수 있었다. 그러므로, 현재 시점 기준 1일 뒤 예측을 위한




Fig. 6. 2 day-ahead prediction with ANN. (a) Prediction of flowrate, (b) Prediction of COD_{Mn}, (c) Prediction of SS, (d) Prediction of TN




Fig. 7. 3 day-ahead prediction with ANN. (a) Prediction of flowrate, (b) Prediction of COD_{Mn}, (c) Prediction of SS, (d) Prediction of TN

인공 신경망과 같은 구조를 가지면서, 단지 연결 가중치 값만이 다른, 현재 시점 기준 2일 뒤, 3일 뒤 예측을 위한 인공 신경망 모델이 적절하게 개발되었다고 할 수 있다.

4. 결론

본 연구에서는 표준활성슬러지 공정으로 운영되고 있는 B시 A하수처리장을 대상으로 공정 운영에 있어 공정 이상을 초래하는 주요한 외란 중 하나인 유입 유량 및 유입 성분들의 농도를 예측 가능한 모델을 개발하고자 하였다. 이를 위해 대상 하수처리장으로부터 장기간의 데이터들이 확보되었고, 시간에 따라 변화하는 많은 변수들을 가짐으로써 보정하기 어렵다는 단점을 가지는 결정론적 모델에 기반하고 단지 유입 유량만의 예측에 국한된 기존의 유입수 예측 모델의 한계점을 극복하기 위해 인공 신경망 기법이 적용되었다. 그 결과, 신경망의 학습을 통해 일반화될 수 있는

현재 시점 기준 1일 뒤, 2일 뒤, 3일 뒤의 대상 하수처리장의 유입 유량, COD_{Mn}, SS, TN의 예측이 가능한 인공 신경망 모델이 성공적으로 개발될 수 있었다. 본 연구에서 개발된 유입수 예측 모델은 기존의 활용되고 있는 공정 성능 예측 모델의 활용성을 높인다는 측면에서 보았을 때, 공정 성능 예측 모델과의 결합을 통해 미래의 공정 상태에 대한 평가를 가능하게 하고, 이를 바탕으로 발생할 수 있는 공정 이상에 사전에 대처하여 발생할 수 있는 공정 이상을 최소화할 수 있는 다양한 제어 전략들을 수립하는 데 있어 유용하게 활용될 수 있을 것이라고 기대된다. 하지만, 하수처리장의 유입수가 하루 중 시간에 따라 변동이 심하다는 점을 감안할 때, 본 연구에서 개발된 인공 신경망 모델이 하루 중 시간에 따른 유입 유량 및 유입 성분들의 변화 패턴들을 적절히 묘사 가능한 인공 신경망 모델 또는 다른 통계학적 모델과의 결합이 이루어져야만 보다 더 나은 제어 전략을 수립하는데 유용할 것이라고 사료된다.

사 사

본 연구는 환경부의 차세대핵심환경기술개발사업(과제번호 2006-07001-0104-0, 데이터마이닝 기법에 의한 하수처리장 운전의 예측진단)에 의해 행해졌음을 밝힙니다.

참고문헌

- Cartensen, J., Nielsen, M. K. and Strandbæk, H. (1998). Prediction of hydraulic load for urban storm control of municipal WWT plant. *Water Science & Technology*, **37**(12), pp. 363-370.
- Choi, D. J. and Park, H. K. (2001). A hybrid artificial neural network as a software sensor for optimal control of a wastewater treatment process. *Water Research*, **35**(16), pp. 3959-3967.
- El-Din, A. G. and Smith, D. W. (2002). A neural network model to predict the wastewater inflow incorporating rainfall events. *Water Research*, **36**, pp. 1115-1126.
- Gernaey, K. V., van Loosdrecht, M. C. M., Henze, M., Lind, M. and Sten B. Jørgensen (2004). Activated sludge wastewater treatment plant modelling and simulation: state of the art. *Environmental Modeling & Software*, **19**, pp. 763-783.
- Grieu, S., Traoré, A., Polit, M. and Colprim, J. (2005). Prediction of parameters characterizing the state of a pollution removal biologic process. *Engineering Application of Artificial Intelligence*, **18**, pp. 559-573.
- Hagan, M. T., Demuth, H. B. and Beale, M. H. (1996). *Neural network design*, PWS Publishing, Boston, MA.
- Jang, J. S. R., Sun, C. T. and Mizutani, E. (1997). *Nuero-fuzzy and soft computing*, Prentice-Hall, Inc., New Jersey.
- Kim, J. R., Ko, J. H., Im, J. H., Lee, S. H., Kim, S. H., Kim, C. W. and Park, T. J. (2006). Forecasting influent flowrate and composition with occasional data for supervisory management system by time-series model. *Water Science & Technology*, **53**(4-5), pp. 185-192.
- Kim, Y. J. (2006). Development of inference models and diagnosis algorithms using intelligent methods for sequencing batch reactor operation. Ph. D. thesis, Pusan National University, Korea.
- Mjalli, F. S., Al-Asheh, S. and Alfadala, H. E. (2007). Use of artificial neural network black-box modeling for the prediction of wastewater treatment plants performance. *Journal of Environmental Management*, **83**(3), pp. 329-338.
- Shioya, S., Shimizu, K. and Yoshida, T. (1999). Knowledge-based design and operation of bioprocess system. *Journal of Bioscience and Bioengineering*, **87**(3), pp. 261-266.
- The MathWorks, Inc. (2000). *Neural network toolbox user's guide*, 3 Apple hill drive, Natick.
- Yoo, C. K., Vanrolleghem, P. A. and Lee, I. B. (2003). Nonlinear modeling and adaptive monitoring with fuzzy and multivariate statistical methods in biological wastewater treatment plants. *Journal of Biotechnology*, **105**, pp. 135-163.