

신경망을 이용한 열간 압연하중 예측용 탄소당량식의 개발

김필호* · 문영훈* · 이준정*

(1997년 8월 20일 접수)

Determination of Carbon Equivalent Equation by Using Neural Network for Roll Force Prediction in hot Strip Mill

P.H.Kim, Y.H.Moon and J.J.Yi

Abstract

New carbon equivalent equation for the better prediction of roll force in a continuous hot strip mill has been formulated by applying a neural network method. In predicting roll force of steel strip, carbon equivalent equation which normalize the effects of various alloying elements by a carbon equivalent content is very critical for the accurate prediction of roll force. To overcome the complex relationships between alloying elements and operational variables such as temperature, strain, strain rate and so forth, a neural network method which is effective for multi-variable analysis was adopted in the present work as a tool to determine a proper carbon equivalent equation. The application of newly formulated carbon equivalent equation has increased prediction accuracy of roll force significantly and the effectiveness of neural network method is well confirmed in this study.

Key Words : Neural Network(신경망), Carbon Equivalent(탄소당량), Roll Force(압연하중), Roll Gap(롤 갭), Deformation Resistance(변형저항), Finishing Mill Set-Up(마무리압연 설정)

1. 서론

열간 압연재의 두께품질에 대한 수요가의 요구가 날로 엄격해짐에 따라 열간 마무리압연(Finishing Mill)시 롤갭(roll gap) 설정정밀도를 개선시키기 위한 연구가 활발히 진행되어 왔다.^{1)~5)} 열간 마무리압연시 연속적으로 배열된 각 스탠드의 롤갭은 많은 조업변수를 정확하게 고려해 주어야만 정밀설정이 가능하나, 다양한 조업변수로부터 발생하게 되는 여러 오차요인으로 인해 아직도 롤갭

설정모델에 대한 개선의 여지가 많은 실정이다. 본 연구에서는 이러한 롤갭의 설정정밀도를 개선시키기 위한 노력의 일환으로 설정 계산시 주요입력변수의 하나로 사용되고 있는 탄소당량식을 재구성해줌으로써 압연재의 합금성분에 기인한 금속학적 변화요인을 설정 계산시 정밀하게 고려해 주고자 하였다. 일반적으로 압연기 롤갭의 설정정밀도는 근원적으로는 설정을 수행하는 설정모델의 설정정밀도에 직접 영향을 받게 되지만, 압연기를 구성하는 설비적요인, 압연소재의 야금학적 특성, 압연소재의 온도

* 포항산업과학연구원 압연설비E&NG 연구팀

분포, 압연기의 밀 강성(Mill Stiffness)등에도 영향을 받게 된다. 롤 갭은 압연 후 목표두께로 부터 압연기의 탄성으로 인해 롤 갭이 늘어나는 만큼을 미리 보상하여 설정하게 되는데, 이를 위해서는 압연시 걸리는 압연하중을 정확하게 계산하여야지만 압연기의 밀 정수(Mill modulus)로 나누어줌으로써 탄성회복량을 보상해 줄 수 있다. 따라서 롤갭의 설정 정밀도는 압연하중의 계산정밀도와 직결되게 되며, 본 연구에서도 압연하중 계산시 주요변수로 사용되고 있는 탄소당량식을 재구성하여 압연하중예측정밀도를 향상시킴으로써 롤 갭의 설정정밀도를 개선시키고자 하였다. 전술한 바와 같이 열간압연하중의 계산에는 탄소당량 이외에도 많은 조업변수가 상호 연관되어 밀접하게 영향을 미치게 되므로 본 연구에서는 다변수 해석에 효과적인 것으로 알려진 신경망(Neural network)¹⁰⁻¹³을 이용하여 고정밀 탄소당량식을 개발하고자 하였다.

신경망을 이용한 해석이 주어진 문제에 대해 항상 최적해(Global minimum)를 제공해 준다고는 볼 수 없지만, 신경망 해석이 합리적 데이터 베이스(data base)를 이용한 최적 해석과정을 거친다면 실제 재료나 관련공정에서 일어나고 있는 복합적인 현상을 해석하는데 유용하게 사용할 수 있다. 신경망을 이용한 공정해석에¹⁰⁻¹¹를 보면 Rao 와 Prasad¹⁰는 상용 신경망 소프트웨어인 "Nworks Professional II Plus"를 이용하여 고온에서의 저탄소강 유동응력을 해석하였으며, 이 이외에도 Hwu와 Lenard¹¹는 오차역전파 회로망(Back-propagation neural network)을 이용하여 고온에서의 유동응력을 계산한 바 있다. 본 연구에서는 신경망 해석의 한 방법으

로 빠른 수렴성과 입력변수간의 상관성 분석이 용이한 특징을 갖는 FNN(Functional neural network)을 이용하여 최적 탄소당량식을 구하고자 하였다.

2. 압연하중 설정모델의 이론적 배경

Fig.1 에 열간 압연공정의 도식도를 나타내었는데 그림에 표기한 바와 같이 마무리압연 설정(Finishing mill set-up)은 사상압연기의 롤 갭과 롤 속도를 설정한다. 마무리 압연기의 정확한 설정을 위해서는 압연공정과 관련된 여러 변수를 이용하여 복잡한 계산과정을 거치게 되는데, 이러한 계산과정에는 마무리압연 설정모델을 구성하는 여러 요소모델들이 유기적으로 관여하게 된다.

Fig.1 에 나타난 바와 같이 롤 갭 설정계산을 위해 필요한 예측압연하중(Pcal)은 압연시 소재의 변형저항에 기인한 하중을 말하는데 아래식(1)에 의해 구한다.

$$P_{cal} = Km W L d C p \quad (1)$$

여기서, Km : 변형저항, Ld : 투영접촉장
 W : 각 스탠드 판폭, Cp : 보정인자

식(1)에서 변형저항(Km)을 제외한 나머지 항목들은 조업변수에 의한 영향도가 미미하므로, 변형저항 예측정밀도와 압연하중 예측정밀도를 동일시하는 것이 일반적이다.

현재 변형저항예측식으로는 나가사끼-기하라(長崎-木原)식¹⁴과 시타(志田)식¹⁵에 근거한 식이 많이 사용되고

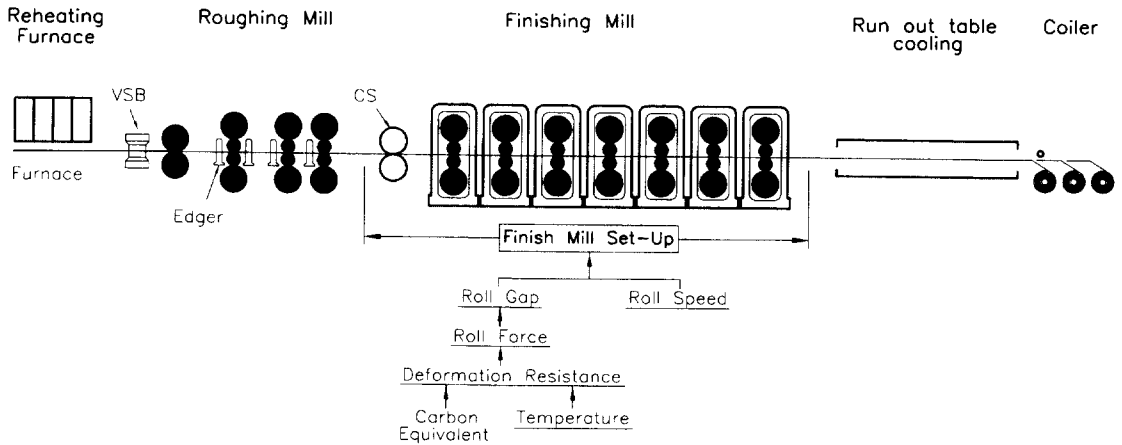


Fig. 1 Schematic drawing of conventional hot strip rolling process line

있는데, 각 철강사에서는 각 사의 압연설비 특성에 맞는 변형저항식으로 수정 보완하여 사용하고 있다.

본 연구의 수정 대상모델인 시다(志田)식은 원통형 압축시험(cylindrical compression)을 통해 구했는데 이에 대한 자세한 사항은 다음과 같다.

- 시험방법 : 원통형 압축시험 (직경 12 mm x 길이 18 mm)
- 시험조건 : $C < 1.2\%$, $\epsilon < 0.7$, $\dot{\epsilon} : 0.1-100 \text{ sec}^{-1}$, 온도 : 700-1200°C (γ 와 α 상 포함)
- 변태에 의해 변형저항이 극대인 온도 T_d (K)
 $T_d(K) = 950 (C+0.41)/(C+0.32)$
 $t_d = T_d(K) / 1000$
 $t = T(K) / 1000$

여기서 T(K) 는 절대온도로 환산한 실험온도

- 변형저항(Km) 계산식

$$K_m (Kgf/mm^2) = K \{ 1.3(\epsilon/0.2)^n - 0.3(\epsilon/0.2) \} (\dot{\epsilon}/10)^m \quad (2)$$

여기서,

$$K = 0.28 \exp 5/t - 0.01/(C+0.05) (t/t_d)$$

$$K = 0.28 \exp 5/t_d - 0.01/(C+0.05) (t/t_d)$$

$$g = 30(C+0.9) [t - 0.95(C+0.49)/(C+0.42)]^2 + (C+0.06)/(C+0.09)$$

$$m = (-0.019C + 0.126)t + (0.075C - 0.05) (t/t_d)$$

$$m = (0.081C - 0.154)t + (-0.019C + 0.207) + 0.027/(C+0.32) (t/t_d)$$

$$n = 0.41 - 0.07C$$

상기 시다식은 합금성분의 효과가 고려되어 있지 않아 다양한 화학조성을 갖는 강종에 폭넓게 적용하는 데는 한계를 갖게 된다. 따라서 합금성분의 효과를 고려해 주기 위해 식(2)의 탄소함량(C) 대신에 탄소당량(Carbon Equivalent: C_{eq}) 을 적용시켜 예측 정밀도를 개선시키게 된다.

3. 해석방법

3.1 신경회로망 구성

본 연구에서는 신경회로망 해석을 위해 FNN(Functional Neural Network)^{16,17)} 을 적용하였다. FNN은 비선형해석이 필요할 때 사용되는 다층구조의 신경회로망의 기능을 한 개의 뉴런(neuron) 층으로 다룰 수 있는 신경

회로망이다. 이 회로망의 특징적인 구조는 입력 데이터의 차수를 인위적으로 늘림으로써 비 선형적인 시스템을 학습하기에 적절하도록 하는 부가적인 추가 입력에 있다. 이렇게 확장된 입력 데이터가 기존의 입력 데이터와 함께 입




Fig. 2 Functional neural network

력패턴으로 사용되게 된다. Fig.2에 FNN의 구조가 나타나 있다.

이 회로망은 원 입력패턴인 J 와 고차수 입력의 역할을 하는 H의 합으로 구성된 입력 패턴을 이용하는데 여기서 H는 원 입력 패턴 원소들로부터 선형-독립적으로 만들어진다. 따라서 비록 어떠한 새로운 정보가 입력되는 것은 아니나 입력 패턴은 추가되었고 확장된 공간에서의 선형 분리성은 확보되어 있게 된다. 본 연구에서는 H 벡터를 합금원소(alloying elements) 들의 텐서(tensor) 모델로 구성하였다. 이것은 입력 패턴을 벡터형태로 다루기 편리한 모양으로 추가되는 입력 항들은 입력 패턴인 J 차수의 입력 원소들의 텐서 입력형태로 되어 있다. 이런 텐서 입력은 합금원소 간의 영향관계를 분석하는데 매우 편리한 모양이다. FNN 의 계수 학습에는 식(3)에 보인 델타 학습법(delta learning rule)이 주로 사용된다.

$$O_i = f(X) \triangleq \sum W_i X_i$$

$$W_{i+1} = W_i + \eta(O_d - O)X_i \quad (3)$$

여기서, W: 계수(weight factor), O : 출력 벡터(output vector).

O_d : 학습데이터 벡터, X : 입력 벡터(input vector).

η : 학습계수, 하첨자 i : 반복시 시간스텝

이 학습법은 O 와 O_d 간의 최소제곱오차 조건으로부터 다음과 같이 유도할 수 있다.

$$E \triangleq \frac{1}{2} (O_d - O)^2 \quad (4)$$

여기서, E : 제곱오차에너지

식(4)와 같이 정의된 제곱오차 에너지(E)는 식 (5)와 동등하고

$$E = \frac{1}{2}[O_d - f(x) (W^T \cdot X)]^2 \quad (5)$$

여기서, $f(x)$: 출력함수

식(5)로 부터 연결강도 W 에 대한 미분벡터를 구하면 식(6)과 같다.

$$\nabla E = -(O_d - O)f'(x) (W^T \cdot X)x \quad (6)$$

여기서, ∇E : E 의 gradient, W : W 의 transpose 벡터

$f'(x)$: 출력함수 $f(x)$ 의 미분함수, x : 입력항

여기에서 오차의 최소화는 연결강도의 변화가 음의 기울기방향으로 변화해야 하므로 식(7)과 같이 구할 수 있다.

$$\Delta W = \eta(O_d - O)f'(x) (W^T \cdot X)x$$

여기서 $f(x)$ 가 선형 함수인 경우,

$$\Delta W = \eta(O_d - O)x \quad (7)$$

즉 식(3)과 식(7)은 동일한 형태로 여기서의 연결강도의 조정은 제곱오차의 최소화에 기초하고 있다. 비선형 시스템에 대한 신경회로망 학습은 시스템 내에 존재하는 많은 국부최소점(local minima)을 피해야 하므로 본 연구에서는 오차 에너지 최소화 과정중의 국부최소점 수렴을 피하기 위해 모사 어닐링(simulated annealing) 이론^[12]을 식(8)과 같이 학습계수에 적용하였다. 어닐링 계획은 물리적인 시스템에서의 온도와 같이 점진적으로 낮아지는 제어변수 T 에 해당된다. 학습이 진행될수록 제어 변수 T 가 점점 낮아지면서 확화시스템이 낮은 에너지쪽으로 유도되는 것과 같은 원리로 오차에너지를 줄이게 된다.

$$\eta(k) = \frac{\eta}{\log(1+k)}, \quad 1 \leq k \leq K. \quad (8)$$

여기서, $\eta(k)$: k 번째 학습시의 학습계수

K : 총 학습회수

일반적으로 식(2)의 압연하중(변형저항) 계산시 사용되

는 탄소함량(C)은 주로 탄소(C), 망간(Mn), 규소(Si) 등의 합금성분을 선형적으로 고려한 탄소당량(C_{eq})을 사용해 왔다. 본 연구에서는 열간압연재의 주요 원소로 강종별 물성에 많은 영향을 미치고 있는 6 가지의 주요원소(C, Mn, Si, Ti, Nb, Cu)를 폭넓게 고려해줌으로써 정확한 압연하중의 예측이 가능하도록 하였다.

본 연구의 탄소당량식의 기본형태는 식(9)와 같다.

$$C_{eq} = C + a_1Mn + a_2Si + a_3Ti + a_4Nb + a_5Cu \quad (9)$$

여기서, $a_{1,2,3,4,5}$ 는 계수

또한 기존의 탄소당량식이 원소상호간의 영향도를 고려하지 않았으나 열간압연시 재료거동을 보다 정확하게 고려해 주기 위해 합금원소 상호간의 영향도도 고려해 주고자 하였다. 이를 위해 식(10)에 나타낸 바와 같이 합금원소의 텐서 입력을 FNN에 첨가시켰다.

$$C_{eq} = C + a_1Mn + a_2Si + a_3Ti + a_4Nb + a_5Cu + \sum_{i=6}^{20} a_i h_i \quad (10)$$

여기서, $a_{1,2,3,4,5, \dots, 20}$ 는 계수

h_i : H-벡터의 component로서 합금원소들의 텐서 입력으로 구성

델타 학습법은 교사 학습법(supervised learning)이므로 FNN을 학습시키기 위해서는 학습이 추구하는 목표 탄소당량(Target C_{eq})를 구하여야 한다. 즉, 압연하중 편차를 최소화할 수 있는 목표 탄소당량으로부터 탄소당량 예측식을 구해야 한다. 이를 위해 두께편차가 목표두께대비 $\pm 50 \mu m$ 이내에 드는 양호한 압연재에 대한 1000 매분의 조업실적을 이용하였다. 신경망 해석을 위한 목표 탄소당량을 구하기 위해, 먼저 압연하중 편차를 0으로 만들어 줄 수 있는 변형저항 목표치(target deformation resistance: K_m^*)를 구했다. 탄소당량식이 변형저항 계산 시에만 주요변수로 사용되므로 변형저항 목표치를 만족시키는 탄소당량식이 압연하중 편차를 0으로 만들어 줄 수 있는, 다시 말해 신경망 학습을 위한 목표 탄소당량으로 간주될 수 있다. 압연하중 편차를 0로 만들어 주기 위해서는 식(1)을 통한 예측압연하중 P_{cal} 이 실측압연하중 P_{act} 와 동일하여야 한다. 즉, 식(1)은 식(11)과 같이 표현되며 식(11)을 만족시키는 변형저항값인 목표 변형저항(K_m^*)을 얻을 수 있다.

$$P_{act} = K_m^* W L_d C_p$$

$$K_m^* = \frac{P_{act}}{W L_d C_p} \quad (11)$$

여기서, P_{act} : 실측 압연하중, K_m^* : 목표 변형저항
이렇게 하여 구한 K_m^* 로부터 식(2)를 통해 목표 탄소
당량(C_{eq}^*)를 식(12)과 같이 구한다.

$$C_{eq} = \arg \text{Min}_x \{K_m^*(x)\},$$

$$\min(C_{eq}) \leq x \leq \max(C_{eq}) \quad (12)$$

FNN의 각각의 가중치는 0과 1 사이에서 난수(random number)로 생성된다. 진술하였듯이 학습은 델타 학습법을 사용하였고 신속한 해석을 위해 임계값(threshold value)보다 낮은 입력은 삭제하였다.

FNN을 위한 해석 알고리즘은 다음과 같이 요약할 수 있다.

(a) 계수와 임계값을 초기화 한다. 즉, 모든 계수와 임계값을 낮은 난수값으로 설정한다.

(b) 입력치와 요구되는 출력치를 계산한다. 즉, 연속적으로 입력벡터 $X_1, X_2, X_3, \dots, X_n$ 을 계산하고 요구되는 출력치(O)인 탄소당량값을 명시한다.

(c) 각 입력에 대한 출력치를 계산한다.

$$O = \sum_{i=0}^{n-1} W_i X_i \quad (13)$$

여기서, O : 출력, W_i : 회로망을 연결하는 가중치

(d) 식(3)의 델타학습법과 식(8)의 모사 어닐링(simulated annealing) 학습계수를 사용하여 계수를 조정한다.

(e) 모든 패턴 입력에 대해서 (b)와 (d)의 과정을 반복하여 출력편차가 각각의 패턴과 각각의 뉴런에 대해 허용 오차 내에 놓이도록 한다.

(f) 계수가 임계값보다 낮을 경우에는 입력단을 삭제하고 (b)와 (e)의 과정을 모든 가중치가 수렴할 때까지 반복한다. (Cut-Offing Iteration)

4. 결과 및 고찰

'3' 절의 과정을 거쳐 신경망해석을 수행한 결과, Cut-Offing Iteration은 3회정도의 반복으로 모든 계수가 수렴하였다. 해석을 통해 얻어진 모든 조합에 대한 계수를 얻었으며 이중 가중치가 0.01보다 작은 텐서 입력단은

그 영향도가 미미한 것으로 간주하여 삭제하였다. 이렇게 해서 구해진 최종 계수는 Table 1에 나타내었고, 초기 반복(iteration)시의 r.m.s.(root mean square) 편차 그래프를 Fig.3에 나타내었는데 FNN의 특성인 빠른 수렴성과 뛰어난 학습 효과를 명확하게 보여 주고 있다.

Table 1에서 합금원소간의 영향도와 각각의 원소의 영향도를 계수값으로 쉽게 알 수 있다. 이러한 결과로부터 새로운 탄소당량식을 얻을 수 있는데 새로운 탄소당량식은 식(14)와 같이 FNN의 가중치와 합금원소의 입력 원소로 표현된다.

$$C_{eq} = W' \cdot I \quad (14)$$

Table 1 Learning result for the determination of carbon equivalent equation

	Tensor 1	Tensor 2	W_1 (3125 iter)	W_2 (2223 iter)	W_3 (1215 iter)
1	C		1	1	1
2	Mn		0.502529	0.499849	0.5
3	Si		1.957197	1.972373	1.974327
4	Ti		3.982345	3.9815	3.978613
5	Cu		0.98145	0.998125	0.998193
6	Nb		1.486402	1.507667	1.640471
7	C	Mn	0.012172	0	0
8	C	Si	0.45164	0.363515	0.259125
9	C	Ti	0.332549	0.330004	0.325871
10	C	Cu	0.17537	0.053776	0
11	C	Nb	0.365071	0.336868	0.306267
12	Mn	Si	0.016473	0	0
13	Mn	Ti	0	0	0
14	Mn	Cu	0	0	0
15	Mn	Nb	0.676728	0.52185	0.366988
16	Si	Ti	0.247976	0.282029	0.318626
17	Si	Cu	0.36733	0.355128	0.341658
18	Si	Nb	0.31998	0.319125	0.318341
19	Ti	Cu	0.377618	0.368669	0.352666
20	Ti	Nb	0.338129	0.341857	0.347809
21	Cu	Nb	0.342491	0.341286	0.342273




Fig. 3 Learning C_{eq} root mean square error

여기서, W : FNN에 의해 학습된 가중치.

I : 합금원소들의 텐서 입력.

신경망 해석을 통해 얻어진 결과를 검증해 보기 위해 본 연구의 신 탄소당량식을 이용하여 1000 배분의 새로운 압연실적을 이용하여 압연하중을 예측한 후 기존의 단순 선형적 탄소당량식의 예측결과와 비교해 보았다. 비교방법은 식(15)에 나타낸 바와 같이, 예측 압연하중과 실적 압연하중의 표준편차량, β 를 새로운 탄소당량식과 기존 탄소당량식별로 구한 후 그 개선정도를 α 를 통해 계산하였다.

$$\beta = \text{standard deviation of} \left(\frac{P_{act} - P_{cat}}{P_{cat}} \right)$$

$$\alpha = \frac{\beta_{old} - \beta_{new}}{\beta_{old}} \quad (15)$$

여기서, P_{act} : 실제 압연하중 P_{cat} : 예측 압연하중.

β_{new} : 신경회로망 탄소당량식을 사용한 β 값

β_{old} : 선형적 단순 탄소당량식을 사용한 β 값

Fig.4 에 나타낸 바와 같이 새로운 탄소당량식을 적용한 후 압연하중 예측편차는 약 20~30% 정도 감소하는 효과를 보였으며 이는 새로운 탄소당량식의 예측정밀도가 기존의 탄소당량식에 비해 우수함을 의미한다.

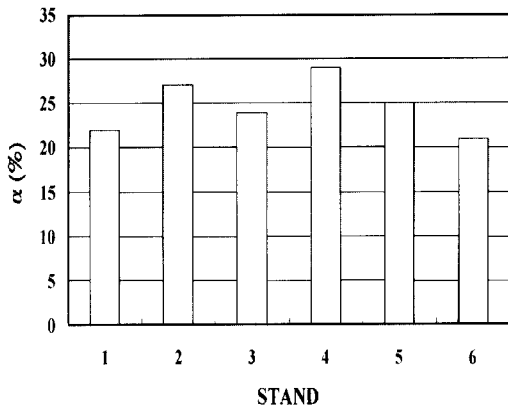


Fig. 4 Decrease of roll force prediction error, α (%)

5. 결론

FNN 신경망 해석을 통해 각 합금원소의 영향도와 원소상호간의 영향도가 고려된 새로운 탄소당량 예측식이

얻어졌으며 이를 이용하여 압연하중을 예측해 본 결과 압연하중 편차가 기존의 선형 탄소당량식에 비해 약 20~30% 감소됨을 확인하였다. 이는 신경망 해석이 합리적 데이터 베이스(data base)를 이용한 최적 해석과정을 거친다면 실제 재료나 관련가공공정에서 일어나고 있는 복잡한 현상을 해석하는데 매우 유용하게 사용될 수 있음을 보여준다.

참고문헌

- (1) C. Nagasaki and J. Kihara, 1988, "Effect of carbon content on deformation resistance of carbon steel in austenitic temperature ranges," J. of ISIJ, Vol.74, No.7, pp.1418~1425.
- (2) 志田 茂, 1970, "熱間壓延における壓延荷重," 日立平論, Vol.52, No.8, pp.731~736.
- (3) K. Kimura, T. Nunokawa, M. Honjyo and R. Takahashi, 1991, "Development of gauge control system with interstand thickness gage for hot strip mill," 鐵と鋼, Vol.77, No.4, pp.58~65.
- (4) T. Morita, M. Konishi, S. Ashizawa and S. Honda, "New gauge control method for hot rolled strip," 神戶製鋼技報, Vol.33, No.1, pp.61~65.
- (5) S. Kuroda, S. Goto, K. Kadono and S. Hanada, 1993, "Improvement of gauge accuracy in No.1 cold tandem mill at KSC's Mizushima Works," 鐵と鋼, Vol.79, No.3, pp.134~140.
- (6) J.M. Jurada, 1992, Introduction to artificial neural systems, Info. Access. Distribution Ltd., Singapore, p. 230.
- (7) S.J. Hanson, J.D. Cowan and C. Lee Giles, 1993, Advances in neural information processing system, Morgan Kaufmann Co., San Mateo.
- (8) S. Gaman and D. Geman, 1984, "Stochastic relaxation, Gibbs distributions and Bayesian restoration of images," IEEE Trans. on PAMI, Vol. PAMI-6, No. 6, p. 721~741.
- (9) K.P. Rao and Y.K.D.V. Prasad, 1995, "Neural network approach to flow stress evaluation in hot deformation," J. of Material Processing Technology, Vol.53, 1995, pp.686~692.
- (10) Y.J. Hwu, Y.T.Pan and J.G. Lenard, 1996, "The

- role of constitutive formulation in the analysis of hot rolling," *Steel Research*, Vol. 67, pp.59~65.
- (11) J.G. Lenard, F. Wang and G. Nadkarni, 1987, " A comparative study of artificial neural networks for the prediction of constitutive behavior of HSLA and carbon steels," *J. of Eng. Mat. Tech.*, Vol. 109, pp.343~349.