

## 신경망을 이용한 판온예측모델내 공정상수 설정 방법

(A Computing Method of a Process Coefficient in Prediction Model of Plate Temperature using Neural Network)

김태은\* · 이해영\*\*

(Tae-eun Kim · Haiyoung Lee)

### Abstract

This paper presents an algorithmic type computing technique of process coefficient in predicting model of temperature for reheating furnace and also suggests a design method of neural network model to find an adequate value of process coefficient for arbitrary operating conditions including test conditions. The proposed neural network use furnace temperature, line speed and slab information as input variables, and process coefficient is output variable. Reasonable process coefficients can be obtained by an algorithmic procedure proposed in this paper using process data gathered at test conditions. Also, neural network model output equal process coefficient under same input conditions. This means that adequate process coefficients can be found by only computing neural network model without additive test even if operating conditions vary.

Key Words : Reheating Furnace Temperature, Radiation, Convection, Neural Network

### 1. 서 론

본 논문은 열간압연공정의 제일 앞 쪽에 위치하는 가열로내 소재의 온도 변화에 대한 예측모델에서 공정상수를 시험데이터로부터 찾아내는 방법과 시험데

이터 이외의 작업조건에 알맞은 공정상수를 실시간으로 산출해 낼 수 있는 신경망 모델의 설계 방법을 제안한다.

가열로는 상온의 소재를 열간압연작업이 가능한 온도까지 상승시키는 역할을 하는 설비다[1-4]. 그 목적을 달성하기 위해서는 가열로 내부의 온도와 소재의 온도사이의 상관관계를 표현하는 모델(비선형 미분방정식)을 정하고, 그 식의 해를 구하는 과정이 필수적이다[1-2, 4]. 그러한 모델에는 공정상수라고 불리는 설계 파라메타가 있다. 그런데 공정상수는 이론적으로 계산될 수 있는 방법이 없다. 따라서 보편적으로 기존 작업 결과를 통해 시행착오적 방법으로 공정상수를 정하여 사용하고 있다. 그로인

---

\* 주저자 : 태창기계공업 기업부설연구소 연구원  
\*\* 교신저자 : 영남대학교 전기공학과 교수  
\* Main author : Researcher at Taechang Machinery IND. CO. LTD.  
\*\* Corresponding author : Professor of Electrical Engineering at Yeungnam University  
Tel : 053-810-2485, Fax : 053-810-4767  
E-mail : hylee@ynu.ac.kr  
접수일자 : 2014년 7월 30일  
1차심사 : 2014년 8월 2일, 2차심사 : 2014년 8월 28일  
심사완료 : 2014년 9월 30일

해 시간과 비용의 손실이 발생하고 있다. 따라서 본 논문에서는 위와 같은 산업공정운영상 문제의 해결 방법으로서 공정상수를 구하는 체계적 방법을 제안한다.

본 논문은 먼저 시험조건에서 취득한 시험데이터를 가지고 그 조건에 부합되는 공정상수의 값을 이론적으로 계산하는 알고리즘을 제안하였다. 다음에 시험조건이 아닌 다른 임의의 작업조건에 알맞은 공정상수를 추가의 시험없이 실시간으로 산출해 내는 기능을 가진 신경망 모델을 설계하였다. 신경망 모델의 입력 변수들은 로온도, 조업속력 및 제품정보이다.

제안된 방법들의 실용성을 입증하기 위해, 공정에서 조업 중에 취득되었던 데이터(목표판온, 가열로 출구에서 측정된 판온, 조업속력, 제품정보 및 로온도 등)를 본 논문에서 개발된 공정상수의 계산 알고리즘에 대입한 결과, 공정상수가 구해짐을 보였다. 나아가 설계된 신경망 모델을 시험데이터를 이용하여 튜닝한 후, 같은 입력 조건에서, 본 논문에서 제안된 신경망 모델이 시험데이터로부터 계산된 공정상수의 값과 동일한 값을 추론하고 있음을 입증하였다. 작업조건이 변경될 경우에도, 그에 알맞은 공정상수가 새로운 시험없이 신경망 모델의 계산을 통해 실시간으로 구해질 수 있음을 보였다.

## 2. 가열로의 구성, 판온 예측모델 및 문제점

### 2.1 열간압연에서의 가열로 구성

열간압연공정에서 제일 앞 쪽에 위치하는 가열로는 상온의 소재를 열간압연이 가능한 온도로 상승시키는 역할을 하는 설비이며, 그림 1과 같이 예열대(Preheating Zone), 가열대(Heating Zone) 및 균열대(Soaking Zone)로 구분된다. 그림 1에서 네모박스 형태가 나열되어 있는 구조는 워킹빔(Walking Beam)이라고 불리며, 위쪽-오른쪽-아래쪽-왼쪽 순으로 움직이면서, 위에 놓여진 소재를 가열로 출구쪽으로 단계적으로 이동시키는 장치이다.




그림 1. 가열로의 구성  
Fig. 1. A Mechanical Structure of Reheating Furnace

### 2.2 가열로내 판온 변동의 예측모델(지배 방정식)

가열로내부에 소재의 온도에 영향을 미치는 원인은 복사와 대류로 본다. 조업 경험에 의하면, 두 가지 원인 중에도 복사가 지배적이다[1]. 따라서  $T_s$  및  $T_f$ 를 각각 ‘소재의 온도’ 및 ‘로온도(가열로 내부의 분위기 온도)’이라고 약속한다. 워킹빔은 지정된 조업속력(Line Speed의 약자로  $LS$ 로 표기함)으로 작동된다.  $x$ 를 수평축 이동거리로 약속하면,  $LS$ 는  $dx/dt$ 이다. 열전달 이론의 기본인 에너지 균형식을 이용하면[5], 가열로내 소재의 온도 변화에 대한 예측모델은 식 (1)과 같이 표현된다.

$$\frac{dT_s}{dx} = 2 \cdot \frac{U\rho F(T_f^4 - T_s^4) + h(T_f - T_s)}{\rho Cd(LS)} \quad (1)$$

여기서  $\rho$ 는 밀도,  $C$ 는 비열,  $\sigma$ 는 Stefan-Boltzmann 상수,  $F$ 는 형상계수(Shape Factor),  $h$ 는 대류열전달계수,  $d$ 는 소재의 두께이다. 한편  $U$ 는 유효방사율과 가열로내의 전열과정 중 식 (1)로는 표현되지 않는 불확실성 등을 모두 포함하는 ‘공정상수’인데, 유효방사율(0이상 1미만)만 보더라도 소재의 재질(구성원소들과 각 원소의 구성비율), 소재의 표면상태(조도 등) 및 가열로내 조업조건(로온도, 작업속도 등) 등에 따라 값이 달라지는 까다로운 특성이 있다.

### 2.3 소재온도 변동에 관한 예측모델의 문제점

가열로가 원래의 설계 목적에 맞게 잘 작동하려면, 가열로에 투입되는 소재, 주어진 가열로 구조 및 조업 조건에 가장 알맞은  $U$ 의 값을 찾아야 한다. 그 이유는, 소재가 가열로를 빠져나갈 때 목표온도에 도달하게 하기위한 알맞은 로온도 설정값을 구하는 과정에서 식 (1)이 필요하기 때문이다. 그러나 그러한  $U$ 의 값을 구할 수 있는 이론적 수단이 없다. 따라서 실무에서는 대개 몇가지 대상들에 대한 시험을 통해 조업 가능한 수준내에서 시행착오적 방법으로  $U$ 의 값을 결정하고 있다. 따라서 다른 소재의 투입 또는 가열로 내 조업상황에 변동이 발생할 경우, 그에 알맞은  $U$ 의 값을 즉시 구할 수 없다면, 그에 따라 소재온도 적중률에 변동이 발생할 수 밖에 없는 조업상 문제가 있다.

### 3. 신경망 모델을 이용한 공정상수 예측 모델

위와 같은 조업상 기술문제를 해결하기위해, 몇가지 소재 및 조업 조건에 대한 조업데이터를 가지고, 임의의 소재 및 임의의 조업조건에 대해 알맞은  $U$ 의 값을 자동으로 산출하는 기능을 가진 신경망 모델을 제안한다.

#### 3.1 시험조건에서 $U$ 의 값 계산방법

임의의 소재 및 임의의 조업조건에 대해 알맞은  $U$ 의 값을 자동으로 산출하는 기능을 가진 신경망 모델을 개발하기 위해서는, 먼저 시험조건에서 취득한 조업데이터를 이용하여 그 조건에 맞는  $U$ 의 값을 찾아야만 하는 특수한 전제조건이 있다. 따라서 본 논문은 주어진 시험조건 데이터를 가지고 그 조건에 부합되는 실제  $U$ 의 값을 구할 수 있는 방법을 알고리즘 형태로 제안하였으며, 다음과 같다.

[시험조건에서  $U$ 의 값 계산 알고리즘]

Step1. 각 변수들의 초기값 설정

시험조건 데이터에서  $\rho, C, \sigma, F, h, d, LS, T_f$  (복사 온도계로 측정된 가열로내 로온도의 값), ‘가열로 출구에서  $T_s$ 의 측정값( $T_{s-out}$ 으로 약속함), ‘ $T_s$ 의 초기값(상온)’을 찾아 가열로내 소재의 온도 변화에 대한 예측모델에 설정한다.  $U$ 의 초기값은 방사율의 보편적 값을 참고하고 이 알고리즘을 통해 반복적 모의실험 경험을 통해 보통 0.255 정도의 값으로 설정한다. 여기서  $U$ 는 알맞은 값이 구해질 때까지 작은 증분(+ 또는 -)이 더해지는 형태로 변화되어야 하므로  $U(k), k=1,2,3,\dots$  으로 바꾸어 쓴다.

Step2. 예측모델의 계산

위 조건에서 가열로내 소재의 온도 변화에 대한 예측모델을 4차 Runge-Kutta 공식[6]을 이용하여 계산함으로써 가열로 출력단에서 ‘ $T_s$ 의 계산값’을 구한다.

Step3. 검증 및 완료여부결정

위 Step2에서 구한 ‘ $T_s$ 의 계산값’과  $T_{s-out}$ 과의 차이( $\Delta T_s$ )를 식 (2)와 같이 구한다.

$$\Delta T_s = T_{s-out} - T_s \text{의 계산값} \quad (2)$$

위와 같이 계산된  $\Delta T_s$ 가 지정된 오차범위이내인지 여부를 검증한 후, 만약 지정된 범위를 초과할 경우에는,  $U(k)$ 을 식 (3)과 같이 변화시킨다.

$$U(k) = U(k-1) + \Delta U \quad (3)$$

여기서  $\Delta U$ 는  $\Delta T_s$ 가 ‘+일 경우에는 +0.0001, -일 경우에는 -0.0001’로 정한다. 다음에 위 Step2부터 다시 시작한다. 만약  $\Delta T_s$ 가 지정된 오차범위이내일 경우에는 그때의  $U(k)$ 을 주어진 시험데이터에 알맞은  $U$ 의 값으로 확정한다.

#### 3.2 공정상수 예측을 위한 신경망 모델

신경망 모델이란, 어떤 시스템의 입력 및 출력 변수들 사이의 상호관계가 수식으로 표현될 수 없는 경우에, 그 관계를 신경네트워크 형태로 표현한 다음에, 그 입력 및 출력관계가 실제 시스템에 대한 실험을 통해 취득된 데이터와 유사한 관계가 되도록 신경네트워크

내부의 각 연결 강도를 결정하는 인공지능적 공정 모델링 방법이다[7]. 본 논문이 다루는 가열로내 소재의 온도 변화에 대한 예측모델내 공정상수 추론을 위한 모델은 수식으로는 표현될 수 없기 때문이다. 따라서 최선의 대안으로서 신경망 모델을 선정하였다. 다음에 본 논문이 제안한 공정상수 추론용 신경망형 모델을 설명한다.

### 3.2.1 입력변수들의 선정

입력변수들의 선정이란, 알맞은  $U$ 의 값을 산출하는 모델을 신경망 모델로 구성할 경우, 신경망 모델의 출력변수는 이미  $U$ 로 확정되어 있으므로, 신경망 모델의 입력에 어떠한 변수들을 사용하는 것이 적절할 지를 결정하는 문제이다. 앞에서 본 바와 같이,  $U$ 의 값에 영향을 주는 요인들은 크게 보면 ‘소재 조건’과 ‘조업 조건’의 두 가지 그룹으로 분류된다. 먼저 소재 조건 중에 현실적으로 고려될 수 있을 수 있는 것은 재질이다. 재질이란 수요가의 요구조건, 주문 규격 및 용도 등에 따라 품질 설계시 정해지는 화학 성분이며, 대표적 소재들에 대해서만 시험데이터를 이용한다. 따라서 소재를 그룹핑하여 번호화한 후 하나의 입력변수로 사용하는 것이 합리적이며, 신경망 모델의 입력변수로 표현하기엔 그 외 달리 표현할 수 있는 방법이 없다. 다음에 조업 조건은 ‘로온도’와 ‘조업속력’ 등이 있다. 로온도와 조업속력 등은 모두 실측되는 물리량들이므로,  $U$ 의 값 추론 성능을 향상시키기 위해 전부 입력변수들로 사용한다.

### 3.2.2 신경망 모델의 설계

먼저 신경망 모델에 사용될 기호들을 약속한다. 조업속력은  $a_1$ , 로온도는  $a_2$  및 제품번호는  $a_3$ 으로 정한다. 측정된 입력변수들에 대한 값을 신경망 내부에서 그대로 사용할 경우, 값의 크기로 인해 계산이 어려워지거나 수렴하지 않는 문제가 발생할 수 있다. 따라서 각 입력 변수의 값들이 설계된 신경망 내부의 계산에 알맞게 크기가 조절된 값을 각각  $a_1^n$ ,  $a_2^n$  및  $a_3^n$ 으로 정한다. 이와 같이 조절된 값들과 신경망 내부의 은닉층(Hidden layer) 사이의 연결 강도 계수들(Weight)

은  $wh_{\alpha\beta}$ 로 약속한다. 여기서  $\alpha=1,2,3$  및  $\beta=1,2,\dots,N$ 이며,  $N$ 은 은닉층의 개수이다. 또한 은닉층과 출력층 사이의 연결 강도 계수들은  $wo_\beta$ 로 약속한다.  $a_1^n$ ,  $a_2^n$  및  $a_3^n$ 와  $wh_{\alpha\beta}$ 를 이용하여  $\beta$ 번째 은닉층의 상태를 계산한 결과를 ‘ $net-Hidden_\beta$ ’라 약속하면,  $net-Hidden_\beta$ 는 다음과 같다.

$$net-Hidden_\beta = wh_{1\beta} a_1^n + wh_{2\beta} a_2^n + wh_{3\beta} a_3^n \quad (4)$$

각 은닉층에서 위 다항식의 계산 결과를 처리하는 평가함수는  $H_\beta(\cdot)$ 로 약속한다. 출력층에서도 은닉층과 마찬가지로 출력층의 계산결과를 ‘ $net$ ’라 약속하면,  $net$ 는 다음과 같다.

$$net = wo_1 H_1(\cdot) + wo_2 H_2(\cdot) + \dots + wo_N H_N(\cdot) \quad (5)$$

출력층에서  $net$ 를 처리하여 최종적으로 추론된  $U$ 를 출력하는 평가함수는  $Y(\cdot)$ 로 약속한다. 일반적으로 신경망 모델에서  $H_\beta(\cdot)$ 와  $Y(\cdot)$ 에 사용되는 함수의 종류는 여러 가지가 있다. 그런데 무엇을 신경망 모델로 표현하느냐 및 사용되는 변수의 값들 등 여러 가지 요인에 따라 그 신경망 모델에 알맞은 함수들이 달라지는데, 그 선택기준에 대하여는 특별한 규칙이나 공식이 존재하지 않는다. 따라서 본 논문은 설계자가 입력변수들에 대한 각 시험데이터를 가지고 많은 반복 시행 과정을 통해 가열로내 소재의 온도 변화에 대한 예측모델에서 공정상수의 산출에 알맞은 함수들을 식 (6) 및 식 (7)과 같이 설계하였다.

$$H_\beta(net-Hidden_\beta) = \frac{1}{1 + e^{-(net-Hidden_\beta)}} \quad (6)$$

$$Y(net) = 2\delta\left(\frac{1}{1 + e^{-\frac{net}{\gamma}}} - \frac{1}{2}\right) \quad (7)$$

여기서  $\delta$ 는 신경망 출력의 크기를 정규화 이전의 범위로 조절하는 역할을 하는 상수이며,  $\gamma$ 는 평가함수의 기울기를 변경하는데 필요한 상수이다. 이상의 과정을 통해 설계된 신경망 모델을 그림 2에 보인다. 신경

망 모델의 입력단에 표기된 숫자들은 신경망 튜닝시 계산 문제가 발생하지 않도록 입력변수의 값을 조절하는 것이며, 제품번호의 크기를 최대 3으로 변환하고, 이를 기준으로하여 나머지 입력변수들의 최대 크기를 3미만으로 맞춘다. 또한 출력단 평가함수의 크기 범위는 시행착오를 통해  $\pm 2.5$ 로 정하였고, 공정상수의 실무상 최대 크기인 0.5이하로 환산해 주기위해 5로 나눈다.




그림 2. 설계된 신경망 모델  
Fig. 2. A designed neural network model

#### 4. 모의실험과 결과

본 논문이 제안한 ‘가열로내 소재의 온도 변화에 대한 예측모델내 공정상수 예측을 위한 신경망 모델’의 타당성을 보이기 위해, 시험데이터를 이용한 모의실험을 시행하였다. 다음에 모의실험 결과를 보인다.

##### 4.1 모의실험용 시험데이터 및 U값의 계산

시험데이터는 공정에서 조업 중에 취득되었던 자료를 사용하였다. 시험데이터에 포함된 자료들은 목표 판온, 가열로 출구에서 측정된 판온, 조업속력, 제품정보 및 로온도 등이다. 이상의 시험데이터들을 앞에서 제안된 ‘시험조건에서의 U의 값 계산 알고리즘’에 대입하여 얻은 결과를 표 1에 보인다. 여기서 제품번호

는 각 제품을 0에서 1사이의 숫자에 대응시키는 방법으로 구분하였다. 이는 설계된 신경망 모델을 학습시키는 과정을 통해 학습수렴속도가 빠르도록 경험적 방법으로 선정된 것이다.

표 1. 시험데이터와 U의 값  
Table 1. Process data and computing result of U

	조업속력 (mpm)	로온도(°C)	제품번호	U
1	150	800.96	0.1	0.2598
2	88.1	858.25	0.2	0.2887
3	106.2	609.28	0.3	0.3062

##### 4.2 U의 값 추론용 신경망 모델 설계 결과와 성능

이제 표 1에 있는 물리량들 중 조업속력, 로온도 및 제품번호를 입력 변수로 하고, U를 출력변수로 하는 신경망 모델을 설계한다. 반복적인 모의실험을 통해, 신경망의 은닉층 개수는 8개,  $\delta$ 는 2.5 및  $\gamma$ 는 9.999로 결정한 후, 신경망 모델내 은닉층과 출력층에 있는 각 가중치를 구하는 방법은 가장 널리 사용되는 보편적 방법인 오류역전파법(Back propagation method)을 이용하였다[7-8]. 오류역전파법은 먼저 신경망 학습에 필요한 변수의 값들이 설정되면, 모든 가중치들을 임의의 값으로 설정시키고, 시험데이터를 설계된 신경망에 입력하여 신경망 출력을 계산한 다음 오류역전파식으로 각 가중치들의 값을 다시 계산한 후 지정된 목표에 도달할 때까지 위 계산을 반복한다. 위와 같은 방법으로 각 층의 연결강도들을 찾아 본 결과, 은닉층 내부의 연결강도들은 표 2 및 출력층 내부의 연결강도는 표 3과 같이 구해졌다. 시험데이터를 설계된 신경망 모델에 입력한 후 신경망을 통해 계산된 출력과 ‘표 1에 있는 계산된 값’과의 비교한 결과를 표 4에 보인다. 표 4는 본 논문이 제안한 신경망 모델이 같은 입력 조건에서 실제와 동일한 공정상수를 추론하고 있음을 보여 주는 것이다. 이 결과는 신경망 출력의 크기가 학습시 자료와 소수 넷째자리까지 일치되도록 설계되었기 때문이다.

표 2. 은닉층 내부의 연결 강도들( $wh_{\alpha\beta}$ )  
Table 2. Weightings in hidden layer( $wh_{\alpha\beta}$ )

$\beta \backslash \alpha$	1	2	3
1	-0.1128	-1.3358	0.9038
2	1.7808	-0.3960	0.8604
3	-0.7463	-1.1768	2.0005
4	-0.5599	0.1348	-1.0819
5	1.4608	1.9670	2.1076
6	1.8294	-0.2849	2.2096
7	1.1707	-2.1714	-1.8482
8	1.3067	1.3107	1.8909

표 3. 출력층 내부의 연결 강도들( $wo_{\beta}$ )  
Table 3. Weightings in output layer( $wo_{\beta}$ )

$\beta$	$wo_{\beta}$
1	1.0841
2	2.2811
3	2.5300
4	0.1537
5	3.7194
6	2.3127
7	-1.2683
8	2.7508

표 4. 설계된 신경망 모델의 성능  
Table 4. Performance of suggested neural net model

	$U$ (알고리즘으로 계산된 값)	$U$ (설계된 신경망 출력값)
1	0.2598	0.2598
2	0.2887	0.2887
3	0.3062	0.3062

### 4.3 결과 고찰

이상의 모의실험 결과를 통해 본 논문의 성과 내지 경제적 이익 등을 설명한다. 첫째, 본 논문이 제안한

‘시험조건에서의  $U$ 의 값 계산 알고리즘’을 이용하면, 시험용 소재에 대한 조업 결과로 취득된 시험데이터를 얻을 수 있을 경우, 가열로내 소재의 온도 변화에 대한 예측모델내 공정변수를 제안된 알고리즘을 통해 구할 수 있고, 결국 수식모델을 완성할 수 있음이 입증되었다. 둘째, 만약 시험데이터를 가지고 있지 않은 작업조건에서 작업을 해야 할 상황이 발생할 경우, 기존에는 그 상태에 알맞은 새로운  $U$ 의 값을 찾기 위해 다시 시험을 하여 그 상황에 맞는 시험데이터를 구해야만 했다. 그렇게 할 경우 하나의 소재에 대해 한번 시험을 하면 경제적 손실(소재 하나를 시험후 고철처리하면 그 소재의 가열로 작업후에 이어지는 열간압연후 완성제품의 가치인 수천만원의 손실, 상온의 소재를 고온으로 가열시키는 동안 소비된 연료비 손실 및 기타 시간적 비용 손실 등)이 크다. 이는 가열로를 운영하는 기업에 경영상 부담을 주게 된다. 그러나 본 논문이 제안한 ‘공정상수 추론용 신경망 모델’을 이용하면, 위와 같이 경제적 손실이 발생할 수 밖에 없는 실제 작업을 하지 않고서도, 단지 새로운 작업조건을 설계된 신경망 모델에 입력하기만 하면 그 상황에 알맞은 공정상수가 실시간으로 계산된다. 따라서 가열로 운전이 있어서 경제적 잇점이 있는 기술임이 입증된 것이다.

## 5. 결 론

본 논문은 가열로내 소재의 온도 변화에 대한 예측 모델에서 공정상수를 시험데이터로부터 찾아내는 방법을 알고리즘 형태로 제안하였다. 시험데이터 이외의 작업조건에 알맞은 공정상수를 실시간으로 산출해 낼 수 있는 신경망 모델의 설계 방법을 제안하였다. 공정에서 조업 중에 취득되었던 데이터를 본 논문이 제안한 공정상수의 계산 알고리즘에 대입한 결과, 공정상수가 구해짐을 보였다. 나아가 설계된 신경망 모델을 시험데이터를 이용하여 알맞게 튜닝함으로써, 작업조건이 변경될 경우에도, 그에 알맞은 공정상수가 새로운 시험없이 신경망 모델의 계산을 통해 실시간으로 구해질 수 있음을 보였다. 향후 본 논문이 제안한 공정상수의 산출 방법을 2차원으로 확장시키면 가

열로운전기술을 향상시키면서 운전비용절감에도 획기적인 도움이 될 것이다.

### References

- [1] J. Harish and P. Dutta, "Heat transfer analysis of pusher type reheat furnace", Ironmaking and Steelmaking, Vol.32, No.2, pp.151-158, 2005.
- [2] M. Safari and A. Saboonchi, "Simulation of temperature distribution in a continuous tunnel reheat furnace using the monte carlo method", International Journal of ISSI, Vol.5, No.1, pp.1-7, 2008.
- [3] Fuyong Su, Zhi Li and Zhi Wen, "Temperature setting method for regenerative rotary reheating furnace", Journal of Information & Computational Science, Vol.10, No.10, pp.3143-3151, 2013.
- [4] Pongam T., Srisertpol J., and Khomphis V., "Manufacturing process identification for reheating furnace walking hearth type using genetic algorithm", International Journal of Modeling and Optimization, Vol.2, No.2, pp.114-118, 2012.
- [5] Yunus A. Cengel, "Heat Transfer: A Practical Approach", McGraw-Hill, 2002.
- [6] Dennis G. Zill, Michael R. Cullen, "Advanced Engineering Mathematics", PWS Publishing Company, pp.880-885. 1992.
- [7] Anil K. Jain, Jianchang Mao, and K. M. Mohiuddin, "Artificial Neural Networks: A Tutorial", IEEE, 1996.
- [8] C. J. Harris, C. G. Moore, and M. Brown, "Intelligent control- Aspects of fuzzy logic and neural nets", World Scientific, 1993.

### ◇ 저자소개 ◇



#### 김태은(金台恩)

1979년 11월 22일생. 2005년 2월 영남대학교 전자공학과 졸업. 2007년 8월 영남대학교 대학원 전기공학과 졸업(석사). 현재 태창기계공업 기업부설연구소 연구원.



#### 이해영(李海榮)

1963년 7월 5일생. 1984년 2월 부산대학교 전기기계공학과 졸업. 1990년 2월 한국과학기술원 전기및전자공학과 졸업(박사). 현재 영남대학교 전기공학과 교수.