

인공신경망 및 통계적 방법을 이용한 오존 형성의 예측

오세천 · 여영구*

천안공업대학 환경공학과

* 한양대학교 화학공학과

Prediction of Ozone Formation Based on Neural Network and Stochastic Method

Sea Cheon Oh · Yeong-Koo Yeo*

Dept. of Environmental Eng., Chonan National Technical College

* Department of Chemical Engineering, Hanyang University

요 약

인공신경 회로망과 통계적 방법을 이용하여 오존 형성의 예측에 관한 연구를 수행하였다. 파라미터 평가 방법으로는 실시간 파라미터를 평가하기 위하여 ELS 및 RML 방법이 사용되었으며 오존 형성의 모델로는 ARMAX 모델을 사용하였다. 또한 3층 구조를 갖는 인공신경 회로망 방법을 이용하여 오존 형성의 예측 시험을 수행하였으며 본 연구에 사용된 통계적 방법의 성능을 평가하기 위하여 오존 형성의 예측결과를 실제 자료와 비교 분석을 하였다. 실제 자료와의 비교를 통하여 파라미터 평가 방법 및 인공신경 회로망 방법에 근거한 예측방법이 제한된 예측 구간 내에서 만족할 만한 성능을 보임을 확인할 수 있었다.

ABSTRACT : The prediction of ozone formation was studied using the neural network and the stochastic method. Parameter estimation method and artificial neural network(ANN) method were employed in the stochastic scheme. In the parameter estimation method, extended least squares(ELS) method and recursive maximum likelihood(RML) were used to achieve the real time parameter estimation. Autoregressive moving average model with external input(ARMAX) was used as the ozone formation model for the parameter estimation method. ANN with 3 layers was also tested to predict the ozone formation. To demonstrate the performance of the ozone formation prediction schemes used in this work, the prediction results of ozone formation were compared with the real data. From the comparison it was found that the prediction schemes based on the parameter estimation method and ANN method show an acceptable accuracy with limited prediction horizon.

Keywords : stochastic prediction method, ozone formation, parameter estimation, ANN

1. 서 론

여러 방출원으로부터 형성되는 대기오염 물질은 직접적 혹은 간접적으로 인간의 건강에 영향을 미치고 있다. 특히 최근에 오존은 인간이나 동물의 건강 뿐만이 아닌 식물 및 토양 그리고 기후 변화에도 중요한 영향을 미치고 있음이 확인되고 있다. 따라서 지표면에서의 오존 농도를 정확히 평가하는 것은 산업 성장 및 사회 발전 계획에 있어서 반드시 고려되어야만 하는 매우 중요한 요소로 작용하게 되었다. 이러한 오존은 대부분 직접적인 방출보다는 화학반응에 의하여 형성되며 따라서 오존의 형성과정을 해석하기 위해서는 대기에서 일어나는 화학반응을 이해하고 규명하는 것이 필수적이다. 그러나 대기 중에서 일어나는 반응은 대부분 반응물질이 매우 낮은 농도를 갖고 있을 뿐만 아니라 반응에 관여하는 반응물질의 종류가 매우 많기 때문에 대기오염에 대한 실험적인 조사를 하는 것은 매우 번거로운 일이다. 그럼에도 불구하고 최근 대기오염의 실험적 접근을 위한 많은 노력이 이뤄지고 있으며 특히 대기오염에 있어서의 오존의 형성을 규명하기 위한 연구가 활발히 진행중이다[1-3].

컴퓨터의 발달로 과거에는 이론에 불과했던 많은 수학적 방법들이 현실적으로 응용이 가능하게 됨에 따라 컴퓨터를 이용하여 대기중의 오존 형성을 예측하는 것은 매우 흥미로운 관심 분야가 되었다. Oh와 Yeo[4]는 세부적인 반응 모델식을 이용하여 C_3H_6 - NO_x -wet air 시스템에서의 빛의 강도, 초기 반응물질의 농도 그리고 온도 및 습도 등의 반응 변수에 따른 오존 형성 과정을 모사 하였으며 계속되는 연구[5]에서 쌍일차 모델(bilinear model) 및 방정식 오차법(equation error method)을 이용하여 오존 형성량을 예측하고자 하였다. 현재 도심 및 지역의 대기오염 모델로는 방출원 및 광화학반응 그리고 오염물질의 감소 요인이 모두 결합된 대기 확산식이 대부분 이용되고 있다.[6] 그러나 이러한 대기 확산식은 방대한 컴퓨터 용량을 필요로 할뿐만 아니라 풍향 및 확산 그리고 대기 오염원들의 예측 불가능한 변화로 인하여 다른 어떤 대기오염 물질보다도 정확성을 필요로 하는 오존의 형성량 예측에 적용되기에는

아직 많은 문제점을 갖고 있다.

따라서 본 연구에서는 파라미터 평가 방법 및 인공신경 회로망 방법을 이용한 오존 형성량의 예측 시스템 개발에 관한 연구를 수행하였다. 파라미터 평가 방법에는 실시간 파라미터를 평가하기 위하여 ELS(extended least squares) 및 RML(recursive maximum likelihood) 방법이 사용되었으며 오존 형성의 모델로는 ARMAX(autoregressive moving average model with external input) 모델을 사용하였다. 또한 3층(layer) 구조를 갖는 인공신경 회로망 방법을 이용하여 오존 형성의 예측 시험을 수행하였으며 본 연구에 사용된 통계적 방법의 성능을 평가하기 위하여 오존 형성의 예측결과를 실제 자료와 비교분석을 하였다.

2. 파라미터 평가 방법

최근 효율적인 파라미터 평가 방법의 개발에 관하여 활발한 연구가 진행되어 왔다[7-9]. Oh와 Yeo[10]는 ARMA(autoregressive moving average) 모델을 이용하여 실시간 파라미터 평가에 관한 연구를 수행하였다. 그러나 ARMA 모델은 시스템의 출력에 대한 외란의 작용을 효과적으로 나타내지 못하는 단점이 있다. 본 연구에서 예측하고자 하는 오존과 같은 대기오염 물질은 외란에 많은 영향을 받게된다. 따라서 본 연구에서는 외란의 영향을 보다 정확히 고려해 줄 수 있는 ARMAX 모델을 파라미터 평가를 위한 모델로 사용하였다. 오존 형성에 대한 이산시간(discrete time) 모델식을 ARMAX 모델을 이용하여 나타내면 다음과 같다.

$$y(t+1) = \sum_{i=1}^n a_i y(t+1-i) + \sum_{j=1}^m b_{j,i} u_j(t+1-d-i) + \sum_{j=1}^m c_j e(t+1-i) + e(t+1) \quad (1)$$

식 (1)에서 n 과 m 은 모델식의 차수 및 입력자료의 수를 각각 의미한다. 또한 y 는 오존 농도를 그리고 u 는 오존 형성의 예측 모델에 이용되는 기타 다른 대기오염 물질의 농도를 각각 나타낸다. 식 (2)에 대하여 실제 예측에 이용되는 예측 모델식은 다

음과 같이 표현된다.

$$\begin{aligned} y^*(t+1) &= \sum_{i=1}^n a_i^* y(t+1-i) + \sum_{j=1}^m \\ &\sum_{i=1}^d b_{ji}^* u_j(t+1-d-i) + \sum_{i=1}^m c_i^* e(t+1-i) \\ &= \theta^*(t+1)^T \phi(t) \end{aligned} \quad (2)$$

식 (2)에서 θ^* 및 ϕ 는 모델의 파라미터와 식 (1)의 입·출력자료로 각각 이뤄진 벡터를 의미며 또한 d 는 오존 형성 반응의 시간지연 상수를 나타낸다. 모델 파라미터 벡터 θ^* 를 평가하기 위하여 본 연구에서는 다음과 같은 연속 파라미터 평가 알고리즘(recursive parameter estimation algorithm)[12]를 이용하였다.

$$\theta^*(t+1) = \theta^*(k) + F(t)\phi(t)\eta(t+1) \quad (3)$$

여기서 $\theta^*(t)^T = [a_1^*(t) \dots a_n^*(t), b_{11}^*(t) \dots b_{1n}^*(t), \dots, b_{m1}^*(t) \dots b_{mn}^*(t), c_1^*(t) \dots c_m^*(t)]$

식 (3)에서 예측오차 η 는 다음과 같이 정의된다.

$$\begin{aligned} \eta(t+1) &= y(t+1) - y^*(t+1) \\ &= \frac{y(t+1) - \theta^*(t)^T \phi(t)}{1 + \phi(t)^T F(t) \phi(t)} \end{aligned} \quad (4)$$

또한 식 (3)에서의 이득(gain) F 는 다음과 같은 식을 이용하여 계산하였다.

$$F(t+1) = \frac{1}{\lambda_1(t)} \left[F(t) - \frac{F(t)\phi(t)\phi(t)^T F(t)}{\frac{\lambda_1(t)}{\lambda_2(t)} + \phi(t)^T F(t)\phi(t)} \right] \quad (5)$$

여기서 $0 < \lambda_1(t) \leq 1$

$$0 \leq \lambda_2(t) < 2$$

$$F(0) = \begin{bmatrix} GI & & 0 \\ & \cdot & \\ 0 & & GI \end{bmatrix}$$

$$GI > 0$$

파라미터 평가 방법은 입·출력자료 벡터 ϕ 를 어떠한 형태로 구성하는가에 따라 방법이 나뉘어 지는데 본 연구에서 사용한 ELS 및 RML 방법의 경우 다음의 식 (6), (7)과 같이 각각 ϕ 가 정의 된다.

$$\begin{aligned} \phi(t)^T &= [y(t) \dots y(t-n+1), u_1(t) \dots u_1(t-n+1), \dots, \\ &u_m(t) \dots u_m(t-n+1), \eta(t) \dots \eta(t-n+1)] \end{aligned} \quad (6)$$

$$\begin{aligned} \phi(t)^T &= \frac{1}{C^*(t, q^{-1})} [y(t) \dots y(t-n+1), u_1(t) \dots \\ &u_1(t-n+1), \dots, u_m(t) \dots u_m(t-n+1), \\ &\eta(t) \dots \eta(t-n+1)] \end{aligned} \quad (7)$$

RML 방법에 대한 식 (7)에서 $C^*(t, q^{-1})$ 는 다음과 같이 표현되며 q^{-1} 는 다항식 연산자(polynomial delay operator)를 의미한다.

$$C^*(t, q^{-1}) = 1 + c_1^*(t)q^{-1} \quad (8)$$

본 연구에서는 식 (2)~(8)을 이용하여 오존 형성량을 예측하였다.

3. 인공신경 회로망 방법

인공신경 회로망 방법은 모델링, 제어, 패턴인식(pattern recognition) 및 예측 등에 널리 이용되어왔다[12]. 신경 회로망은 유니트(unit), 혹은 셀(cell)이라는 불리는 PE(processing element)의 상호 회로망(network)형태로 결합되어 있으며 하위의 PE층에서의 상위의 PE층으로 신호가 전파해 가는 계층구조로 되어있다. 이 때 각각의 결합 강도를 학습에 의하여 변화시킬 수도 있으며 또한 각 PE는 병렬로 동작할 수도 있다. 이러한 신경 회로망은 회로망내의 PE가 각각 어떤 타이밍으로 동작하는가에 따라서도 그 특성이 달라진다. 본 연구에서는 3층 구조를 갖는 인공신경 회로망 방법을 이용하였으며 첫 번째 층은 입력층(input layer), 그리고 마지막 층은 출력층(out-

put layer)을 각각 의미하며 입력층과 출력층 사이의 두 번째 층은 입력층으로부터의 입력을 받아 학습된 방식에 따라 출력층으로 신호를 보내는 중간층(intermediated layer)역할을 수행하게 된다. 여기서 입력층과 중간층은 모두 비선형 입·출력 응답 모델을 사용하게 되며 출력층은 입력 패턴의 분류에 대응하는 신호에 따라 계산값을 출력한다. 따라서 기본적으로 인공신경 회로망의 성능은 요구되는 출력값과 실제의 출력값 사이의 오차를 최소화하도록 적용되는 학습 방법에 따라 좌우된다[13-14].

본 연구에 사용된 인공신경 회로망의 입력층과 중간층은 각각 i 개와 j 개의 뉴런(neuron)으로 이뤄져 있으며 출력층에는 최종적으로 오존의 예측값을 출력하는 한 개의 뉴런으로 이뤄져 있다. 또한 각 뉴런은 편향 가중치(bias weight)의 영향을 받게 된다. 각 뉴런의 내부에서는 가중치가 고려된 입력값의 합이 계산되며 넷(net)라고 불리는 이러한 값은 이극 시그모이드 함수(bipolar sigmoid function)에 의하여 전환된 후 다음 층의 뉴런으로 보내진다. 본 연구에서는 다음과 같이 -1과 1사이의 값을 갖는 이극 시그모이드 함수를 사용하였다.

Bipolar Sigmoid Function

$$F(net) = \frac{2}{1 + \exp(-\lambda \cdot net)} - 1 \quad (9)$$

식 (9)에서 λ 는 net 값이 0인 근처에서의 함수 $F(net)$ 의 경사도(steeptness)를 결정하는 뉴런 이득(gain)에 비례한다[12].

본 연구에 적용된 신경 회로망의 입력층에는 오존, SO₂, NO₂, NO, THC(total hydrocarbon), CO 및 CH₄의 농도 그리고 측정 시간에 대한 과거 및 현재의 자료가 입력값으로 주입된다. 또한 중간층에는 보다 정확한 예측 결과를 얻기 위하여 30개의 뉴런을 사용하였으며 출력층은 본 연구에서 예측하고자 하는 값이 오존에 한정됨으로 하나의 뉴런으로 구성하였다. 각 가중치는 신경 회로망이 학습되는 과정에 계산되며 본 연구에서는 이러한 신경 회로망을 학습시키기 위하여 EBP(error back propagation) 알고리즘을 적용하였다. 학습 과정시 가중치의 초기값은 난수치로 초기화하였다. 입력층으로 주입된 입력값은

출력층에 도달할 때까지 중간층의 뉴런들을 통하여 퍼져나가게 되며 신경 회로망에 의하여 출력층으로부터 계산된 출력값을 실제의 측정값과 비교하여 이때 발생하는 오차로부터 식 (10)을 이용하여 가중치를 다시 조절하였다.

$$\begin{aligned} \text{new weight change} &= \eta \times \text{output error} \times \text{input} + \\ &\alpha \times \text{previous weight change} \end{aligned} \quad (10)$$

식 (10)에서 η 와 α 는 각각 학습속도 및 모멘텀(momentum)을 의미하며 본 연구에서는 예측오차를 최소화 할 수 있도록 시행오차법(trial error method)을 이용하여 구하였다. 이렇게 새롭게 결정된 가중치를 이용하여 사전에 결정된 범위 내에 오차가 만족될 때까지 반복적으로 학습과정을 수행하였다. 학습이 완료된 신경 회로망은 실제 오존 형성을 표현하는 함수 $P(X)$ 에 대한 근사함수 $P(V,W,X)$ 를 의미하게 되며 따라서 이 함수를 이용하여 오존 형성량을 예측하였다. 여기서 X 는 입·출력자료로 이뤄진 벡터를 그리고 V 와 W 는 입력층 뉴런들로부터 중간층 뉴런들로 연결된 가중치 매트릭스(matrix)와 중간층 뉴런들로부터 출력층 뉴런들로 연결된 가중치 매트릭스(matrix)를 각각 나타낸다. 이러한 근사함수는 다음과 같은 식으로 표현된다.

$$O = F \left(\sum_j W_j H_j + \Phi \right) \quad (11)$$

$$H_j = F \left(\sum_i V_{ij} X_i + \Phi_j \right) \quad (12)$$

식 (11)과 (12)에서 F 는 시그모이드 함수를 의미하며 X_i 와 O 는 선형적으로 표준화된 입력 및 출력값을 의미한다. H_j 는 중간층 뉴런으로부터의 출력값을 나타내며 W_j 는 중간층 뉴런과 출력층 뉴런 사이의 가중치를, 그리고 V_{ij} 는 입력층 뉴런과 중간층 뉴런 사이의 가중치를 각각 나타낸다. 또한 Φ_j 와 Φ 는 중간층의 뉴런과 출력층 뉴런의 편향 가중치를 의미한다.

본 연구에서는 시간에 따라 계속적으로 변하는 경우 예측값의 정확도를 높이기 위하여 각 샘플링 순간마다 신경 회로망을 적용시킬 수 있는 슬라이딩 윈도우(sliding window) 학습과정을 함께 사용하였

다[12]. 또한 본 연구에 사용된 실제의 대기오염 물질의 측정자료는 시간 단위로 이뤄져 있으며 오존의 경우 24시간을 주기로 하여 발생 추이가 변함으로 본 연구에서는 학습시간을 24시간으로 구성하였으며 신경 회로망의 학습을 위한 입·출력값은 실제 자료값의 상한 및 하한값에 대하여 0~1의 값이 되도록 표준화하였다. 그리고 최종적으로 인공신경 회로망으로부터 계산된 출력값을 다시 실제의 오존 농도에 대한 범위로 환산하여 실제의 오존 농도와 비교하였다.

4. 결과 및 고찰

본 연구에서는 서울시 대기보전과로부터 제공된 1996년도 5월 11일부터 14까지 4일간의 서울시 오존 및 대기오염 물질의 측정자료를 이용하였다. Fig. 1과 2는 ELS 파라미터 평가 방법을 이용한 경우 예측 구간의 증가에 따른 오존 형성의 예측 결과를 보여주고 있다. 이때 오존의 형성량을 예측하기 위하여 ELS 방법에 사용된 ARMAX 모델의 파라미터에 대한 초기값이 매우 불명확함으로 본 연구에서는 식(5)의 초기 이득값으로 $GI=1000$ 과 같은 매우 큰 값을 사용하였으며 모델의 초기값으로는 모두 0.1로 가정하였다. 또한 식(5)에서의 $\lambda_1(t)$ 과 $\lambda_2(t)$ 값으로는 시행오차법에 의하여 결정된 0.99와 1.5을 각각 사용하였으며 모델의 시간 지연 상수로는 1시간을 그리고 모델의 차수로는 2차 모델을 각각 적용하였다.

Fig. 1과 2로부터 2시간까지의 예측 구간에 대해서는 만족할 만한 예측 결과를 보여주었으나 이후 시간이 증가함에 따라 예측 오차 또한 증가함을 알 수 있었다. Fig. 3과 4는 RML 파라미터 평가 방법을 이용한 경우 예측 구간의 증가에 따른 오존 형성의 예측 결과를 보여주고 있다. RML 방법에 적용된 상수 및 조건은 앞의 ELS 방법에 적용된 값과 같은 값을 적용하였다. Fig. 3과 4로부터 ELS 방법의 경우와 같이 2시간까지의 예측 구간에 대해서는 만족할 만한 예측 결과를 보여 주었으나 이후 시간이 증가함에 따라 예측 오차가 증가함을 알 수 있었다. 다만 ELS 방법의 경우 예측 구간이 증가할수록 예측 오차가 실제값보다 큰 방향으로 증가하였으나 RML 방법

의 경우 이와는 반대로 예측 오차가 실제값보다 작은 방향으로 증가하였다.

ELS 방법과 RML 방법을 이용한 경우 모델의 시간 지연 상수의 변화에 따른 오존 형성의 예측 결과를 Fig. 5와 6에 각각 나타내었다. Fig. 5와 6으로부터 ELS 방법 및 RML 방법 모두 1시간의 모델 지연 상수를 사용한 경우 가장 양호한 예측 결과를 얻을 수 있었다. 따라서 이로부터 오존의 형성과 관련된 각 대기오염 물질의 농도 변화는 1시간 이내에 오존의 형성에 영향을 미치기 시작할 것으로 판단된다. 그러나 이러한 현상의 보다 명확한 확인을 위해서는 보다 많은 연구가 필요할 것으로 생각된다. Fig. 7과 8은 모델의 차수에 따른 ELS 방법 및 RML 방법을 이용한 경우의 오존 형성의 예측 결과를 보여주고 있다. 그림으로부터 1차 모델을 이용한 경우에 비하여 2차 모델을 이용하였을 경우가 ELS 방법과 RML 방법 모두 보다 양호한 예측 결과를 보여주고 있음을 확인할 수 있다. 이러한 결과로부터 오존 형성 반응은 1차 반응 모델보다는 2차 반응 모델에 보다 유사할 것으로 판단되며 이는 Oh와 Yeo[4,5]의 연구 결과와도 일치함을 알 수 있다.

Fig. 9는 ELS 방법과 RML 방법으로부터 얻은 예측값을 평균하여 실제의 오존 농도와 비교한 그림이다. 이때 모델의 차수와 시간 지연 상수는 앞의 연구 결과로부터 가장 만족할 만한 예측 결과를 보여준 1차 모델과 1시간을 각각 사용하였다. Fig. 9로부터 알 수 있듯이 한 방법을 사용한 경우에 비하여 보다 양호한 예측 결과를 얻을 수 있음을 확인할 수 있다. 이는 Fig. 1~4로부터 본 연구에 적용된 두 파라미터 평가 방법이 각각 상반된 방향으로 예측 오차를 발생 시키기 때문에 상호 보완적인 역할을 수행한 결과로 판단된다. 또한 두 방법의 평균값을 사용한 경우 3시간까지 만족할 만한 예측 결과를 얻을 수 있었다.

Fig. 10은 인공 신경 회로망 방법을 이용한 경우의 오존 형성량의 예측 결과를 나타내고 있다. 입력자료는 측정시간과 대기 오염물질 즉 오존, NO_2 , SO_2 , THC, CH_4 , CO 그리고 NO의 측정 농도로 구성되어 있으며 뉴런을 학습시키기 위한 각 대기 오염물질의 상한값 및 하한값으로는 오존의 경우 0~0.09, SO_2 는 0~0.03, NO_2 는 0~0.12, CO는 0~2,




Figure 1. One and two hours ahead prediction results of O₃ formation using ELS method




Figure 4. Three and five hours ahead prediction results of O₃ formation using RML method




Figure 2. Three and five hours ahead prediction results of O₃ formation using ELS method




Figure 5. One hour ahead prediction results of O₃ formation using ELS method for the change of model time delay

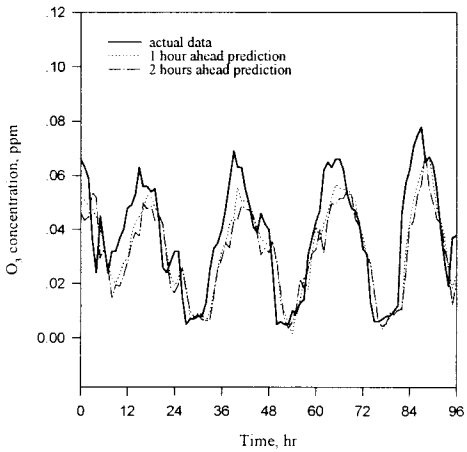


Figure 3. One and two hours ahead prediction results of O₃ formation using RML method




Figure 6. One hour ahead prediction results of O₃ formation using RML method for the change of model time delay




Figure 7. One hour ahead prediction results of O₃ formation using ELS method for the change of model order




Figure 9. Prediction results of O₃ formation using the average of ELS and RML method for the change of prediction horizon




Figure 8. One hour ahead prediction results of O₃ formation using RML method for the change of model order




Figure 10. Prediction results of O₃ formation using ANN with 24 hours learning data set (error limit in learning = 0.05)

THC는 0~0.04, NO는 0~0.25 그리고 CH₄에 대해서는 0~0.038의 값을 각각 사용하였다. 신경 회로망을 학습시키기 위해 사용된 EBP 알고리즘에는 24개의 패턴을 사용하였으며 식 (9)와 (10)의 λ 값으로는 1을 그리고 η 및 α 값으로는 모두 0.5를 사용하였다. Fig. 10으로부터 예측 구간이 증가할수록 파라미터 평가법의 경우와 같이 예측 오차가 증가함을 알 수 있었다. 또한 오존 관리 시스템에 있어서 가장 중요시되는 최대 오존 발생량에 대한 예측 결과를 보면 5시간의 예측 구간에 대해서도 하루중의 최대 오존 발생량에 있어서는 만족할 만한 결과를 보여주고

있다. 그러나 안정성에 있어서는 파라미터 평가 방법에 비하여 매우 불안함을 확인할 수 있었다. 이러한 이유는 파라미터 평가 방법의 경우 근본적으로 오존 형성반응에 대한 이산시간의 반응 모델식을 사용함으로써 반응 물질만을 고려해도 시간에 따라 비교적 안정적인 결과를 얻을 수 있으나 인공신경 회로망 방법의 경우 학습방법 및 튜닝에 의하여 그 성능이 좌우됨으로 오존 형성에 매우 커다란 영향을 미치는 날씨 및 습도 그리고 풍향 등과 기후 조건을 입력자료로 사용하지 않았기 때문으로 여겨진다. 따라서 보다 만족할 만한 오존 형성량 예측 결과를 얻기 위해

서는 매우 불규칙하게 변하는 기후 변화 등을 고려할 수 있는 예측 방법의 개발에 관한 연구가 필요할 것으로 판단된다.

5. 결 론

파라미터 평가 방법과 인공신경 회로망 방법 등의 통계적 방법을 이용하여 오존 형성의 예측에 관한 연구를 수행하였으며 이로부터 얻은 예측값을 실제의 오존 농도와 비교하였다. 비록 날씨 및 습도 그리고 풍향 등과 같은 예측 불가능한 기후 조건 등에 의하여 오존의 형성량 예측에 많은 어려움이 있다 할지라도 본 연구에서 적용한 통계적 방법으로부터 제한된 예측 구간에 대하여 만족할 만한 예측 결과를 얻을 수 있었다. 또한 최대 오존 발생량의 예측에 있어서는 예측 구간이 증가함에 따라 신경 회로망 방법이 파라미터 평가 방법에 비하여 보다 정확한 예측 결과를 보여 주었으나 전체적으로 예측값의 안정성에 있어서는 파라미터 평가 방법이 보다 우수함을 보였다. 그러나 예측 구간이 증가할수록 두 방법에 의한 오존 형성량의 예측 오차 또한 모두 증가함을 보였으며 따라서 만족할 만한 예측 구간을 보다 확장하기 위해서는 날씨 및 습도 그리고 풍향 등과 같은 기후 변화의 영향을 고려해 줄 수 있는 예측 방법의 개선이 필요하다고 판단된다.

참 고 문 헌

1. Carter, W. P. L., A. M. Winer, K. R. Darnal and J. N. Jr. Pitts, Smog Chamber Studies of Temperature Effects in Photochemical Smog, *Environ. Sci. Technol.*, 13, 1094 (1979)
2. Sakamaki F., M. Okuda, H. Akimoto and H. Yamazaki, Computer Modeling Study of Photochemical Ozone Formation in the Propene-Nitrogen Oxides-Dry Air System. Generalized Maximum Ozone Isopleth, *Environ. Sci. Technol.*, 16, 45 (1982)
3. Costanza V. and J. H. Seinfeld, Optimal Emission Control Strategies for Photochemical Smog, *Environ. Sci. Technol.*, 16, 98 (1982)
4. S. C. Oh and Y. K. Yeo, Modeling and Simulation of Ozone Formation from A Propene-Nitrogen Oxide-Wet Air Mixture in A Smog-Chamber, *Korean J. Chem. Eng.*, 15, 20 (1998)
5. 오세천, 여영구, 대기오염에 있어서 오존형성에 관한 모사 및 모델인식, *환경과학논문집*, 19, 17 (1998)
6. Scheffe R. D. and R. E. Morris, A Review of the Development and Application of the Urban Airshed Model, *Atmos. Environ.*, 27B, 23 (1993)
7. Elsayed E. A. and T. O. Boucher, *Analysis and Control of Production Systems*, Prentice-Hall, Inc., Englewood Cliffs, New Jersey (1994)
8. Frick, P. A. and A. S. Valvavi, Estimation and Identification of Bilinear Systems, *Atomat. Contr. Theory and Applications*, 6, 1 (1978)
9. Kubrusly, C. S., Identification of Discrete-Time Stochastic Bilinear Systems, *Int. J. Control*, 33, 291 (1981)
10. S. C. Oh and Y. K. Yeo, On-Line Identification of Interacting Two-Tank System, *Korean J. Chem. Eng.*, 13, 422 (1996)
11. Landau, I. D., *System Identification and Control Design*, Prentice-Hall, Inc., Englewood Cliffs, New Jersey (1994)
12. Zurada, J. M., *Introduction to Artificial Neural Systems*, PWS Publishing Company, Boston, (1995)
13. Funahashi, K., On the Approximate Realization of Continuous Mappings by Neural Networks, *Neural Networks*, 2, 183 (1989)
14. Sprecher, D. A., A universal mapping for Kolmogorov's superposition theorem, *Neural Networks*, 6, 1089 (1993)