
뉴로-퍼지 시스템을 이용한 CAL공정내 용접상태 진단

김경민*, 김이곤*, 박중조**, 송명현***, 정양희*, 배영철*, 최남섭*

Diagnosis for the Welding Condition of the CAL Process using Neuro-Fuzzy System

Kyoung-min Kim, Yi-gon Kim, Joong-jo Park, Myung-hyun Song, Yang-Hee Jung,
Young-chul Bae, Nam-sup Choi

Abstract

The use of neural-fuzzy system to model mesh seam welding is described in this paper. Conventional, automated process generally involves sophisticated sensing and control techniques applied to various processing parameters. Welding parameters affecting quality include the arc voltage, the welding current, torch travel speed and the pressure and so on. The relationship between the welding parameters and weld quality is not a direct one, and in addition, the effect of the weld parameter variables are not independent of the each other.

The effectiveness of the proposed neuro-fuzzy algorithms is demonstrated by computer simulations.

Keywords : neural-fuzzy, welding process, mash seam welding

1. 서 론

일반적으로 냉연공정에 있어서 연속작업을 위한 Coil to Coil의 용접은 mash seam용접에 의해서 수행되고 있는데, 용접품질상태는 조업자의 경

험에 의한 감각과 육안 그리고 hammering으로 판단하고 있다.

이는 조업자에 따라 판정 기준이 달라지고, 용접 품질의 평가 자체가 표준화되지 못하므로 CAL의 가장 핵심적인 관리 기준중의 하나인 작업 연

* 여수대학교 전기공학과

** 경상대학교 제어계측공학과

*** 순천대학교 전기제어공학과

속성의 품질확보에 위협을 받고 있는 상태이다. 따라서 용접 품질을 객관적으로 판단할 방법을 강구해야 할 상태이다.

일본의 Kawasaki 제철사에서 용접 품질 판정 기준을 마련하여 system에 적용 가동중에 있으나, 이는 F/R(Fault Ratio)을 설정하여 이에 따라 Fault Alarm, Buzzer을 통한 경고와 CRT를 통해 고장의 상태를 표시하고 있으나 초보적인 단계로 알고 있다.

프랑스의 SOLLAC사에서도 두께와 강종정보로 모델링을 하여 system을 구성하고 있으나 만족할 만한 해결책은 제시하지 못하고 있는 실정으로 현재까지 용접부 품질에 대한 판정 기준(표준)이 전무한 상태이다.

따라서 용접품질의 합, 부 판정을 위한 표준수치 값과 용접품질에 대한 규격화가 필요하며, 이를 기초로 용접부 상태진단을 위한 체계적인 진단 알고리즘의 개발이 요구되어진다.

본 연구에서는 용접부품질 판정기준 파라미터를 정량화하여, 명확한(explicit) 지식을 다루는 퍼지 시스템의 장점과 학습에 의해 구해지는 근사화한(implicit) 지식을 다루는 신경회로망의 장점을 결합한 뉴로-퍼지 하이브리드 진단시스템을 개발하고자 한다.

2. 용접기의 용접불량과 고장요인 분석

용접 기술은 철강산업의 기초분야로 그 중요도가 대단히 높지만 이 분야의 기술개발과 연구가 계속 요구되는 분야이다. Welder의 용접 불량이나 고장 요인은 크게 Hardware(설비)와 Software(제어, 조업)적인 것으로 분류할 수 있으며 Hardware적인 것은 용접설비의 성능에 기인함으로써 새로운 설비의 도입 및 용접기술개발 등으로 용접불량과 고장을 개선할 수 있다. Software 분야는 정밀 제어기술과 시스템의 신뢰도를 높이기 위한 제반 기술을 말한다. 본 논문에서는 Software분야로서 용접 파라미터와 조업data을 분석, 체취하여 용접 파라미터를 세분화하고 적정 용접 진단 Table을 구하여 용접 품질상태를 진단하는 조업의 신뢰도를 확보할 수 있는 시스템을 개발하는 것이다.

CAL조업의 Line 용접에 사용되고 있는 Mesh

seam 용접불량이 미치는 생산성 영향을 분석하면 소둔로 내 판파단을 발생시킬 수 있다. 이 경우 평균 20시간 line stop(120 coil 생산중단)을 야기시킨다. 그리고 용접부의 형상이 불량하게 될 경우는 SPM에 영향(center Mark)을 줄 수 있고, 이럴 경우 이러한 제 문제를 해결하기 위해 재용접을 필요로 한다. 그럴 경우에는 생산라인의 정지가 필요하므로 생산공정에 차질을 발생시킨다.

결합의 요인을 살펴보면, 용접기 전극의 마모 냉각, 정밀도, Cam/유압의 정밀도와 용접속도, 전류 등의 용접 변수와 작업성으로 평가되는 숙련도, 품질관리 그리고 소재에 의한 결합(편식, 개재물), 절단부의 정밀도, 표면처리, 기계적 특성과 화학적 조성의 영향을 받는다. 마지막으로 용접기의 전후 설비의 영향 등이 용접부의 품질을 결정한다. 그 결과 용접부 균열이 발생하여 판 파단등을 야기시킨다.

용접부 결합의 종류 및 원인을 살펴보면, 불충분한 가열이나 또는 Upsetting의 결과로 생기는 Crevice, 급속 냉각으로 발생하는 Cracking, 불충분한 Upset 압력으로 발생하는 Void가 있다. 그리고 불충분한 Upset 압력으로 생기는 Oxides and Inclusions, 높은 flashing 전압, 높은 온도 편차에 의한 Penetrator가 있다.

Line 용접에서 Mash seam 용접품질에 미치는 공정 변수는 primary parameter인 용접 전류, 용접 속도, 전극 가압력, 소재의 종류, 부재의 두께, Overlap 량, Overlap형태, Planish 가압력(or 유무)이 있고, secondary parameter로는 전원의 종류(AC, DC, 주파수, Waveform), 구동계의 방식 및 정밀도, Clamping 상태, 전극 휠의 표면상태, 소재의 표면상태등으로 분류할 수 있다. 본 연구에서는 용접 전류, 속도, 가압력, 두께, LAP, Swaging 합력을 중심으로 용접상태진단을 수행하고자한다.

3. 퍼지 동적 모델의 온-라인 식별모델

3.1 퍼지동적모델(Fuzzy Dynamic model)

본 논문에서는 복잡한 MIMO(multi-input multi-output) 비선형 계통을 표현하기 위해 다음과 같이 근사추론 규칙과 지역선형모델을 포함하는 퍼지모델을 고려한다.

$$\begin{aligned}
 R^l: IF z_1 \text{ is } F_1^l \dots \text{ AND } z_n \text{ is } F_n^l \\
 \text{THEN } y(t+1) = A_l(q^{-1})y(t) + B_l(q^{-1})u(t) + C_l \\
 A_l(q^{-1}) = A_1^l + A_2^l q^{-1} + \dots + A_n^l q^{-n+1}, \\
 A_k^l = [a_{kj}^l]_{p \times p} \\
 B_l(q^{-1}) = B_0^l + B_1^l q^{-1} + \dots + B_{n-1}^l q^{-n+1}, \\
 B_k^l = [b_{kj}^l]_{p \times g} \\
 l = 1, 2, 3, \dots, m, \quad \bar{n} = p \times n + g \times n
 \end{aligned} \tag{1}$$

여기서, R^l 은 l -번째 근사추론규칙, (A_l, B_l, C_l) 은 l -번째 지역모델의 파라미터, m 은 근사추론 규칙의 개수(number), $u(t) \in R^g$ 와 $y(t) \in R^p$ 는 각각 계통의 입력, 출력 변수이다. q^{-1} 는 시간 지연연산자이다. $z(t)$ 는 입출력으로 다음과 같이 구성되는 벡터이다.

$$z(t) = [y(t)^T, y(t-1)^T, \dots, y(t-n+1)^T, u(t-1)^T, \dots, u(t-n+1)^T]^T \tag{2}$$

모델의 출력은 식(1)의 모든 지역모델들에 대해 하중평균(weighted average)을 취함으로써 추론될 수 있다.

본 논문에서는 S. G. Cao등에 의해 제안된 퍼지 동적모델의 오프라인 식별 알고리즘을 고장진단 목적에 적합하도록 온라인화 한 것으로서 식(1)의 전건부 소속함수 식별 알고리즘과 후건부의 지역 모델 알고리즘의 두 단계로 구성된다.

3.2 소속함수의 식별

퍼지모델에서 근사적 추론 규칙의 전건부 소속함수들은 프로세스 입출력 공간을 임의로 퍼지 분할하도록 정의하는 경우도 있는데 그러한 경우 규칙의 개수가 증가하여 바람직하지 않으며, 입출력 데이터들에 대해 fuzzy c-means(FCM)을 적용하여 정의하는 것이 더욱 일반적이다. 그러나 일반적인 FCM에서의 평가함수들은 패턴인식 문제에서와 같은 정적인 데이터에 적합한 것이므로 제어기 설계, FDI 설계 문제와 같이 동적인 데이터의 경우에는 적합하지가 않다. S.G.Cao 등은 선형모델의 오차에 대한 보상항을 포함하는 평가함수를 이용한 동적

퍼지 클러스터링(dynamic fuzzy clustering : DFCM) 알고리즘을 제안하고 이를 퍼지동적모델의 소속함수 식별에 사용하여 그 유용성을 보였다. 평가함수는 다음과 같다.

$$\begin{aligned}
 J(\mu, \bar{z}, a) = w_1 \left[\sum_{l=1}^m \sum_{t=1}^N \mu_l(t)^\omega \|z(t) - \bar{z}_l\|^2 \right] \\
 + w_2 \left[\sum_{l=1}^m \sum_{t=1}^N \mu_l(t)^\omega e_l(t) \right]
 \end{aligned} \tag{3}$$

$$\begin{aligned}
 e_l(t) = y(t)^T - \varphi(t-1)^T a^l \\
 \varphi(t-1)^T = ((1, 1, \dots), y(t-1)^T, \dots, y(t-n)^T, \\
 u(t-1)^T, \dots, u(t-n)^T) \\
 a^l = [\alpha_1^l \quad \alpha_2^l \quad \dots \quad \alpha_p^l] \quad \alpha_j^l = [\alpha_{j1}^l \quad \dots \quad \alpha_{jn}^l]
 \end{aligned} \tag{4}$$

단, $\bar{n} = p + p \times n + g \times n$, 모든 t 에 대해 $\sum_{l=1}^m \mu_l(t) = 1$ 이며, \bar{z}_l : 클러스터 중심값, ω : 지수하중(exponential weight), w_1, w_2 : 하중값(weighting value), $\|z(t) - \bar{z}_l\|$: \bar{z}_l 로부터 $z(t)$ 까지의 거리이다.

식(3)의 평가함수에서 첫째 항은 z 벡터와 각 클러스터의 중심값과의 거리가 가능한 작게 되도록 하는 것이므로 입력공간의 퍼지분할에 해당되며, 두 번째 항은 퍼지 계통과 지역 선형모델간의 출력간의 추정 오차가 최소가 되도록 입력공간을 최적 분할되도록 하는 것이다. 각 파라미터에 대해서 평가함수를 최소화하는 클러스터링 알고리즘은 다음과 같다.

$$\bar{z}_l = \frac{\sum_{t=1}^N \mu_l(t)^\omega z(t)}{\sum_{t=1}^N \mu_l(t)^\omega}, \quad l=1, 2, \dots, m \tag{5}$$

$$a_l = [\Phi^T D_l \Phi]^{-1} \Phi^T D_l Y, \quad l=1, 2, \dots, m \tag{6}$$

$$D_l = \text{diag}[\mu_l(t)]_{N \times N} \tag{7}$$

$$\Phi = [\varphi(1) \quad \varphi(2) \quad \dots \quad \varphi(N)]^T \tag{8}$$

$$Y = [y(1) \quad y(2) \quad \dots \quad y(N)]^T$$

$$\mu_i(t) = \left\{ \frac{\sum_{j=1}^m \frac{[\omega_1 \|z(t) - \bar{z}_i\|^2 + \omega_2 e_i(t)^2]^{\frac{1}{w-1}}}{[\omega_1 \|z(t) - \bar{z}_j\|^2 + \omega_2 e_j(t)^2]^{\frac{1}{w-1}}} \right\}^{-1} \quad (9)$$

U = [μ_{ij}]_{i=1,2,...,m, j=1,2,...,N}
 : 분할행렬(partition matrix)

위의 분할행렬은 해석적인 방법에 의해 해를 얻을 수 없기 때문에 반복적인 방법으로 구해야 하며 그 과정은 다음과 같다.

- 1) 클러스터의 수(2 ≤ m ≤ N)와 ω(1 < ω < ∞), w₁, w₂,의 값을 정하고 초기 분할행렬 U⁽⁰⁾ 및 최종한계값 ε > 0 를 설정한다. 단, 반복회수 k=0.
- 2) U^(k)와 식(6)을 이용하여 중심값 \bar{z}_i^k (i=1,2,...,m k=0, 1,...)를 구한다.
- 3) \bar{z}_i^k 와 식(10)을 이용하여 새로운 분할행렬 U^(k+1) 를 구한다.
- 4) || U^(k+1) - U^(k) || ≤ ε 이면 중지, 아니면 단계 2로 돌아감.

하나의 주어진 데이터가 각 규칙에 소속되는 정도의 합은 반드시 1 이 되어야 하므로 초기의 분할행렬 U⁽⁰⁾는 다음의 조건을 만족하도록 설정하여야 한다.

$$\sum_{i=1}^m \mu_{ij} = 1 \quad j=1, 2, \dots, N \quad (10)$$

3.3 지역모델의 온라인 진단

지역선형모델의 식별은 식(2)의 퍼지모델 출력과 계통 출력간의 예측오차를 최소화할 수 있는 선형모델의 파라미터를 추정하는 문제이며 앞절에서 설정한 소속 함수를 이용하여 최소자승법(least square algorithm: LSA)으로 수행할 수 있다. 일반성은 유지하면서 전개를 간단히 하기 위해 MISO(multi input multi output) 계통인 경우로 가정하고, 식(1)의 퍼지동적모델중 하나의 규칙에서의 지역모델에 대한 진단 알고리즘을 기술한다.

식(1)의 퍼지동적모델에서 l-번째 규칙에 의한 계통 출력의 예측값은 다음의 형태로 표현할 수

있다.

$$\hat{y}_l(t) = v^T(t, \mu) \hat{\theta}^l \quad (11)$$

여기서 $v^T(t, \mu) = \mu_l(z(t-1)) \varphi(t-1) = [v_0(t, \mu) \ v_1(t, \mu) \ \dots \ v_M(t, \mu)]$, $\hat{\theta}^l = (\theta_1^l, \theta_2^l, \dots, \theta_M^l)^T$ 는 l-번째 규칙의 파라미터 추정값이다.

$$\mu_l(z) = \left\{ \frac{\sum_{i=1}^m \frac{[\omega_1 \|z(t) - \bar{z}_i\|^2]^{\frac{1}{w-1}}}{[\omega_1 \|z(t) - \bar{z}_j\|^2]^{\frac{1}{w-1}}} \right\}^{-1} \quad (12)$$

오프라인 파라미터 추정문제는 다음의 평가함수를 최소화하는 파라미터를 결정하는 것으로 정의할 수 있다. (N 은 데이터의 개수)

$$J(\hat{\theta}) = \| Y - \Phi(\mu) \hat{\theta} \|^2 \quad (13)$$

$$\Phi(\mu) = \begin{bmatrix} v_0(1, \mu) & v_1(1, \mu) \dots & v_M(1, \mu) \\ v_0(2, \mu) & v_1(2, \mu) \dots & v_M(2, \mu) \\ \vdots & \vdots & \vdots \\ v_0(N, \mu) & v_1(N, \mu) \dots & v_M(N, \mu) \end{bmatrix} \quad (14)$$

식(14)를 최소화하는 파라미터는 다음과 같이 계산된다.

$$\hat{\theta}_l = [\Phi(\mu)^T \Phi(\mu)]^{-1} \Phi(\mu)^T Y \quad (15)$$

진단에의 응용을 위해서는 지역선형모델을 온라인으로 진단해야 하며, 이를 위해 RLSA(recursive least square algorithm)으로서 다음을 사용할 수 있다.

$$\hat{\theta}_l(t) = \hat{\theta}_l(t-1) + L(t)[y(t) - v(t, \mu_l)^T \hat{\theta}_l(t-1)] \quad (16)$$

$$L(t) = \frac{P(t-1)v(t, \mu_l)}{\lambda(t) + v(t, \mu_l)^T P(t-1)v(t, \mu_l)} \quad (17)$$

$$P(t) = [P(t-1) - \frac{P(t-1)v(t, \mu_l)v(t, \mu_l)^T P(t-1)}{\lambda(t) + v(t, \mu_l)^T P(t-1)v(t, \mu_l)}] \quad (18)$$

여기서, $v(t, \mu_l)^T = [v_0(t, \mu_l) \ v_1(t, \mu_l) \ \dots]$

$v_M(t, \mu_i)$, $\lambda(t)$ 는 forgetting factor이다.

3.4 신경망 학습

다층 신경회로망의 역전파 학습 알고리즘은 일반화된 델타 룰(Generalized delta rule)을 적용함으로써 이루어지는데 임의의 (n) 번째 층을 표현한 모델에 따르면 그림 3-1과 같다




그림 3.1 (n) th Layer의 Neuron Model

(n-1)층에 존재하는 L개의 뉴런에서 출력되는 $O_i^{(n-1)}$ 는 각각의 연결 가중치와 곱해지고 합산되어 $I_j^{(n)}$ 라는 값으로 (n)층에 입력된 다음 (n)층의 $f(I_j^{(n)})$ 의 함수를 통하여 출력 $O_j^{(n)}$ 이 얻어진다.

$$I_j^{(n)} = \sum_{i=1}^L w_{ji}^{(n)} * O_i^{(n-1)} \quad \dots\dots\dots (19)$$

$$O_j^{(n)} = f(I_j^{(n)}) \quad \dots\dots\dots (20)$$

이때 (n-1)층에 입력된 P번째 학습데이터로부터 (n)층에서 원하는 출력이 $D_{pj}^{(n)}$ 이고 실제로 추론된 출력이 $O_j^{(n)}$ 이라면 그 에러 값은 $\epsilon^{(n)} = D_{pj}^{(n)} - O_j^{(n)}$ 이고, 이때 에너지 평가 함수는 식(21)과 같이 정의된다.

$$E_{pj} = \frac{1}{2} (D_{pj}^{(n)} - O_j^{(n)})^2 \quad \dots\dots\dots (21)$$

에너지 평가 함수 E_{pj} 를 최소로 하기 위해 p번째 데이터의 오차에 대한 i번째의 결합 하중치 $w_{ji}^{(n)}$ 의 변화량 $\Delta w_{ji}^{(n)}$ 는 다음과 같이 유도된다.

$$\frac{\partial E_{pj}}{\partial w_{ji}} = -(D_{pj}^{(n)} - O_j^{(n)}) \frac{\partial f(I_j^{(n)})}{\partial I_j^{(n)}} \frac{\partial I_j^{(n)}}{\partial w_{ji}} \quad \dots\dots\dots (22)$$

(n) 층 입력의 i번째 입력 가중치에 대한 미분을 구하면 식(21)과 같고 이를 식(22)에 대입하면 식(23)과 같다.

$$\frac{\partial I_j^{(n)}}{\partial w_{ji}} = \frac{\partial}{\partial w_{ji}} (\sum_{k=1}^L w_{jk}^{(n)} * D_k^{(n-1)}) = O_i^{(n-1)} \quad \dots\dots\dots (23)$$

$$\frac{\partial E_{pj}}{\partial w_{ji}} = -(D_{pj}^{(n)} - O_j^{(n)}) f'(I_j^{(n)}) O_i^{(n-1)} \quad \dots\dots\dots (24)$$

다음 학습되기 전의 상태를 (t) 라면 (t+1) 상태의 가중치를 갱신하는 변화량은 에러의 변화분에 역으로 작용한다.

$$w_{ji}^{(n)}(t+1) = w_{ji}^{(n)}(t) + \Delta w_{ji}^{(n)}(t) \quad \dots\dots\dots (25)$$

$$\Delta w_{ji}^{(n)} = \eta (D_{pj}^{(n)} - O_j^{(n)}) f'(I_j^{(n)}) O_i^{(n-1)} \quad \dots\dots\dots (26)$$

여기서 η 는 학습률(learning-rate)이다. 간략화시키기 위해 식(27)라 놓으면 식(28)과 같이 된다.

$$\delta^{(n)} = (D_{pj}^{(n)} - O_j^{(n)}) f'(I_j^{(n)}) \quad \dots\dots\dots (27)$$

$$w_{ji}^{(n)}(t+1) = w_{ji}^{(n)}(t) + \eta \delta^{(n)} O_i^{(n-1)} \quad \dots\dots\dots (28)$$

위 역전파 학습 알고리즘에 따라 뉴로-퍼지의 전건부 삼각형 멤버쉽 함수와 후건부 싱글톤 값이 다음의 학습 과정을 통해 동정된다.

4. 실험과 고찰

본 연구의 실험 대상의 용접시스템은 Mesh seam으로 구조와 동작원리를 살펴보면 다음과 같다. 본 실험에서는 일상 조업 데이터를 분석하여 용접 조건표를 얻고 이를 실험하여 수정된 용접조건을 구하는 실험을 시도하였으며 이의 타당성을 입증하고자 하였다.




그림 4.1 MESH SEAM WELDER의 구조

그림4.1의 시스템 동작원리를 그림으로 나타내면 다음과 같이 Clamp와 Welding Wheel 그리고 전원 공급을 위한 변압기로 구성되었다.




그림 4.2 Welder의 동작원리

Table 4.1은 정상상태 조업중 용접품질을 결정하는 Coil의 두께, 용접전류, 용접속도, LAP, Swaging합력의 값을 도표로 나타내었으며 그림 4.3과 같이 그림으로 용접조건을 얻을 수 있었다. 이 경우 실제 용접을 실험하여 용접시 발생하여 용접품질에 직접적인 영향을 미치는 Spark와

Table 4.1 용접파라미터값 테이블

두께	전류		속도		압력		LAP		SWAGING합력	
	CG이상	HSS	CG이상	HSS	CG이상	HSS	CG이상	HSS	CG이상	HSS
0.4	11	9	15		400		1		L	
0.5	11	9	15		450		1		L	
0.6	12	10	15		550		1		L	
0.7	12	10	15		650		1		L	
0.8	13	11	15		750		1		H	
0.9	13	11	15		850		1		H	
1.0	14	12	15		900		1		H	
1.1	15	13	15		950		1		H	
1.2	15	13	15		950		1		H	
1.3	16	14	15		1000		1		H	
1.4	17	15	15		1050		1		H	
1.5	17	15	15		1100		1		H	
1.6	18	16	15		1150		1		H	
1.7	18	16	15		1150		1		H	
1.8	18	16	15		1200		1.5		H	
1.9	19	17	15		1250		1.5		H	
2.0	19	17	15		1300		1.5		H	
2.1	19	17	15		1350		1.5		H	
2.2	20	18	15		1350		1.5		H	
2.3	20	18	15		1400		1.5		H	

Erichsen Test결과를 중심으로 Table 4.2와 같이 얻었다.




그림 4.3 정상 조업시 얻어진 용접조건




그림 4.4 수정된 용접 조건

Table 4.2의 실험결과로부터 얻어진 정보를 이용하여 수정된 용접 조건표를 Table 4.3에서 얻어 졌으며 수정된 결과를 그림 4.4에서 보여주고 있다.

5. 결과

본 연구는 CAL공정내의 용접상태진단을 위한 용접시스템의 기초자료 취득과 분석을 토대로 뉴로-퍼지 진단 시스템을 설계하였다. 연구 결과에서와 같이 일상 조업데이터를 이용하여 조업 조건 테이블을 얻었으며, 얻어진 조건을 이용하여 진단 시스템을 구성하여 이를 토대로 그림 4.4와 같이 수정된 결과를 도출할 수 있었다. 앞으로의 연구방향은 이러한 수정된 테이블을 경험에 의한 수정조건 탐색 대신에 뉴로-퍼지를 이용한 진단 알고리즘을 적용하여 보다 신뢰성있고 정확한 용접 조건 도출 모델을 설계하고자 한다.

참고문헌

1. Iserman,R., P. Balle, "Trends in the Application of Model-based Fault Detection and Diagnosis of Technical Process",13th IFAC World Cong., Sanfrancisco. pp.709-719, 1996.

Table 4.2 용접실험 결과표

구분	용접전류	속도	압력	LAP	SWAGING	SPARK	ERICHSENTE ST결과	비고
0.6+0.6	12	15	550	1	L	양호	양호	
1.0+1.0	13	15	900	1	H	양호	불량	
1.5+1.5	17	10	1100	1	H	양호	양호	
2.0+2.0	19	7	1200	1.5	H	미량발생	양호	
0.6+1.0	12	15	550	1	L	양호	양호	
0.6+1.0	12	15	750	1	H	양호	불량	
0.6+1.0	13	15	900	1	H	양호	불량	
1.0+1.5	13	15	900	1	H	양호	불량	
1.0+1.5	15	14	950	1	H	양호	양호	
1.0+1.5	17	10	1100	1	H	양호	양호	
1.5+2.0	17	10	1100	1	H	미량발생	보통	
1.5+2.0	18	8	1150	1	H	미량발생	양호	
1.5+2.0	19	6	1200	1.5	H	미량발생	양호	

Table 4.3 수정된 용접 조건표

두께	전류		속도		압력		LAP		SWAGING합력	
	CG이상	HSS	CG이상	HSS	CG이상	HSS	CG이상	HSS	CG이상	HSS
0.4	11	9	15		400		1		L	
0.5	12	10	15		450		1		L	
0.6	12	10	15		550		1		L	
0.7	12	10	15		650		1		L	
0.8	12	10	15		750		1		H	
0.9	13	11	15		850		1		H	
1.0	13	11	15		900		1		H	
1.1	14	12	15		950		1		H	
1.2	15	13	14		950		1		H	
1.3	15	13	12		1000		1		H	
1.4	16	14	11		1050		1		H	
1.5	17	15	10		1100		1		H	
1.6	18	16	9		1100		1		H	
1.7	18	16	8		1150		1		H	
1.8	18	16	8		1150		2		H	
1.9	19	17	7		1200		2		H	
2.0	19	17	6		1200		1.5		H	
2.1	19	17	5		1200		1.5		H	
2.2	20	18	5		1250		1.5		H	
2.3	20	18	4		1250		1.5		H	

2. Patton,R.J. ,P.M. Frank,R.N. Clark (eds). Fault Diagnosis in Dynamical Systems. - Theory and Applications, Prentice Hall (control engineering series), 1989
3. Isidori,A, Nonlinear control systems an Introduction lecture notes in control and information science Vol.72 Springer-Verlag Berlin, 1985.
4. P.Balle, D.Juricic, A.Rakar, S.Ernst, “ Identification of Nonlinear Processes and Model Based Fault Isolation Using Local Linear Models”, AACC, 1997.
5. S.G.Cao, N.W.Rees and G.Feng, “ Analysis and Design for a Class of Complex Control Systems, Part I: Fuzzy Modelling and Identification ”, Automatica, Vol.33, No. 6, pp. 1017-1028, 1997.

※ 본 논문은 과학기술부·한국과학재단 지정 여수대학교 설비 자동화 및 정보시스템 연구개발센터 연구비 지원에 의한 것임.

김 경 민

1988년 고려대 전기공학과 졸업.

동대학원 석사(1991), 박사(1996).

1997년~현재 여수대학교 전기공학과 조교수.

*관심분야는 신호처리 및 컴퓨터비전, 퍼지 및 신경 회로망 응용.

박 중 조

1981, 1983, 1995 고려대 전기공학과 학사 석사 박사.

1996년~현재 경상대학교 전기전자공학부 부교수.

*관심분야 : 컴퓨터비전, 패턴인식, 퍼지 및 신경회로망.

송 명 현

고려대 전기공학과 학사 석사 박사.
1988년 ~ 현재 순천대학교 전기제어공학과 교수.
*관심분야 : 제어 시스템, 퍼지 및 신경회로망 제어,
시스템 설계.



배 영 철

1984, 광운대 전기공학과 졸업.
1997년 2월 광운대 대학원 박사
1986~1991 한국전력공사
현재 여수대학교 전기공학과 조
교수


*관심분야 : 퍼지 및 신경망 카오스동기화.



정 양 희(Yang-Hee Joung)

1983년 2월 단국대학교 응용물
리학과 졸업(공학사)
1985년 8월 인하대학교 응용물
리학과 졸업(공학석사)
1993년 8월 인하대학교 전자재
료공학과 졸업(공학박사)


1988-1995년 LG반도체 선임연구원
1995-현재 여수대학교 전기공학과 조교수
관심분야 : VLSI공정 및 반도체 물성



김 이 곤(Yi-Gon Kim)

1992년 일본동경공대 객원 연구원
1993년 전남대학교 대학원 전기
공학과 졸업(공학박사)
1995-현재 여수대학교 전기공학
과 조교수

관심분야 : 퍼지 및 신경망, 웨이브렛



최 남 섭(Nam-Sup Choi)

1987년 2월 고려대학교 전기공
학과 졸업
1989년 2월 KAIST 전기및전자
공학과 졸업(공학석사)
1994년 2월 KAIST 전기및전자
공학과 졸업(공학박사)

1994년 2월~1995년 3월 KAIST 정보전자연구소
연구원
1995년 3월~현재 국립여수대학교 전기 및 반도체
공학과 교수
1999년 3월~2000년 2월 미국 Wisconsin-Madison
주립대학 방문교수

*관심분야 : 전력전자회로 모델링 및 해석, 멀티레
벨 컨버터 설계 및 응용