

## 자동회귀이동평균 모델에 의한 고로내 용선온도의 실시간대 예측

최태화·이일옥·이광순\*·김기병\*

산업과학기술연구소 제철연구부

\*서강대학교 이공대학 화학공학과

(1987년 3월 23일 접수, 1988년 4월 14일 채택)

## Real-Time Prediction of Hot Metal Temperature in a Blast Furnace Using an ARMAX Model

Tae-Wha Choi, Il-Ok Lee, Kwang Soon Lee\* and Ki-Byung Kim\*

*Ironmaking Research Lab., Research Institute of Industrial Science and Technology, Pohang 790-330, Korea*

*\*Department of Chemical Engineering, Sogang University, Seoul 121-742, Korea*

(Received 23 March 1987; accepted 14 April 1988)

### 요 약

실제 고로에서 실시간대의 용선온도를 예측하는 방법에 반복 계수확인법이 합치된 자동회귀이동평균 모델을 사용하는 것을 제시하였다. 이 방법을 실제 고로의 조업 데이터에 적용하기 위해 먼저 용선온도의 변화에 영향이 큰 12개의 조업인자를 상관분석을 통해 찾아냈으며 이 인자들과 용선온도의 관계를 나타내는 자동회귀이동평균 모델의 계수를 구하기 위해 RLS, RIV, RELS 그리고 RML의 4가지 반복계수확인법을 사용하여 비교하였다. 본 연구를 통하여 고로 용선온도의 실시간대 예측에 반복계수확인법이 합치된 자동회귀이동평균 모델이 매우 유용함을 알 수 있었다.

**Abstract**—A method to predict real-time temperature of hot metal in an industrial blast furnace is proposed by using an ARMAX model combined with recursive parameter identification techniques. To apply this method to real blast furnace operating data, 12 operating variables which have significant effects on the hot metal temperature were chosen first through correlation analysis. Then four recursive identification techniques of RLS, RIV, RML, and RELS were tested and compared for estimation of parameters in the ARMAX model. Through this work, it was found that the ARMAX model combined with recursive parameter identification techniques is very useful for prediction of the hot metal temperature in real-time.

### 1. 서 론

용선 제조를 위한 일반적인 고로공정을 간단히 설명하면 다음과 같다. 예비처리과정을 거친 철광석과 코우크스가 일정량씩 교대로 belt conveyor에 실려 hopper에 공급된 후 장입장치에 의해 고로내에 장입된

다. 고로의 하부로부터는 원주방향으로 설치된 풍구(tuyère)를 통해 열풍로에서 예열된 고온의 공기가 고로내로 공급된다. 이 공기에 의해 코우크스는 CO화되며 장입된 철광석을 환원시키고 녹인다. 고로 하부에 고인 용융물, 즉 용선(hot metal)과 slag는 비중차에 의해 분리되어 출선구를 통해 배출된다. 일반적인 고로

의 형태를 Fig. 1에 보였다. 노벽에는 온도와 압력을 검지하는 sensor들이 설치되어 있으며 고로의 상부에는 고로내의 가스조성과 온도를 검지하는 장치가 있다.

고로조업에 있어서 용선온도가 낮으면 slag의 유동성이 악화되기 때문에 안정하게 고로내에 녹아있는 용융물을 배출할 수 없다. Slag의 유동성이 악화되면 고로 하부에 잔류하는 용융물이 증가되며 고로의 통기성이 악화된다. 극단적인 경우에는 장입물 강하가 불안정하게 되어 안정된 조업을 할 수 없게 된다. 또한 온도가 낮은 용융물이 배출되면 쉽게 응고되므로 출선, 출재작업에 많은 어려움을 준다. 그러나 고로의 조업에 영향을 주지 않는 한 용선온도를 낮추는 것은 연료비를 절감시킴으로써 용선 제조원가를 낮출 수 있게 한다. 반면에 용선온도가 너무 높으면 고로내의 가스온도가 상승되고 철광석이 용융되는 구간이 보다 커져서 역시 고로내의 통기성을 악화시킨다. 또한 노내 가스의 온도가 상승하고 환원가스의 이용율이 낮아져 연료비가 증가된다. 한편 변동이 심한 용선온도는 용선중의 규소와 유황의 농도를 변동시켜 다음 공정인 제강공정에 어려움을 준다. 이러한 이유로 용선온도의 안정화는 고로조업에 있어서 매우 중요한 문제가 된다[1, 2].

안정된 용선온도 값을 유지시키기 위해서는 제어계를 구성하는 것이 필요하나 대단히 차수가 큰 다변수제인 고로에서 이 제어계가 다른 변수들에 미칠 영향이 먼저




Fig. 1. Profile of blast furnace.

충분히 검토되지 않고는 운영될 수 없다는 문제점을 갖고 있다. 이를 위한 차선의 방법은 용선온도의 예측모델을 구성하여 실시간대에서 조업자에게 용선온도의 미래치를 제시해 주고 조업자가 이것을 참고하여 경험에 의한 적절한 행동을 취하게 하는 것이다.

이와같은 고로 중요인자들의 거동예측을 위하여 70년대 이후 고로내의 현상들을 수학적 모델로 표현하고 이의 해를 얻어 해석하려는 시도가 꾸준히 진행되고 있으나[3, 4] 노내 현상에 대한 이해가 부족하고 계산량이 매우 많아 실시간대에서의 거동 예측에 이용될 단계에까지는 이르지 못한 형편이다.

본 연구에서는 이와같은 물리적 수지에 의한 수학적 모델을 지양하고 용선온도와 고로조업변수들의 관계를 경험적 추계모델인 ARMAX(Auto-Regressive Moving Average with auxiliary input) 모델을 도입하여 표현하고 이것으로부터 예측모델을 구성하여 고로내의 여러 조업인자들의 측정치로부터 용선온도의 미래치를 예측하고자 하였다. 이를 위해 먼저 장기간에 걸쳐 취합한 고로조업 데이터로부터 용선온도에 영향을 주는 조업인자들을 상관관계분석을 통하여 찾아낸 후 용선온도와 이 인자들 사이의 동특성을 ARMAX 모델로 가정하였다. ARMAX 모델의 계수들은 검출단으로부터 측정된 시계열(time-series)적 데이터를 반복계수확인법(recursive parameter identification technique)으로 처리하여 구하였으며 이를 통하여 실시간대에서의 용선온도 예측의 가능성을 검토하고자 하였다.

## 2. ARMAX 모델과 예측기의 구성[5, 6]

고로에 설치된 각종 검출단들은 고로내 여러 지점에서의 온도, 압력 그리고 여러가지 가스성분의 농도를 측정한다. 이 측정치들에는 고로의 조업특성상 많은 잡음성분이 섞이게 되며 따라서 추계적(stochastic) 모델에 의한 처리가 요구된다. 이 측정치들을 물리적 수지에 의한 동특성모델 구성에 이용하고 이 모델로부터 예측기를 구성하는 것도 가능하나 이와같은 동특성모델은 대단히 복잡하여 실시간대에서 측정치들을 처리하고 예측치를 계산하는 것은 실질적으로 어려움이 있다. 본 연구에서는 이 측정치들로부터 용선온도와 높은 상관성을 갖는 인자들을 Table 1과 같이 찾아내고 Fig. 2에서와 같이 용선온도  $y$ 와 영향을 주는 인자들  $u_i$ ,  $i=1, 2, \dots, m$  사이를 다중입력 단일출력(multiple-input single-output) 형태의 선형동적계로 구성하고자 하였으며 식 (1)과 같은 ARMAX 모델로 표현하였다.




Fig. 2. Schematic diagram of input-output model of the blast furnace.

$$y(k) + a_1y(k-1) + \dots + a_Ny(k-N) = b_{10}u_1(k-d_1) + b_{11}u_1(k-d_1-1) + \dots + b_{1NB_1}u_1(k-d_1-NB_1) + \dots + b_{m0}u_m(k-d_m) + b_{m1}u_m(k-d_m-1) + \dots + b_{mNB_m}u_m(k-d_m-NB_m) + e(k) + c_1e(k-1) + \dots + c_Ne(k-N) \quad (1)$$

여기서  $d_1, \dots, d_m$ 은 각 입력인자들의  $y$ 에 대한 지연시간,  $e(k)$ 는 백색잡음(white noise), 그리고  $a_1, \dots, c_N$ 는 측정된 공정변수들을 이용하여 찾아야 할 계수들이다.

이제 위의 ARMAX 모델로부터  $k$ 스텝까지의 측정 데이터를 이용하여 임의의  $n$ 스텝 후의 값을 예측하는 모델은 다소의 수학적 조작을 필요로 하나  $n=1$ 인 경우는 식 (1)로부터 직접 도출된다. 위의 식에서  $e(k)$ 는 예측이 불가능한 상태로 나타나는 것이지만 이것이 출력  $y(k)$ 에 합하여서 나타나므로  $y$ 의 신호를 적절한 방법으로 처리하면  $e$ 의 값을 추정하는 것이 가능할 수 있다. 이렇게 하여 추정된  $e$ 를  $\hat{e}$ 라 할 때  $k$ 스텝까지의 측정치들을 이용하여 구한  $y(k+1)$ 의 최선의 예측치는

$$\hat{y}(k+1) = -a_1y(k) - \dots - a_Ny(k+1-N) + b_{10}u_1(k+1-d_1) + b_{11}u_1(k-d_1) + \dots$$

Table 1. List of major input variables and their time-delays.

Item $u_i$	Time Delay (Hr) $d_i$
flame temperature	3
Si content in hot metal	1
permeability resistance index	1
temperature of top gas	4
N <sub>2</sub> (%) in top gas	6
CO <sub>2</sub> (%) in top gas	5
ratio of gas utilization	1
charging speed	4
cross-sonde temp. (No. 4)	1
throat temperature	3
wall temperature (S <sub>2</sub> )	1
wall temperature (S <sub>5</sub> )	1

$$+ b_{1NB_1}u_1(k+1-d_1-NB_1) + \dots + b_{m0}u_m(k+1-d_m) + b_{m1}u_m(k-d_m) + \dots + b_{mNB_m}u_m(k+1-d_m-NB_m) + c_1\hat{e}(k) + \dots + c_N\hat{e}(k+1-N) \quad (2)$$

와 같이 될 것이다. 식 (2)는 식 (1)의  $k$ 를  $k+1$ 로 대치한 후 이때 나타나는  $e(k+1)$ 은 미래에 나타날 잡음치로 예측이 불가능한 것이므로 그 항을 제하여 얻어진 것이다. 식 (2)의  $\hat{e}$ 항을 계산하기 위한 방법은 다음 절의 식 (7)에 기술하였다.

### 3. 반복계수확인법

식 (1)의 계수들은 반복계수확인법을 이용하여 구하였으며 대표적인 방법들인 RLS(Recursive Least Squares), RIV(Recursive Instrumental Variables), RELS(Recursive Extended Least Squares) 그리고 RML(Recursive Maximum Likelihood)의 4가지를 적용하여 그 성능을 비교하여 보았다. 이들 방법은

$$y(k) = \theta^T \phi(k) + w(k) \quad (3)$$

와 같이 계수 벡터  $\theta$ 에 대해 선형적인 관계를 갖고며 측정치  $y(k)$ 에 임의의 잡음성분  $w(k)$ 가 가해지는 모델에서 계수  $\theta$ 를 측정치  $y(k)$ 와 regressor 벡터  $\phi(k)$ 를 이용하여 반복적으로 개선하며 추정할 수 있도록 구성된 것이다. 이 방법들은 식 (4)와 같은 일반적인 형태로 나타낼 수 있다.

$$\hat{\theta}(k) = \hat{\theta}(k-1) + \gamma(k) [y(k) - \phi^T(k) \hat{\theta}(k-1)] \quad (4)$$

여기서  $\gamma$ 는 추정치임을 나타내기 위해 도입된 부호이며  $\gamma(k)$ 는 계수벡터의 개선방향 및 크기를 결정시켜주는 구실을 하는 것으로 그 구체적인 모습은 반복계수확인법에 따라 조금씩 달라지게 된다. 식 (4)에서  $\phi^T(k) \hat{\theta}(k-1)$ 은  $k-1$  스텝에서 추정된 계수  $\hat{\theta}(k-1)$ 을 이용하여  $y(k)$ 를 예측한 것이므로  $[y(k) - \phi^T(k) \hat{\theta}(k-1)]$ 는  $y$ 에 대한 예측오차가 된다. 결국 식 (4)는  $y$ 에 대한 예측오차가 없어질 때까지  $y$ 의 예측오차에 의해 계속 계수벡터를 개선해 나가는 구조를 가지고 있다.

이제 이와같은 반복계수확인법을 식 (1)의 ARMAX 모델의 계수 추정에 적용하여 보자. 식 (1)의  $e(k)$ 를 식 (3)의  $w(k)$ 로 생각하고

$$\theta^T = [a_1, a_2, \dots, b_{10}, \dots, c_1, \dots, c_N] \quad (5)$$

$$\phi^T(k) = [-y(k-1), -y(k-2), \dots, u_1(k-d_1), \dots, e(k-1), \dots, e(k-NC)] \quad (6)$$

와 같이 계수 및 regressor 벡터를 정의하면 ARM-AX 모델이 식 (3)의 형태를 갖게 되어 반복계수확인법의 적용이 가능해 진다. 이때  $y$  및  $u$ 들은 실제 측정치들이지만  $e$ 는 직접 측정할 수 있는 것이 아니므로 식 (7)과 같이 추정치인  $\hat{e}$ 로 대체된다.  $\hat{e}$ 는 식 (1)을 역으로 정리함으로써 얻어지며 다음과 같은 회귀식에 의해 계산된다.

$$\begin{aligned} \hat{e}(k) = & -\hat{c}_1(k)\hat{e}(k-1) - \dots - \hat{c}_{NC}(k)\hat{e}(k-NC) \\ & + y(k) + \hat{a}_1(k)y(k-1) + \dots \\ & + \hat{a}_{NA}(k)y(k-NA) \\ & - \hat{b}_{10}(k)u_1(k-d_1) + \dots \\ & - \hat{b}_{1NB_1}(k)u_1(k-d_1-NB_1) \\ & - \hat{b}_{m0}(k)u_m(k-d_m) + \dots \\ & - \hat{b}_{mNB_m}(k)u_m(k-d_m-NB_m) \\ = & y(k) - \phi^T(k)\hat{\theta}(k) \end{aligned} \quad (7)$$

Table 2에 본 연구에서 사용한 4가지 반복계수확인법의 알고리즘을 실었다. 이 방법들의 유도과정 및 자세한 내용은 여러 문헌[7, 8]을 통해 찾아볼 수 있으나 간단히 이들의 특징을 비교하면 다음과 같다.

먼저 RLS는 ARMAX 모델에서  $c_1 = \dots = c_{NC} = 0$ 이라는 가정하에 구성된 것으로 최소자승법의 개념을 이용하여  $a_1, \dots, b_{mNB_m}$ 만을 반복적으로 추정해 내는 방법이다. 이 방법은 수렴속도가 빠르고 안정하게 동작한다는 이점이 있지만 ARMAX 모델의 잡음항이 백색잡음만으로 나타나지 않는 경우 추정된 계수값의 기대치가 실제값과 다르게 나타난다는 문제점이 있다. RIV는 RLS와 유사하나 데이터 벡터 (6)외에 instrumental variable이라는 것을 도입하여 추정된 계수의 기대치가 실제값과 같아지도록 함으로써 RLS의 문제점을 해결한 방법이다. RELS와 RML은 잡음항의 계수  $c_j$ 를 포함한 모든 계수를 추정해 내는 방법이다. 이 중 RELS는 최소자승법의 개념을 확장하여, RML은 maximum likelihood 방법의 개념을 이용하여 구성한 방법이다. 이들 두 방법은 공정을 좀 더 정확히 표현해 줄

**Table 2. Algorithms of the four different recursive parameter identification techniques.**

$\hat{\theta}(k+1) = \hat{\theta}(k) + P(k+1) \alpha(k+1) [y(k+1) - \phi^T(k+1) \hat{\theta}(k)]$ $P(k+1) = [P(k) - P(k) \alpha(k+1) \beta^T(k+1) P(k)] / (\lambda + \alpha^T(k+1) P(k) \beta(k+1)) / \lambda$				
method	$\hat{\theta}(k)$	$\phi(k+1)$	$\alpha(k+1), \beta(k+1)$	remark
RLS	$\begin{bmatrix} \hat{a}_1 \\ \vdots \\ \hat{a}_{NA} \\ \hat{b}_{10} \\ \vdots \\ \hat{b}_{mNB_m} \end{bmatrix}$	$\begin{bmatrix} -y(k) \\ \vdots \\ -y(k-NA) \\ u_1(k-d_1) \\ \vdots \\ u_m(k-d_m-NB_m) \end{bmatrix}$	$\alpha = \beta = \phi$	$\bar{y}(k) = -\hat{a}_1 \bar{y}(k-1) - \dots - \hat{a}_{NA} \bar{y}(k-NA) + \hat{b}_{10} u_1(k-d_1) + \dots + \hat{b}_{mNB_m} u_m(k-d_m-NB_m)$
RIV			$\beta = \phi$ $\alpha^T(k+1) = [-\bar{y}(k), \dots, -\bar{y}(k-NA), u_1(k-d_1), \dots, \dots, u_m(k-d_m-NB_m)]$	
RELS	$\begin{bmatrix} \hat{a}_1 \\ \vdots \\ \hat{a}_{NA} \\ \hat{b}_{10} \\ \vdots \\ \hat{b}_{mNB_m} \\ \hat{c}_1 \\ \vdots \\ \hat{c}_{NC} \end{bmatrix}$	$\begin{bmatrix} -y(k) \\ \vdots \\ -y(k-NA) \\ u_1(k-d_1) \\ \vdots \\ u_m(k-d_m-NB_m) \\ \hat{e}(k) \\ \vdots \\ \hat{e}(k-NC) \end{bmatrix}$	$\alpha = \beta = \phi$	$\hat{e}(k) = y(k) - \phi^T(k) \hat{\theta}(k)$ $\bar{y}(k) = y(k) - \hat{c}_1 \bar{y}(k-1) - \dots - \hat{c}_{NC} \bar{y}(k-NC)$ $\bar{u}_j(k) = u_j(k) - \hat{c}_1 \bar{u}_j(k-1) - \dots - \hat{c}_{NC} \bar{u}_j(k-NC)$ $\bar{e}(k) = e(k) - \hat{c}_1 \bar{e}(k-1) - \dots - \hat{c}_{NC} \bar{e}(k-NC)$
RML			$\alpha = \beta$ $\alpha^T(k+1) = [-\bar{y}(k), \dots, -\bar{y}(k-NA), \bar{u}_1(k-d_1), \dots, \bar{u}_m(k-d_m-NB_m), \bar{e}(k), \dots, \bar{e}(k-NC)]$	

Note =  $\lambda = 0.9 \sim 0.99$

수 있다는 이점이 있으나 추정해내야 할 계수의 수가 늘어남에 따라 수렴속도가 늦어진다는 단점이 있다.

이제 Table 2에 보인 반복계수확인법이 합치된 예측 모델의 계산과정의 예를 RML 방법에 대해 보이면 다음과 같다.

1.  $k=0$
2. 데이터 벡터  $\phi(0)$ ,  $\alpha(0)$ 의 값을 임의로 가정 혹은 적당한 방법에 의해 추정하여 초기화한다. 마찬가지로 계수 추정치와 계수 추정치의 covariance 행렬의 초기치  $\hat{\theta}(0)$  및  $P(0)$  값을 각각 설정한다. 여기서  $P(0)$ 는 보통 큰 값의 대각행렬(예,  $10^4 I$ )로 준다.
3.  $y(0)$ 와  $u_j(0)$ 를 측정한다.
4. 식 (7)에 의해  $\hat{e}(k)$ 를 계산한다.
5.  $\theta(k)$ ,  $y(k)$ ,  $y(k-1)$ ,  $\dots, u_j(k+1-d_j)$ ,  $\dots, \hat{e}(k)$ ,  $\hat{e}(k-1)$ 를 이용하여 식 (2)에 의해  $\hat{y}(k+1)$ 을 구함으로 예측을 행한다.
6.  $y(k)$ ,  $u_j(k)$  및  $e(k)$ 를 이용하여  $\phi(k+1)$ 을 구성하고 또  $\bar{y}(k)$ ,  $\bar{u}(k)$ ,  $\bar{e}(k)$ 를 계산하여  $\alpha(k+1)$ 을 구성한다.
7. 구성된  $\alpha(k+1)$ 와 전 스텝에서 구한  $P(k)$ 를 이용하여  $P(k+1)$ 을 계산한다.
8. 한 sampling 스텝 후,  $k=k+1$
9.  $y(k)$ ,  $u_j(k)$ 을 측정한다.
10. 전 스텝에서 구성한  $P(k)$ ,  $\alpha(k)$ ,  $\phi(k)$  및  $\hat{\theta}(k-1)$ 를 이용하여  $\hat{\theta}(k)$ 을 계산한다.
11. 4의 과정으로 돌아간다.

이와같은 계산과정에 의해  $k$ 스텝까지 측정된 공정데이터를 이용하여 1스텝 후인  $k+1$  스텝에서 나타날  $y$  값-예를 들어 sampling 간격이 1시간인 경우,  $k$ 를 현재시간이라 할 때 1시간 후의 미래치-을 예측할 수 있게 된다.

ARMAX 모델에 반복계수확인법을 적용하기 위해서는 모델의 차수  $NA$ ,  $NB_1, \dots, NC$ 와 각 입력변수의 지연시간  $d_1, d_2, \dots$ 을 먼저 알고 있어야 한다.

#### 4. 공정 데이터의 수집 및 계산방법

반복계수확인법이 합치된 예측모델은 궁극적으로는 실시간대에서 운영하는 것이 그 목적이나 본 연구에서는 미리 수집된 공정 데이터를 실시간 데이터로 가상하여 여기에 예측모델을 적용하여 봄으로써 그 성능과 가능성을 보고자 하였다.

먼저 용선온도에 영향을 미치는 입력인자들을 선정하

기 위하여 94개 항목의 고로조업 데이터를 수집한 후 용선온도와와의 상관분석을 행하였으며 이 중 상관관계가 높은 12개의 인자를 선정하였다. 이 일을 위해 포항종합제철의 제2고로에서 1985년 7월부터 시작하여 1일 평균 조업 데이터를 약 6개월간 수집하였다.

다음 반복계수확인법에 의한 예측모델의 구성을 위해 1986년 1월 21일부터 1월 26일까지(데이터 set 1), 또 동년 2월 17일부터 2월 22일까지(데이터 set 2) 각 6일간씩 두 차례에 걸쳐 선정된 입력변수와 용선온도를 1시간간격으로 수집하였다. 측정된 각 데이터들은 차원이 다르고 절대값과 변이에서 큰 차이를 보이며 이것이 계산과정중 수치오차를 줄일 수 있어 먼저 식 (8)과 같이 표준화하여 계산에 이용하였다.

$$y = (Y - \bar{Y}) / D_Y$$

$$u_j = (U_j - \bar{U}_j) / D_{U_j} \quad (8)$$

여기서  $Y$ ,  $U_j$ 는 각각 용선온도와 12개 입력인자들의 실제 측정치  $\bar{Y}$ ,  $\bar{U}_j$ 는 이들의 정상상태 조업치-여기서는 평균값을 취하였음-그리고  $D_Y$ ,  $D_{U_j}$ 는 경험적으로 관찰된 각 변수의 최대편차이다. ARMAX 모델의 차수 및 입력변수들의 지연시간은 반복계수확인법과 예측모델 구성을 위해서는 미리 알고 있어야 하는 것이며 이들은 다음의 방법에 의해 결정하였다.

먼저 지연시간  $d_1, \dots, d_m$ 은 데이터 set 1에 대하여 각 입력인자와 용선온도 사이의 cross-covariance 함수

$$r_{yu_j}(m) = \text{cov}[y(k), u_j(k-m)]$$

$$\approx \frac{1}{N} \sum_{n=1}^N y(n) u_j(n-m) \quad (9)$$

을 여러가지  $m$ 에 대하여 계산한 후  $m$  대  $r_{yu_j}$  그래프를 그려  $r_{yu_j}$  값이 크게 나타나기 시작하는 지점의  $m$ 값을 취해  $u_j$ 의 지연시간  $d_j$ 로 취하였다. 이것은 지연시간이내의 시간간격내에 있는  $y$ 와  $u_j$ 는 통계적으로 아무런 상관관계를 가질 수 없다는데 그 근거를 두고 행한 일이다. Table 1에 선정된 12개의 입력인자와 이와같이 구해진 이들의 지연시간을 보였다. ARMAX 모델 각 항의 차수  $NA$ ,  $NB_1, \dots, NB_m$ 는 컴퓨터 모사에서 얻은 경험에 의존하여 2, 2,  $\dots$ , 2로 취하였으며  $NC$ 는 RELS, RML에서는 2로, RLS, RIV에서는 0으로 하였다. 이 이상의 높은 차수를 취한 경우에서도 계수를 추정하며 용선온도 예측을 해보았으나 수렴속도만 늦어질 뿐 더 정확한 예측은 이루어지지 않았다.

이제 이와같이 구해진 ARMAX 모델의 기본구조에 3절에서 기술한 계산과정에 의거해 반복계수확인법을

적용하여 계수의 추정치를 구한 후 식 (2)의 예측모델에 대입하여 용선온도의 예측을 행하였다.

본 연구에서 구성된 ARMAX 모델은 적용하고자 하는 반복계수확인법에 따라 모두 26개(RLS, RIV의 경우) 또는 28개(RML, RELS의 경우)의 계수를 가지고 있으나 수집된 데이터의 양은 각 데이터 set에서 약 130 set로 계수의 초기치를 임의로 주는 경우 반복계수확인법이 수렴된 계수값을 주기에는 충분한 양이 아니다. 따라서 본 연구에서는 먼저 계수의 초기 추정치  $\hat{\theta}(0)$ , 그리고 데이터 벡터  $\phi(0)$ ,  $\alpha(0)$ ,  $\beta(0)$ 를 모두 0으로 가정하여 데이터 set 1에 대해 반복계수확인법을 적용한 후 이로부터 구해진 계수 추정치를 다시 계수의

초기 추정치로 취하여 각 데이터 set에 반복계수확인법이 합치된 용선온도 예측모델을 적용하였다.

## 5. 결과 및 고찰

Fig. 3과 4에 RLS 및 식 (2)의 예측모델을 이용하여 구한 1스텝 후의 용선온도 예측값을 실측치에 비교해 보았다. 측정된 용선온도가 1490°C에서 1530°C 사이를 임의성을 가지고 변화하나 ARMAX 모델의 계수가 반복계수확인법에 의해 점점 개선됨에 따라 약 30스텝 후 부터는 용선온도의 예측치가 측정치와 잘 일치되는 것을 볼 수 있다. 나머지 3가지 반복계수확인법을




Fig. 3. Result of hot metal temperature forecasting by ARMAX model combined with RLS for data set 1.




Fig. 4. Result of hot metal temperature forecasting by ARMAX model combined with RLS for data set 2.

적용한 경우도 비슷한 경향을 나타내며 좋은 일치율을 보였다. 계산 초기에 예측값이 실측치와 큰 차이를 보이는 것은 각 계수들이 충분히 수렴하지 않았기 때문에 생긴 현상이다. 실제 실시간대에서 운영하는 경우는 계수의 추정치가 지속적으로 개선될 것이므로 문제가 되지 않는다.

데이터 set 1에 대하여 RLS 방법을 적용한 Fig. 3의 결과중 충분히 수렴이 이루어졌다고 생각된 30스텝 이후의 용선온도 예측값과 실측치를 Fig. 5와 같이 비교하여 보았다. 실측치에 대한 예측치의 평균오차는  $3.3^{\circ}\text{C}$ 의 낮은 값을 보였으며 상관계수는 0.87의 높은 값을 보였다. 이 결과로부터 ARMAX 모델이 고로의 물리적 현상을 고려하지 않은 경험적인 것이기는 하나 고로의 용선온도와 여러 조업인자 사이의 동적인 관계를 상당한 정확도로 표현해 줄 수 있는 적절한 모델임을 알 수 있었으며 반복계수확인법에 의한 실시간대 적용 가능성을 볼 수 있었다.

이와같은 상관분석을 4가지 반복계수확인법에 대해 모두 행하였으며 그 결과를 Table 3에 보였다. 각 데이터 set에 대해 4가지 방법이 모두 비슷한 값의 상관계수를 보였으나 RIV, RML보다는 RLS나 RELS 방법이 더 좋은 결과를 보여 주었다. RIV은 원래의 공정이 ARMAX식으로 표현되는 경우 unbiased되는 계수




Fig. 5. Correlation between observed temperature and forecasted temperature by RLS method.

Table 3. Correlation coefficients between observed and forecasted hot metal temperatures.

Method Input data	RLS	RIV	RELS	RML
Data set 1	0.87	0.82	0.87	0.85
Data set 2	0.70	0.68	0.70	0.67

추정치를 준다는 점에서 매력적이 있으나 고로와 같은 비선형계의 경우 RIV로 구한 계수 자체에 물리적인 의미를 부여하기가 어려우므로 그 이점이 상실된다 할 수 있다. 오히려 instrumental variable을 만들기 위한 추가적 계산과정이 요구됨으로써 수렴속도나 용선온도 예측의 정밀도에 있어 quadratic 수렴성을 갖는 RLS보다 그 성능이 떨어지는 것으로 이해된다. RML가 RELS보다 성능이 떨어지는 것도 비슷한 해석이 가능하다. Maximum likelihood 방법을 회귀식으로 근사시키는 과정에서 늘어난 계산량, 계수 추정치의 정확도-공정이 선형인 경우에만 적용되는 개념-를 높이기 위해 도입된 filtered 변수,  $\bar{y}(k)$ ,  $\bar{u}(k)$  등에 의한 quadratic 수렴상의 변질이 그 원인으로 생각된다. RLS와 RELS가 거의 같은 정도의 결과를 준 것은 ARMAX 모델의 이동평균항이 모델의 정확도에 큰 영향을 주지 못하고 있음을 의미한다. 모델에서 이용되지 않은 조업변수들의 영향, 모델 구조상의 불확실성 그리고 실제 잡음 성분 등이 종합적으로 모여져 이동평균항을 구성한다고 생각할 때 본 연구에서 선택한 12개의 입력인자들과 선형계의 도입이 용선온도의 동특성을 표현하는 데에 충분했던 것으로 생각된다.

실제 반복계수확인법을 온-라인으로 공정에 연결하여 운용할 경우 조업 데이터들이 지속적으로 들어오며 계수들을 계속 개선해 나갈 것이므로 본 연구에서 얻은 것 보다 더 좋은 예측이 가능할 것으로 기대된다.

예측 모델을 더욱 개선하기 위해서는 고로의 비선형적 특성을 나타내는 모델이 필요할 것으로 생각되며 이를 위해 식 (10)에 보인 것과 같이 변수에 대하여서는 비선형이나 계수에 대해서는 선형인 모델을 도입하여 반복계수확인법을 적용하는 일도 고려해 볼 수 있다. 또한 식 (8)에서 정상상태의 값  $\bar{Y}$ ,  $\bar{U}_j$ 의 값을 정확히 알 수 없을 때 모델이 bias 되는 것을 보정해 주기 위하여 식 (1)의 ARMAX 모델에 상수항  $dc$ 를 더해준 모델을 도입하여 계수  $dc$ 까지 함께 반복계수확인법으로 찾아주는 일도 예측 모델의 정확성을 향상시키는 한 방안이 될 것으로 생각된다.

$$\begin{aligned}
y(k) = & -a_{1N}y(k-1) - \dots - a_{1NA}y(k-NA) \\
& -a_{21}y^2(k-1) - \dots - a_{2NA}y^2(k-NA) \\
& +b_{110}u_1(k-d_1) + \dots + b_{11NB_1}u_1(k-d_1-NB_1) \\
& +b_{210}u_1^2(k-d_1) + \dots + b_{21NB_1}u_1^2(k-d_1-NB_1) \\
& \vdots \\
& +b_{1m0}u_m(k-d_m) + \dots + b_{1mNB_m}u_m(k-d_m-NB_m) \\
& +b_{2m0}u_m^2(k-d_m) + \dots + b_{2mNB_m}u_m^2(k-d_m-NB_m) \\
& +e(k) + c_1e(k-1) + \dots + c_{NC}e(k-NC) \quad (10)
\end{aligned}$$

본 연구를 통해 행해진 용선온도의 실시간대 예측기 구성은 용선온도의 온-라인 제어계 구성 연구에 응용될 수 있다. 실제로 12개의 입력인자 중 flame 온도 및 charging speed는 조작이 가능한 변수이며 두 변수 중 지연시간이 짧고 민감도가 빠른 것을 조작변수로 택하고 나머지 11개의 변수를 측정 가능한 외란으로 간주하면 피드백-피드포워드 제어계가 예측 모델로 부터 쉽게 구성된다. 그러나 제어계의 구성을 위해서는 이 조작변수의 다른 조업상황에 대한 영향을 먼저 충분히 검토하여야 할 것이다.

## 6. 결 론

고로 용선의 온도를 실시간대에서 예측하기 위하여 반복계수확인법이 합치된 자동회귀이동평균 모델을 실제 고로의 운전자료에 적용하였다. 이 연구를 통해 얻은 결론은 다음과 같다.

1. 용선온도의 변화에 영향이 큰 12개의 조업인자를 찾아낼 수 있었다.
2. 경험적 선형 모델인 ARMAX 모델이 용선온도의 동적변화를 상당한 정확도로 표현해 줄 수 있었다.
3. 최소자승법 개념에 의한 RLS와 RELS가 용선온도의 예측 모델의 구성에서 RIV나 RML 보다 더 우수하게 작용하는 것으로 나타났다.

본 연구에서 행한 용선온도 예측은 용선온도의 온-라인 제어계 구성을 위한 연구에 중요한 지침이 될 것으로 사료된다.

## NOMENCLATURE

- $a_i, b_i, c_i$  : parameters of the ARMAX model  
 $d_i$  : time delay of the  $i$ -th input term in the ARMAX model  
 $D_Y, D_{U_i}$  : maximum deviations of  $Y$  and  $U_i$  from their mean values  
 $e(k)$  : white noise  
 $\hat{e}(k)$  : estimate of the noise term

- $I$  : identity matrix with an appropriate dimension  
 $k$  : time index, means time instant  $kT$   
 $m$  : total number of input variables  
 $N$  : total number of sample  
 $NA$  : order of autoregressive term in the ARMAX model  
 $NB_i$  : order of  $i$ -th auxiliary input term in the ARMAX model  
 $NC$  : order of moving average term in the ARMAX model  
 $P(k)$  : parameter covariance matrix  
 $r_{yuk}(m)$  : cross-covariance function between  $y(k)$  and  $u_i(k-m)$   
 $T$  : sampling interval  
 $u_i(k)$  : normalized  $i$ -th input variable  
 $U_i$  : measured input variable  
 $\bar{U}_i$  : mean value of  $U_i$   
 $y(k)$  : normalized output variable  
 $\hat{y}(k)$  : prediction of  $y(k)$   
 $Y$  : measured output variable  
 $\bar{Y}$  : mean value of  $Y$

## Greek Letters

- $\alpha, \beta$  : filtered data vectors  
 $\gamma$  : vector defined in eq.(4)  
 $\lambda$  : forgetting factor  
 $\theta$  : parameter vector  
 $\phi$  : data vector

## Symbol

- $\hat{\phantom{x}}$  : estimated or forecasted value

## REFERENCES

1. Biswas, A.K.: "Principles of Blast Furnace Ironmaking", Cootha Publishing House, Brisbane, Australia (1981).
2. Hatano, M., Matoba, Y., Otsuka, K., Yoshihi, M. and Miyagi, T.: Trans. ISIJ, **22**, 534 (1982).
3. Yagi, J. and Muchi, I.: Trans. ISIJ, 392 (1970).
4. 杉山喬: "高爐内の流動, 傳熱, 反應解析", 日本鐵鋼協會主催, 第95回 西山記念講座, 大阪(1983).
5. Åström, K.J.: "Introduction to Stochastic Control Theory", A.P., N.Y. (1970).
6. Box, G.E.P. and Jenkins, G.M.: "Time Series Analysis, Forecasting and Control", Holden-Day, San Fransisco (1976).
7. Goodwin, G.C. and Payne, R.L.: "Dynamic System Identification; Experiment Design and Data Analysis", A.P., N.Y. (1977).
8. Isermann, R.: "Digital Control System", Springer-Verlag, Berlin (1981).