

발전소에서의 SO_x 공정 모사, 모니터링 및 패턴 분류

SO_x Process Simulation, Monitoring, and Pattern Classification in a Power Plant

최상욱, 유창규, 이인범

(Sang Wook Choi, Chang Kyoo Yoo and In-Beum Lee)

Abstract : We propose a prediction method of the pollutant and a synchronous classification of the current state of SO_x emission in the power plant. We use the auto-regressive with exogeneous (ARX) model as a predictor of SO_x emission and use a radial basis function network (RBFN) as a pattern classifier. The ARX modeling scheme is implemented using recursive least squares (RLS) method to update the model parameters adaptively. The capability of SO_x emission monitoring is utilized with the application of the RBFN classifier. Experimental results show that the ARX model can predict the SO_x emission concentration well and ARX modeling parameters can be a good feature for the state monitoring. In addition, its validity has been verified through the power spectrum analysis. Consequently, the RBFN classifier in combination with ARX model is shown to be quite adequate for monitoring the state of SO_x emission.

Keywords : ARX modeling, radial basis function, recursive least squares, power spectrum, process simulation, SO_x

I. 서론

현재 포스코(POSCO) 철강공장 내 발전소에서는 연료와 부생가스를 이용하여 전기를 생산하고 있다. 연료는 외부에서 공급되는 반면 Coke Oven Gas (COG), Blast Furnace Gas (BFG), Linz Donawitz Gas (LDG)와 같은 부생가스(off gas)는 다른 생산 공정에서 사용된 후 나온 부산물로서 발전소에 에너지 절감 차원에서 공급된다. 이 연료와 부생가스는 끼너에서 연소되어 에너지원이 되는데, 연소과정에서 SO_x와 NO_x 등의 대기오염물질이 발생된다.

시간에 따라 사용되는 연료의 양이 각기 다르고 연소과정 또한 복잡하여 이를 모사하기 위해서는 보다 효율적인 공정 모델링 기법이 요구되어진다. 특히, 연속적으로 변화하는 공정을 모델링 하는데 있어서 일반적인 정적 모델(static model)이 아닌 동적 모델(dynamic model)을 고려해야 한다.

동적 모델링 기법은 매우 오랫동안 연구되어 왔다. Gauss는 처음으로 반복 최소자승법(recursive least squares method)을 유도하였고, Box와 Jenkins는 autoregressive with moving average(ARMA) 모델을 만들기 위한 최소자승법의 연속적 방법을 제안하였다[1]. 한편, 최근에는 다양한 분야에서 신경회로망(neural network)을 이용하여 공정 모델링이나 제어에 적용하는 사례가 늘고 있다[2]. Bozdar는 SO₂ 농도의 단기간 예측에 신경회로망을 적용하였고[3], Bakal 등은 화석연료를 사용하는 발전소에서의 NO_x와 CO의 발생 패턴을 시간 지연 신경회로망을 이용하여 예측하였다[4]. Comrie는 오존(O₃)의 발생을 예측하는데 신경회로망 모델과 회귀(regression) 모델을 비교하였다[5]. 또한, 손 등은 신경회로망

을 이용하여 서울 지역의 1차 대기 오염 물질의 양을 예측하였다[6].

날로 더해 가는 환경 규제로 인해 오염물질의 양을 최소화하려는 시도가 계속되고 있으며[7], 이를 위해 우선적으로 오염 물질의 방출 상태를 사전에 예측하는 것이 필수적이다. 따라서, 본 연구에서는 적응 반복 최소자승법(adaptive recursive least squares method)을 이용하여 발전소에서의 SO_x의 발생량을 예측하는 공정모델링방법을 제시하고, 몇 가지 방출 패턴을 RBFN(radial basis function network)를 이용하여 확인하였다. 더불어, ARX 모델계수는 SO_x의 방출량의 상태를 알 수 있는 중요한 지표가 될 수 있음을 파워스펙트럼(power spectrum)을 통해 확인하였다.

II. 공정 모사 및 모니터링 방법

본 연구에서는 실시간 SO_x 농도 공정 모사 (모델링) 및 모니터링 시스템의 개발에 중점을 두었다. 이는 복잡한 분산 처리, 뛰어난 학습 능력, 그리고 패턴화된 정보의 일반화 능력을 가진 신경회로망에 기반한다. 이 시스템은 적응 처리(adaptive processing)와 패턴 분류(pattern classification)의 두 부분으로 구성되어 진다. 우선 적응 처리 단계에서는 SO_x 방출 농도를 공정 모델링 방법을 이용하여 예측하게 된다. 발전소에서의 입출력 데이터를 이용하여 ARX 모델을 설계하여 연료 패턴에 따른 오염물질 방출량을 예측하게 되는데, 이 과정에서 모델 계수는 반복 최소자승법을 이용하여 추정된다. 또한, 모델 계수가 패턴 분류의 지표가 됨을 파워스펙트럼을 통해 확인한다. 둘째, 패턴 분류 단계에서는, 적응모델계수에 대해 RBFN을 이용하여 SO_x 방출 패턴을 인식한다. RBFN의 학습 후, 네트워크의 출력으로부터 현재 오염 물질 발생 패턴이 어떠한지를 인식할 수 있게 된다.

1. SO_x 발생량 공정모사 (예측 모델링)

철강 공장 내 발전소에서의 오염물질 발생량을 모사하기

논문접수 : 2002. 6. 13., 채택학정 : 2002. 8. 26.

최상욱 : 포항공과대학교(ghostzip@postech.ac.kr)

유창규 : 포항공과대학교(ckyoo@postech.ac.kr)

이인범 : 포항공과대학교(iblee@postech.ac.kr)

※ 본 연구는 BK 2 1프로젝트에 의하여 지원되었습니다.

위해서 ARX 모델을 구성하였고 계수 추정 방법으로서 반복 최소자승법을 사용하였다. 시스템이 선형 미분 방정식(linear differential equation)으로 표현될 수 있으면, 시스템으로부터의 불연속 데이터로부터 선형 차등 방정식(linear difference equation)을 유도할 수 있다[8]. 그러나, 불확정(stochastic) 시스템의 경우 미래의 값을 정확히 예측하는 것은 불가능하고, 대신 임의 변수(random variable)의 평균(mean), 분산(variance) 혹은 확률 밀도 함수(probabilistic density function)와 같은 몇 가지 특성을 알면, 가장 신뢰할만한 예측값을 구할 수 있다. ARX 모델의 일반적인 형태는 다음과 같다.

$$\begin{aligned} y(t) + a_1 y(t-1) + \cdots + a_{n_a} y(t-n_a) \\ = b_1 u(t-1) + b_2 u(t-2) + \cdots + b_{n_b} u(t-n_b) + e(t) \end{aligned} \quad (1)$$

여기서 $y(t)$ 은 시스템 출력, $u(t)$ 은 시스템 입력, $e(t)$ 는 측정 불가능한 순수 노이즈이다. n_a 와 n_b 는 각각 autoregressive부분과 exogeneous 부분의 차수이다.

ARX-RLS 방법의 목적은 다음 목적함수

$$V = \frac{1}{N} \sum_{t=1}^N \lambda^{N-t} (y(t) - \hat{y}(t))^2 \quad (2)$$

를 최소화하는 계수 a_i 와 b_i 를 추정하는 것이다. 여기서 목적함수는 가중 평균 오차 제곱합(weighted mean squared error)으로 나타나며, 예측 출력값은 $\hat{y}(t)$ 은 $\hat{y}(t) = \phi^T(t)\theta$ 으로 표현 가능하다. 여기서

$$\begin{aligned} \phi^T(t) &= [-y(t-1) - y(t-2) \cdots - y(t-n_a)] \\ u &= [(t-1)u(t-2) \cdots u(t-n_b)] \end{aligned} \quad (3)$$

$$\theta = [a_1 \ a_2 \cdots a_{n_a} \ b_1 \cdots b_2 \ b_{n_b}]^T \quad (4)$$

이다. $\phi^T(t)$ 은 회귀벡터(regression vector)라 부르고, θ 는 ARX 모델 계수 벡터, N 은 데이터 샘플(sample) 수, λ 는 망각상수(forgetting factor)이다. ARX 모델의 '모든 계수는 평균 오차 제곱의 최소화하도록 결정된다. 시변(time varying) 시스템의 경우, 시변 모델 계수는 최근에 측정된 공정 데이터에 보다 많은 가중치를 부여한 형태인 가중 평균 오차 제곱합을 최소화함으로서 구할 수 있다. 각 샘플링 시간마다 모델 계수를 연속적으로 재생산하기 위해서 망각 상수를 가진 반복 최소자승법을 이용한 계수 적응 알고리즘(parameter adaptation algorithm)이 사용된다. 일반적인 최소자승법은 모든 데이터가 수집된 후에 계수를 추정하지만, 반복 최소자승법에서는 샘플링 시간마다 계수의 추정이 이루어진다. 따라서, 연속 최소 제곱 방법은 계산 노드를 줄일 수 있으며, 계수를 연속적으로 시스템의 변화에 따라 재생산할 수 있는 장점을 가진다.'

반복 최소자승법은 다음의 식들로 표현된다.

$$\hat{\theta}(t) = \hat{\theta}(t-1) + K(t)(y(t) - \hat{y}(t)) \quad (5)$$

$$\hat{y}(t) = \phi^T(t)\hat{\theta}(t-1) \quad (6)$$

$$K(t) = \frac{P(t-1)\phi(t)}{\lambda + \phi^T(t)P(t-1)\phi(t)} \quad (7)$$

$$P(t) = \frac{P(t-1) - \frac{P(t-1)\phi(t)\phi^T(t)P(t-1)}{\lambda + \phi^T(t)P(t-1)\phi(t)}}{\lambda} \quad (8)$$

여기서 $K(t)$ 는 적응 이득(adaptation gain), $\hat{\theta}(t)$ 는 계수 추정치, $\hat{y}(t)$ 는 $t-1$ 에서의 관측치에 기반한 예측치, $P(t)$ 는 추정치의 공분산 행렬이다.

반복식(recursive formula)을 사용하기 위해, 망각상수의 값, 공분산 행렬과 적응 이득의 초기값 $\hat{\theta}(0)$ 과 $P(0)$ 이 필요하다. $P(0)$ 가 작다면, $K(t)$ 도 작아져 추정계수는 초기값 $\hat{\theta}(0)$ 으로부터 그다지 많이 변하지는 않는다. 반면에 $P(0)$ 가 크다면, $K(t)$ 가 큰 값을 갖게 되어 추정계수는 $\hat{\theta}(0)$ 값과는 상이한 값을 갖게 된다. 따라서, 계수의 초기값에 대하여 신뢰가 떨어질 경우 $P(0)$ 의 값을 크게 주면 된다. 망각상수 또한 수렴속도와 계수의 안정성이 영향을 준다. 대개 0.9에서 0.99사이의 값이 선택된다. 모델 계수가 적절히 재생산된다면, 동적 공정의 변화는 계수 추정치의 점진적인 변화로 나타나게 된다. 그러므로, 공정의 동적 상태 변화는 ARX 모델의 변화를 관측함으로써 감지할 수 있다.

2. 파워스펙트럼

ARX 모델 계수가 입력에 해당하는 패턴의 특성 벡터(feature vector)가 되는지의 여부를 파워스펙트럼을 통해 확인할 수 있다[9]. 확정 신호(deterministic signal)는 다른 주파수를 가지는 sine과 cosine함수의 합으로 표현 가능하다. 반면, 시간의 함수로 나타나는 시계열(time-series) 혹은 불확정(stochastic) 시스템의 경우에는 임의 함수(random function)의 주파수 분해는 자기공분산(autocovariance) 함수의 Fourier 변환을 통해 가능하다. 즉, 불확정 시스템에 대하여,

$$y(t) = G(q)u(t) + H(q)e(t) \quad (9)$$

이다. G 와 H 를 안정한 필터라고 하면, $y(t)$ 는 준정상(quasi-stationary) 상태이고, $y(t)$ 의 스펙트럼 $\Phi_y(\omega)$ 와 $y(t)$ 와 $u(t)$ 간의 상호 스펙트럼(cross-spectrum) $\Phi_{yu}(\omega)$ 은 각각

$$\Phi_y(\omega) = |G(e^{j\omega})|^2 \Phi_u(\omega) + \sigma_e^2 |H(e^{j\omega})|^2 \quad (10)$$

와

$$\Phi_{yu}(\omega) = G(e^{j\omega})\Phi_u(\omega) \quad (11)$$

로서 나타난다. 각 패턴을 묘사하는 국소 ARX 모델 계수의 파워스펙트럼이 서로 다른 형태를 가지게 될 경우 ARX 모델 계수는 각 패턴의 특성치(feature value)로서 사용될 수 있다.

3. RBFN 분류기

신경회로망은 많은 분야에서 매우 다양한 목적으로 사용

되고 있는데, 그 중 하나가 패턴 분류 혹은 패턴 인식(pattern recognition) 분야이다[10]. 하지만 일반적인 신경회로망은 학습되지 않은 패턴이 들어올 경우에 이를 기존의 패턴으로 인식하는 위험성을 안고 있다. 이러한 한계성을 RBFN의 사용을 통해 극복될 수 있다. RBFN의 경우에는 학습되지 않은 패턴에 대하여 아무런 결론도 유도하지 않는다[11,12].

RBFN은 입력층, 은닉층, 출력층의 3개의 층으로 구성되어진다. 특히 은닉층을 이루는 각 노드(node)는 방사상 함수(radial basis function)로 표현된다. 가장 자주 사용되는 함수는 Gaussian 함수이다.

$$h_j(\mathbf{x}; \mathbf{c}_j, \sigma_j) = \exp\left[-0.5\sigma_j^{-2}\|\mathbf{x} - \mathbf{c}_j\|^2\right] \quad (12)$$

여기서 $\|\mathbf{x} - \mathbf{c}_j\|$ 는 입력 벡터 \mathbf{x} 와 함수 중심 \mathbf{c}_j 사이의 유clidean 거리(Euclidian distance)이고 σ_j 는 j 번째 함수의 폭을 나타낸다. 임의의 함수는 다음의 두 가지 방식, 즉, 가중합(weighted sum)

$$y_k(\mathbf{x}) = \sum_{j=1}^m w_{jk} h_j(\mathbf{x}) \quad (13)$$

혹은 가중 평균(weighted average)

$$y_k(\mathbf{x}) = \sum_{j=1}^m w_{jk} h_j(\mathbf{x}) / \sum_{j=1}^m h_j(\mathbf{x}) \quad (14)$$

으로 근사할 수 있다. 여기서 $y_k(\mathbf{x})$ 는 k 번째 출력노드의 출력, w_{jk} 는 j 번째 은닉 노드와 k 번째 출력 노드의 연결강도를 나타내며, $h_j(\mathbf{x})$ 는 j 번째 은닉 노드의 출력을 나타낸다. 가중평균이 계산은 더 복잡하나 보다 더 나은 근사결과를 보인다.

실제값 t 과 RBFN 출력 y 간의 오차 제곱합은

$$E = \sum_p E_p = \sum_p \sum_k (t_k^{(p)} - y_k^{(p)})^2 \quad (15)$$

이다. RBFN은 세가지 종류의 계수를 가진다. 이는 radial basis 함수의 중심과 폭, 그리고 은닉층과 출력층 사이의 가중치들이다. Radial basis 함수의 중심과 폭은 비선형 계수인 반면 연결 가중치는 선형이다. 일반적인 학습 방법에는 비선형 학습 방법과 선형/비선형 방법을 혼합한 혼합 학습 방법(hybrid learning method)이 존재한다.

최대 내림 경사법(steepest descent method)나 커티지 기울기법(conjugate gradient method)과 같은 미분에 기반한 방법들이 신경회로망을 학습하는데 주로 많이 이용된다. RBFN의 경우에도 이러한 기울기에 기반한 방법들이 세 가지 종류의 계수를 확인하는데 사용될 수 있다. 모델의 오차를 최소화 하기 위하여 계수들은 임의의 초기값에서 최적값으로 수렴하게 된다. p 번째 sample에 대하여, k 번째 가중치 벡터에 대한 E_p 의 기울기는

$$\nabla_{w_k} E_p = -2(t_k - y_k) \nabla_{w_k} \sum_j^m w_{jk} h_j(\mathbf{x}) = -2(t_k - y_k) \mathbf{h}(\mathbf{x}) \quad (16)$$

이다. 여기서 $\mathbf{h}(\mathbf{x}) = [h_1(\mathbf{x}) \ h_2(\mathbf{x}) \ \dots \ h_m(\mathbf{x})]^T$ 이다. 유사하게 j 번째 중심과 폭에 대한 E_p 의 기울기는

$$\begin{aligned} \nabla_{c_j} E_p &= -2(t_k - y_k) \nabla_{c_j} \sum_{j=1}^m w_{jk} h_j(\mathbf{x}) \\ &= -2h_j(\mathbf{x}) \sigma_j^{-2} (\mathbf{x} - \mathbf{c}_j) \sum_{k=1}^n (t_k - y_k) w_{jk} \end{aligned} \quad (17)$$

와

$$\begin{aligned} \nabla_{\sigma_j} E_p &= -2(t_k - y_k) \nabla_{\sigma_j} \sum_{j=1}^m w_{jk} h_j(\mathbf{x}) \\ &= -2h_j(\mathbf{x}) \sigma_j^{-3} \|\mathbf{x} - \mathbf{c}_j\|^2 \sum_{k=1}^n (t_k - y_k) w_{jk} \end{aligned} \quad (18)$$

로서 나타난다. 한편, 위 (16)-(18)로 나타나는 역전파(back-propagation) 학습은 온라인(on-line)과 배치(batch)의 두 가지 다른 학습 모드로 실행 가능하다. 온라인 학습에서는 각 학습 샘플이 얻어질 때마다 계수의 변화가 일어나고, 반면에 배치 학습에서는 모든 학습 샘플이 얻어진 후 계수를 학습시킨다. 다음의 세 식은 각각 가중치, radial basis 함수의 중심과 폭의 변화 정도를 나타낸다.

$$\Delta \mathbf{w}_k = -\eta_w \sum_{p=1}^N \nabla_{w_k} E_p + \alpha \Delta \mathbf{w}_{k,old} \quad (19)$$

$$\Delta \mathbf{c}_j = -\eta_c \sum_{p=1}^N \nabla_{c_j} E_p + \alpha \Delta \mathbf{c}_{j,old} \quad (20)$$

$$\Delta \sigma_j = -\eta_\sigma \sum_{p=1}^N \nabla_{\sigma_j} E_p + \alpha \Delta \sigma_{j,old} \quad (21)$$

여기서 N 은 전체 샘플의 수, η 는 학습 속도 상수(learning rate parameter), α 는 모멘텀 계수(momentum coefficient)를 나타낸다. (19)-(21)의 우변 첫번째 항과 두번째 항은 각각 국소 기울기(local gradient)와 모멘텀을 의미한다. 모멘텀 항은 계수의 변화가 국소 기울기 뿐만 아니라 최근의 변화 방향에도 영향을 받게끔 하는 역할을 하여, 학습이 국소 최소점에서 머무르게 되는 가능성을 완화시켜 준다.

RBFN은 또한 혼합 학습 방법에 의해서도 학습이 가능하다. 이 알고리즘은 비선형 계수와 선형 계수에 각각 비선형과 선형 최적화 방법을 사용하는 것에 기반을 둔다. 즉, 선형 계수인 연결 가중치는 최소 자승법을 사용하고 비선형 계수인 radial basis 함수의 계수들은 위에서 언급한 비선형 최적화 기법을 사용하여 연속적으로 학습한다. 이를 통해 보다 빠른 속도로 최적의 계수들을 찾을 수 있으며 계산 부담을 줄일 수 있는 장점을 있다.

RBFN을 패턴 분류기로서 사용하기 위해 우리는 다음과 같이 패턴과 그것에 해당하는 클래스를 입력-출력쌍으로 사용한다. k 번째 출력 y_k 는 이진수로서 그것이 특정 클래스에 속하면 1의 값을 가지고 그렇지 않을 경우 0의 값을 갖게 된다. 세 가지의 클래스를 갖는 패턴 분류시, 목표 벡터 y 는 다음과 같이 표현된다. 패턴이 첫번째 그룹에 속한다면 $y = [1 \ 0 \ 0]^T$, 두번째 그룹에 속한다면 $y = [0 \ 1 \ 0]^T$.

세번째 그룹에 속한다면 $y = [0 \ 0 \ 1]^T$ 이 된다.

4. 패턴분류

새로운 입력에 대하여 RBFN의 출력이 나오게 되면, 출력을 바탕으로 해당하는 그룹을 판단하게 된다. 만약 모든 $k(k=1, 2, \dots, n : k \neq i)$ 에 대하여 $y_i(\theta) > y_k(\theta) \geq \varepsilon$ 이고, $y_i(\theta) \geq \varepsilon$ 이면 분류기를 통해 특정 입력 벡터 θ 는 그룹 s_i 에 속한다고 말한다. 여기서 y_i 와 y_k 는 각각 RBFN의 입력 θ 에 대한 i 번째와 k 번째 출력이고, s_i 는 i 번째 패턴 그룹, n 은 출력 노드의 개수, ε 는 적절한 한계값이다. 입력이 주어진 상태에서 각 그룹에 대한 확률 $p(s_i | \theta)$ 이 서로 상이할 때 가장 큰 출력은 거의 확률 1로서 존재하게 된다.

III. 실험 결과 및 고찰

본 연구에서 사용된 모델에 대한 전제적인 구조는 그림 1과 같다. 크게 ARX 모델과 RBFN 분류기 두 부분으로 구성되어 있다. 우선, SO_x 방출 농도를 예측하기 위한 ARX 모델이 구성되고 ARX 모델의 계수들은 연속적으로 반복 최소 자승법에 의해 구해져 특성 벡터(feature vector)로서 RBFN의 입력이 된다. RBFN은 특성 벡터를 해당하는 출력값과 연관시키는 역할을 하게 된다. RBFN의 학습 단계를 거쳐 RBFN 모델의 계수들이 정해지면 특정 입력에 대한 출력이 계산되어 나오게 된다. 이러한 출력값들 중 가장 큰 값을 주는 출력 노드가 바로 입력에 해당하는 그룹의 지표가 된다.

센서를 통해 측정된 값은 네 개의 입력(COG, BFG, LDG, and oil)과 한 개의 출력(SO_x)이다. 그림 2와 3은 각각 ARX 모델의 4가지 입력(COG, BFG, LDG, oil)과 출력(SO_x)의 시계열 패턴을 나타낸다.

전체 샘플의 갯수는 417개이고, 이 중 SO_x 방출량이 비교적 낮은 단계, 점점 높아지는 단계, 비교적 높은 단계로 나누었을 때 각각 162, 17, 238개씩 존재한다.

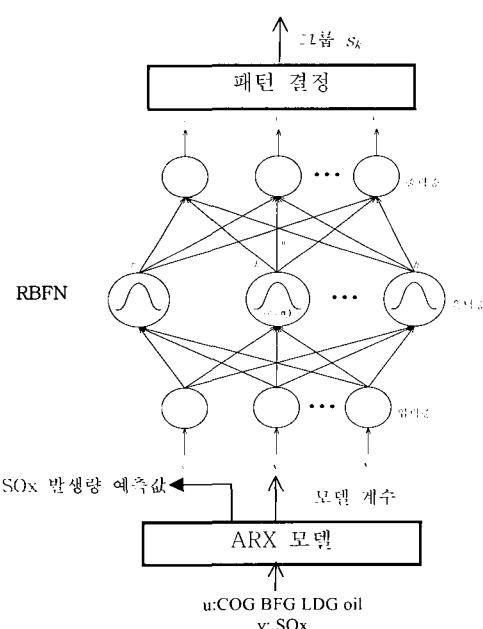


그림 1. SO_x 모니터링 알고리즘.

Fig. 1. SO_x monitoring algorithm.

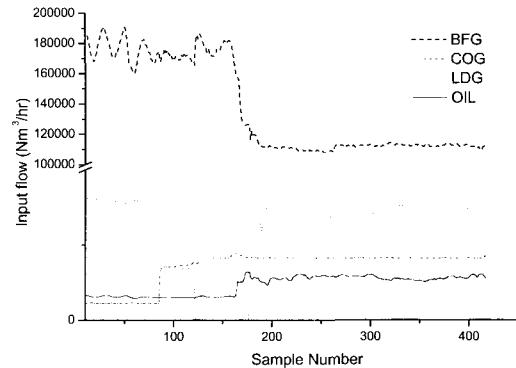


그림 2. 4가지 입력 변수들의 시계열 패턴.

Fig. 2. Time-series patterns of the input variables.

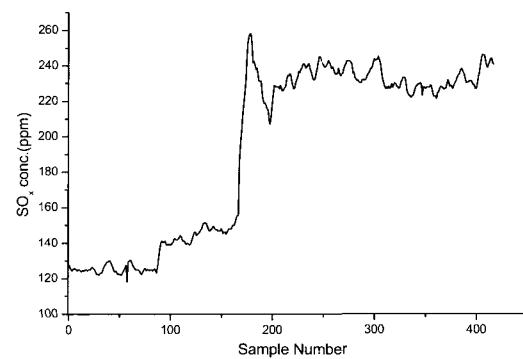


그림 3. 측정된 출력 변수의 시계열 패턴.

Fig. 3. Time-series pattern of the measured output variable.

ARX 모델 차수의 결정은 모델의 정확성과 모델의 복잡성을 동시에 고려하여 절충적인 값을 얻어야 한다. 즉, 모델의 차수가 너무 클 경우 계수의 온라인 개선시, 시간이 오래 걸리기 때문에, 여기서는 각 입력과 출력의 자기 상관(autocorrelation)을 고려하여 입력과 출력의 차수를 모두 2로 정하였다. 따라서 ARX 모델은 두 개의 autoregressive 항과 8 개의 exogeneous 항으로 구성된다.

$$\hat{y}(t) = -a_1 y(t-1) - a_2 y(t-2) + b_{1,1} u_1(t-1) + b_{1,2} u_1(t-2) + b_{2,1} u_2(t-1) + b_{2,2} u_2(t-2) + b_{3,1} u_3(t-1) + b_{3,2} u_3(t-2) + b_{4,1} u_4(t-1) + b_{4,2} u_4(t-2) \quad (22)$$

여기서 $y(t)$ 는 SO_x , $u_i(t)$ 는 COG , $u_2(t)$ 는 BFG , $u_3(t)$ 는 LDG , $u_4(t)$ 는 oil 의 양이다. 즉, 시간 t 에서의 SO_x 의 예측치는 시간 $t-1$ 과 $t-2$ 에서의 SO_x 발생량과 네 가지 연료의 합으로 나타난다. 따라서, ARX 모델을 통해 얻게 되는 특성 벡터는 10개의 계수들로 구성되어진다.

전체 데이터를 입력과 출력의 변화에 따라 총 9개의 패턴(4개의 정상상태, 1개의 변화상태, 4개의 비정상상태)으로 나누어 각각에 대하여 국소적인 ARX 모델을 구성하였다. 특히, estimation windup 현상을 방지하기 위하여, 반복 최소 자승법으로서 blind 방법을 사용하였다. 각 패턴 그룹에 대

한 ARX 모델의 계수의 평균값이 그림 4에 나타난다. 그림 4에서 나타나듯이 각 패턴에 대한 계수들의 값이 서로 다르기 때문에 이러한 계수들이 패턴을 분류하는 특성으로 사용될 수 있음을 확인할 수 있다. 또한, 이러한 사실을 파워스펙트럼을 통해서 검증한 결과가 그림 5에 나타난다.

그림 5에서 보여지듯이, 세개의 파워스펙트럼에서 첫번째 모드 크기의 변화가 상당히 크다. 따라서, ARX 모델 계수의 반복 최소자승법을 통한 생신값들은 시스템의 변화에 대한 정보를 포함하고 있고, 따라서 이를 통해 현재의 패턴을 간접적으로 확인할 수 있다.

그림 6은 ARX 모델을 이용한 SO_x 발생량의 예측(one-step

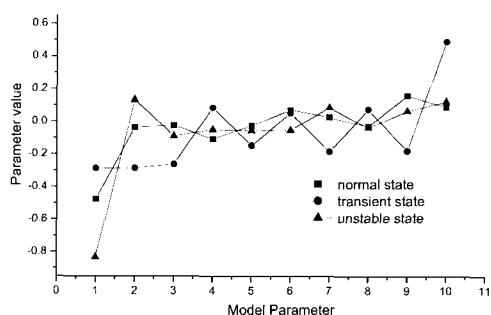


그림 4. 세가지 다른 패턴에서의 ARX 모델 계수의 평균값.

Fig. 4. Average model parameters under three different SO_x emission states.

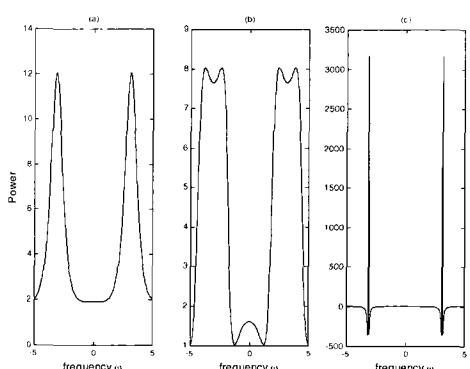


그림 5. 세가지 다른 패턴에서의 파워스펙트럼.

Fig. 5. Power spectrum in three different states.

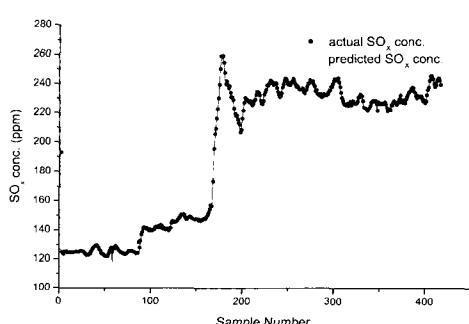


그림 6. ARX 모델을 이용한 SO_x 발생량 예측.

Fig. 6. Estimation of SO_x emissions using the ARX model.

ahead prediction) 결과이다. 관측치와 예측치의 평균 오차 제곱합은 $(3.4 \times 10^{-3})^2$ 이다. 오차가 상대적으로 매우 작고, 오차들간의 자기 상관이 거의 없음을 통해 예측 모델의 신뢰성을 확인할 수 있다.

RBFN 분류기는 10-H-3(H:은닉 노드의 갯수)의 구조를 가진다. H는 입력 데이터의 패턴으로부터 k-means 클러스터링을 통해 가장 적절한 갯수를 찾아내었다. 9개의 국소 ARX 모델 각각에서 10개의 수렴한 모델 계수를 입력으로 하고 각 구성된 모델이 묘사하는 패턴을 출력으로 하여 RBFN의 모델 계수(Gaussian 함수의 중심과 폭, 연결 가중치)를 학습시켰다. 모델 계수의 초기값은 계수의 수렴속도와 정확성에 큰 영향을 주며 특히, Gaussian 함수의 갯수와 각 함수의 중심과 폭의 초기값을 정하는 것이 중요하다. 따라서 이러한 클러스터의 적절한 갯수를 정할 수 있는 보정된 K-mean clustering 알고리즘을 이용하여 Gaussian 함수의 갯수 ($H=8$)와 중심의 초기값을 결정하였고, Moody and Darken's 규칙 [13]을 이용하여 각 함수의 폭의 초기값을 결정하였다.

본 연구에서는 총 세 개의 서로 다른 패턴 그룹 s_1 , s_2 and s_3 을 입력(COG, BFG, LDG, oil)과 출력(SO_x)의 시계열 패턴에 따라 미리 정하였다. 각 그룹은 각각 정상(SO_x 발생량이 비교적 낮은 경우), 전이(SO_x 발생량이 높아지는 경우), 비정상(SO_x 발생량이 비교적 높은 경우) 상태를 나타낸다.

표 1. 417개 샘플의 패턴 분류 결과.

Table 1. Classification result of 417 samples.

	예측			
	정상	전이	비정상	
관측	정상	155	0	9
	전이	3	9	11
	비정상	5	0	226

표 1은 417개의 연속적인 데이터 샘플을 이용하여 제안한 모델을 통해 패턴을 분류했을 때의 결과를 보여준다. 이 행렬의 대각(diagonal) 위치에 있는 것이 올바르게 패턴이 분류된 샘플의 갯수를 나타내고, 비대각(off-diagonal) 위치에 있는 것은 잘못 분류된 샘플의 갯수를 의미한다. 제안한 알고리즘의 전체적인 패턴 인식률은 약 93.5%였다. 실제 많은 분류 오류는 농도 변화 상태에 있는 샘플에서 나왔는데, 그 이유는 실제 이러한 패턴을 갖는 샘플이 RBFN을 학습하기에는 너무 적은 수 존재했기 때문이다.

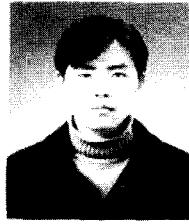
IV. 결론

적용 예측 알고리즘과 RBFN의 결합된 형태의 모니터링 방법이 SO_x 방출량 모니터링에 적용되었다. 이를 통해 제안한 알고리즘이 SO_x 방출량을 예측하는 동시에 현재의 패턴을 판단하는데 유용함을 확인하였다. 또한, 오염물질 방출 패턴과 그 패턴을 묘사하는 ARX 모델 계수간에 상관관계가 존재함을 알 수 있었다. 따라서, 모델 계수가 패턴을 인식하는 지표가 됨을 확인하였다. 이러한 사실을 바탕으로 RBFN을 통한 패턴 분류를 통해서 샘플을 입출력의 양상에 따라 몇 가지 패턴 그룹으로 나누는 일도 가능하였다.

참고문헌

- [1] G. E. P. Box and G. M. Jenkins, "Time series analysis : forecasting and control," San Francisco, CA : Holden-Day, 1970.
- [2] D. M. Himmelblau, "Application of artificial neural networks in chemical engineering," *Korean J. Chem. Eng.*, 17, pp. 373-392, 2000.
- [3] M. Bozner, M. Lesjak and P. Mlakar, "A neural network based method for short term predictions of ambient SO₂ concentrations in highly polluted industrial areas of complex terrain," *Atmospheric Environment*, 27B(2), pp. 221-230, 1993.
- [4] B. Bakal, T. Adali, M. K. Sönmez and R. Fakory, "Time delay neural networks for NO_x and CO prediction in fossil fuel plants," *Proc. of World Congress on Neural Networks (WCNN)*, Washington, DC, 3, pp. 111-115, 1995.
- [5] A. C. Comrie, "Comparing neural network and regression models for ozone forecasting," *Journal of the Air and Waste Management Association*, 47, pp. 653-663, 1997.
- [6] S. H. Sohn, S. C. Oh and Y. K. Yeo, "Prediction of air pollutants by using an artificial neural network," *Korean J. Chem. Eng.*, 16(3), pp. 382-387, 1999.
- [7] N. De Nevers, "Air pollution control engineering," *McGraw -Hill, Inc.*, Singapore, 1995.
- [8] L. Ljung, "System Identification," *P T R Prentice Hall*, Englewood Cliffs, New Jersey, 1987.
- [9] D. W. Cho and K. F. Eman, "Pattern recognition for on-line chatter detection," *Mechanical Systems and Signal Processing*, 2(3), pp. 279-290, 1988.
- [10] S. Haykin, "Neural networks," *Prentice Hall International, Inc.*, New Jersey, 1999.
- [11] J. S. R. Jang, C.T. Sun and E. Mizutani, "Neuro-fuzzy and soft computing," *Prentice-Hall, Inc.*, New Jersey, 1997.
- [12] C. - T. Lin and C. S. G. Lee, "A Neuro-Fuzzy Systems," *Prentice-Hall, Inc.*, New Jersey, 1996.
- [13] T. J. Moody and C. J. Darken, "Fast learning in networks of locally tuned processing units," *Neural Computing*, 1, pp. 281-294, 1989.

최상욱



1975년 7월 16일생. 1999년 포항공과대학교 화학공학과 졸업. 동대학원 환경공학부 석사(2001). 2001년~현재 동대학원 환경공학부 박사과정 재학중. 관심분야는 공정 모델링, 모니터링 및 공정 데이터 분석.

유창규



1969년 9월 25일생. 1993년 연세대학교 화학공학과 졸업. 포항공과대학교 화학공학과 석사(1995). 동대학원 화학공학과 박사(2002). 관심분야는 생물학적 폐수처리공정의 모니터링 및 제어, 공정 데이터 분석.

이인범



1955년 8월 25일생. 1973년 3월~1977년 2월 연세대학교 화학공학과(학사). 1977년 3월~1979년 2월 한국과학기술원 화학공학과(석사). 1982년 8월~1987년 9월 미국 Purdue 대학교 화학공학과(박사). 1979년 3월~1982년 7월 한국과학기술연구원 화공연구부 연구원. 1987년 10월~1988년 8월 미국 Purdue 대학교 화학공학과 post-doc. 1988년 8월~현재 포항공과대학교 화학공학과 교수. 1998년 9월~현재 공정산업의 지능자동화연구센터 소장. 2000년 3월~현재 포항공과대학교 환경공학과정 주임교수. 2000년 3월~현재 포항공과대학교 환경연구소 소장. 2002년 1월~현재 본 학회 교육이사.