

# 통계적 회귀 모형과 인공 신경망을 이용한 Plasma-MIG 하이브리드 용접의 인장강도 예측

정진수\* · 이희근\*\* · 박영환\*\*\*,†

\*CS 홀딩스

\*\*대우조선해양(주) 산업기술연구소 용접기술연구그룹

\*\*\*국립부경대학교 공과대학 기계공학과

## Prediction of Tensile Strength for Plasma-MIG Hybrid Welding Using Statistical Regression Model and Neural Network Algorithm

Jin Soo Jung\*, Hee Keun Lee\*\* and Young Whan Park\*\*\*,†

\*CS Holdings Co. Ltd, Pohang 37863, Korea

\*\*Welding Engineering R&D Group, Industrial Application R&D Institute,  
Daewoo Shipbuilding Marine Engineering, Geoje 53302, Korea

\*\*\*Department of Mechanical Engineering, Pukung National University, Busan 48513, Korea

†Corresponding author : parkyw@pknu.ac.kr

(Received February 17, 2016 ; Revised March 28, 2016 ; Accepted April 6, 2016)

### Abstract

Aluminum alloy is one of light weight material and it is used to make LNG tank and ship. However, in order to weld aluminum alloy high density heat source is needed. In this paper, I-butt welding of Al 5083 with 6mm thickness using Plasma-MIG welding was carried out. The experiment was performed to investigate the influence of plasma-MIG welding parameters such as plasma current, wire feeding rate, MIG-welding voltage and welding speed on the tensile strength of weld. In addition we suggested 3 strength estimation models which are second order polynomial regression model, multiple nonlinear regression model and neural network model. The estimation performance of 3 models was evaluated in terms of average error rate (AER) and their values were 0.125, 0.238, and 0.021 respectively. Neural network model which has training concept and reflects non-linearity was best estimation performance.

Key Words : Al 5083 alloy, Plasma-MIG hybrid welding, Tensile strength estimation, Statistical regression model, Neural network model.

### 1. 서 론

석유 에너지 자원과 더불어 LNG에 대한 수요가 증가하고 있으며 이에 따라 LNG선과 탱크의 수요가 증가하고 있다. 이를 제작하기 위해서는 강도와 용접성, 내식성이 우수한 Al 5083 합금으로 주로 사용되며, 알루미늄 합금의 선체의 제작에 있어서 용접은 매우 중요한 공정이 된다. 그러나 알루미늄 합금은 고체보다 액

체 상태에서 높은 수소 용해도를 가진다<sup>1)</sup>. 이는 알루미늄 용접 시 기공의 주된 원인이 된다<sup>2)</sup>. 이러한 알루미늄 용접의 단점을 극복하기 위하여 Plasma-MIG (Metal Inert Gas)와 같은 복합열원의 용접 공정이 수소의 영향을 최소화할 수 있는 방법으로 적용될 수 있다.

Ton 은<sup>3)</sup> 비동축 Plasma-MIG 용접에서 광학 분광법을 이용하여 아크의 온도분포를 측정하였고, 와이어에 의해 흐르는 전류와 플라즈마 전류와의 관계를 확인

하였다. Essers 등은<sup>4)</sup> Plasma-MIG 용접과 MIG 용접 중 모재의 열량을 측정하여 열전달 메카니즘과 용입 면적을 비교 분석하였다. Ono 등은<sup>5)</sup> 알루미늄을 용접하기 위하여 플라즈마 용접과 MIG 용접 토치를 동축으로 구성하여 스패터와 흠의 저감을 확인하였고, 와이어 예열을 통해 마그네슘 기화현상을 줄이고, 안정적인 아크가 형성됨을 확인하였다. Kim<sup>6)</sup> 과 Jung<sup>7)</sup> 등은 알루미늄 합금 4t와 6t용접의 공정 변수 영향력을 분석하고, 기존 MIG 용접과 비교하여 생산성 측면에서 유리하다고 설명하였다.

본 논문에서는, 와이어와 모재의 수소 및 수분 혼입을 방지하고, 기공 및 균열의 민감도를 낮추기 위해 Plams-MIG 하이브리드 용접을 이용하여 I형 맞대기 형상에 대한 소재 두께 6t 용접을 진행하였다. Plasma-MIG 하이브리드 용접에서 각 용접 인자들이 용접부 강도에 미치는 영향력과 용접부 인장강도 예측을 위하여 통계적 회귀모델과 인공신경 회로망을 이용하여 용접부 강도 예측 모델을 개발하였다. 사용된 회귀모델은 2차 다항 회귀모델(second order polynomial regression model), 그리고 다중 비선형 회귀모델(multiple non-linear regression model)이며 통계적 모델과 비교하기 위하여 인공지능 알고리즘을 이용한 신경회로망 모델(neural network model)을 이용하여 강도 예측 모델을 개발하였다. 개발된 모델의 예측 성능을 확인하기 위하여 실제 강도와 예측값에 대한 평균 오차율을 이용하여 각 모델의 정량적인 예측 성능을 확인하였다.

## 2. 실험 장치 및 용접 조건

### 2.1 실험 장치 및 용접 재료

실험에 사용된 용접장치는 플라즈마와 MIG 용접이 복합열원으로 작용하는 시스템으로 Fig. 1과 같이 플라즈마 발생 노즐과 GMAW의 와이어가 동축으로 공급되는 시스템이다. 용접은 Plasma-MIG 용접 토치는 로




Fig. 1 Plasma-MIG welding torch

Table 1 Chemical composition of Al alloys(wt.%)

|         | Si  | Cu  | Mn   | Mg   | Zn   | Cr   | Ti   | Al   |
|---------|-----|-----|------|------|------|------|------|------|
| Al 5083 | 0.4 | 0.1 | 0.7  | 4.5  | 0.25 | 0.15 | 0.15 | Bal. |
| ER5183  | 0.4 | 0.1 | 0.75 | 4.75 | 0.15 | 0.11 | 0.15 | Bal. |

봇에 고정되어 있고 용접하고자 하는 시편을 고정 장치 (fit-up device)로 지그의 베드(bed)에 고정되어 용접 진행 방향의 반대 방향으로 이송하여 용접이 수행된다. 용접의 자동적인 시스템 운영을 위해 3축 xyz 테이블 이송 시스템을 이용하였다.

실험에 사용된 모재는 Al 5083-H321 알루미늄 합금으로 그 조성은 Table 1과 같다. 시편은 250mm × 150mm × 6mm의 크기를 갖고 있다. 용접와이어는 5000계열 알루미늄 합금에 주로 사용되는 ER 5183을 사용하였다. 사용된 용접 와이어의 직경은 1.2mm이다. ER 5183의 조성은 Table 1과 같다. 용접은 맞대기 용접으로 수행하였으며 시편이 맞는 부분은 밀링으로 가공하여 그 면을 일정하게 하였다. 용접은 이송 베드(bed)에 의해 시편이 움직이는 방식으로 용접 길이는 130mm 였다.

### 2.2 용접 실험 계획 및 조건

일반적으로 Plasma-MIG 용접에서 주요 용접 공정 변수는 플라즈마 용접 인자인 플라즈마 전류와 전압 등이 있고, GMAW 용접의 인자인 아크 전류와 전압, CTWD (Contact tube to workpiece distance) 등이 존재한다. 뿐만 아니라 공정 변수로써, 용접 속도, 가스의 유량, 팁모재간 거리 등이 있다. 본 논문에서는 다양한 인자 중에서 용접부의 입열에 주요 인자로 사료되는 플라즈마 용접 전류(plasma welding current: PWC), MIG 용접 전압 (MIG Welding voltage: GWV), 와이어 송급속도 (wire feeding rate: WFR), 용접 속도 (welding speed: WS)를 선택하였다. 각 용접 변수에 대한 수준과 그 값은 예비 실험을 통하여 선정하였고 이것은 Table 2와 같다.

Table 2 Factors and levels of orthogonal experiment

| No. | Factor                         | Level 1 | Level 2 | Level 3 |
|-----|--------------------------------|---------|---------|---------|
| A   | Plasma welding current: PWC(A) | 120     | 140     | 160     |
| B   | MIG welding voltage: GWV(V)    | 25      | 26      | 27      |
| C   | Wire feed rate: WFR(m/min)     | 16      | 18      | 20      |
| D   | Welding speed: WS(mm/s)        | 14      | 15      | 16      |

본 용접을 전수로 수행한다면, 총 81회의 실험을 수행하여야 한다. 그러나 실험의 효율성 확보를 위하여 일부실험시법(fractional factorial design)중 하나인 직교 배열법(orthogonal design)을 이용하여 실험을 진행하였다. 직교 배열표(table of orthogonal arrays)에 의하여 3수준계를 사용하여 구성한 실험 조건은 총 27개의 조건을 이용하였다.

Plasma-MIG 용접의 고정인자로는 플라즈마 전극과 모재간 거리(torch standoff: SO)는 10mm로 하였으며, 용접에 필요한 가스는 모두 99.99% 순도를 갖는 아르곤 가스를 이용하였다. 각각의 가스 공급 유량으로 MIG 가스, 플라즈마 가스, 차폐 가스는 10L/min, 10L/min, 15L/min로 설정하여 공급하였다.

### 3. 용접부 인장강도

Al 5083 합금의 Plasma-MIG 용접에서 용접부의 기계적 강도를 평가하기 위하여 인장시험을 수행하였다. 인장 시험은 KS B ISO 4136<sup>8)</sup>의 규정에 따라 진행하였으며 인장 시편의 치수는 Fig. 2와 같다. 그림에서 보는 바와 같이 용접부의 인장 강도를 측정하기 위해서 용접부의 덧살 (reinforcement)를 제거하여 실험을 수행하였다. 모재의 인장강도는 351N/mm<sup>2</sup> 이고 Al 5083 모재의 최소 인장강도는 AWS(american welding society)에서 270N/mm<sup>2</sup>로 규정하고 있다<sup>9)</sup>. 용접부의 인장 강도 결과는 Table 3과 같다.

Table 3의 22번 실험의 경우 용입이 적어 인장시험을 수행하지 못한 결측치이다. 용접부의 비드 형상은 Fig. 3과 같다. 표에서 보는 바와 같이 인장시험 결과 대부분 플라즈마 전류가 낮은 120A, 와이어 송급속도가 높은 20 m/min에서 최소인장강도 보다 높은 결과가 나왔다. 이것은 Fig. 3에서 보는 바와 같이 완전 용입이 발생하는 경우이며 완전 용입과 비드 형상이 우수한 경우 용접 강도가 높게 나타났다. 그러나 용접 입열이 적은 용접 전류가 낮고, 용접 속도가 빠른 경우는 Fig. 3의 (a)와 같이 불완전 용입이 발생하였으며, 이에 따라 인장 강도가 낮았다. 반면 플라즈마의 전류가 높고, 용접 속도가 느린 경우에 있어서는 Fig. 3의 (c)





Fig. 2 Tensile test piece

Table 3 Tensile test results

| No. | PWC (A) | GWV (V) | WFR (m/min) | WS (mm/s) | TS (N/mm <sup>2</sup> ) |
|-----|---------|---------|-------------|-----------|-------------------------|
| 1   | 120     | 25      | 16          | 14        | 173.86                  |
| 2   | 140     | 25      | 18          | 14        | 195.23                  |
| 3   | 160     | 25      | 20          | 14        | 97.04                   |
| 4   | 140     | 26      | 16          | 14        | 135.94                  |
| 5   | 160     | 26      | 18          | 14        | 127.72                  |
| 6   | 120     | 26      | 20          | 14        | 292.43                  |
| 7   | 160     | 27      | 16          | 14        | 95.91                   |
| 8   | 120     | 27      | 18          | 14        | 288.3                   |
| 9   | 140     | 27      | 20          | 14        | 85.91                   |
| 10  | 140     | 25      | 16          | 15        | 149.31                  |
| 11  | 160     | 25      | 18          | 15        | 142.46                  |
| 12  | 120     | 25      | 20          | 15        | 293.37                  |
| 13  | 160     | 26      | 16          | 15        | 162.33                  |
| 14  | 120     | 26      | 18          | 15        | 181.15                  |
| 15  | 140     | 26      | 20          | 15        | 278.98                  |
| 16  | 120     | 27      | 16          | 15        | 210.25                  |
| 17  | 140     | 27      | 18          | 15        | 223.25                  |
| 18  | 160     | 27      | 20          | 15        | 116.65                  |
| 19  | 160     | 25      | 16          | 16        | 155.26                  |
| 20  | 120     | 25      | 18          | 16        | 181.86                  |
| 21  | 140     | 25      | 20          | 16        | 153.44                  |
| 22  | 120     | 26      | 16          | 16        | *                       |
| 23  | 140     | 26      | 18          | 16        | 142.36                  |
| 24  | 160     | 26      | 20          | 16        | 183.71                  |
| 25  | 140     | 27      | 16          | 16        | 108                     |
| 26  | 160     | 27      | 18          | 16        | 151.81                  |
| 27  | 120     | 27      | 20          | 16        | 285.18                  |



(a) Partial penetration (b) Full penetration (c) Burn through

Fig. 3 Weld bead shape

와 같이 용락현상이 발생하여 용접부의 강도를 저하시키는 원인으로 작용한다.

### 4. 공정변수를 이용한 인장강도 예측 모델

공정변수를 이용하여 용접성을 평가하기 위한 방법 중 하나로 인장강도를 예측할 수 있는 모델을 제시하고자 한다. 실험 조건내에서 용접 공정변수에 대하여 Al

5083 알루미늄 합금의 최소인장강도보다 높은 인장강도를 갖는 조건을 예측하여 시스템을 모델링 하게 되면, 실험 구간내에서 실험하지 못한 입력 조건에 대하여 출력을 근사적으로 구할 수 있다. 본 연구에서는 통계적인 접근 방식의 회귀모델(regression model)과, 학습에 의한 인공지능형 신경망모델(neural network model)을 제시하였다.

4.1 회귀 분석을 이용한 인장강도 예측 모델

회귀분석(regression analysis)이란 변수들 간의 관련성을 규명하기 위하여 어떤 수학적 모형을 가정하고, 이 모형을 측정된 변수들의 데이터로부터 추정하는 통계적 분석 방법을 말한다. 본 연구에서는 용접의 입열 인자를 입력 변수로, 반응변수로는 용접부의 용접성을 나타낼 수 있는 인장강도로 하여 모델링하였다.

인장 강도예측을 위해서 사용된 모델은 크게 2가지를 이용하였다. 3장에서 보는 바와 같이 용접부의 강도는 용접 형상과 관련되어 매우 비선형적인 모습을 갖게 된다. 그러므로 이를 반영하여 2차 다항 회귀모델(second order polynomial regression model: Model I)과 다중 비선형 회귀모델(multiple nonlinear regression model: Model II)을 이용하였다. 각 모델은 식 (1)과 (2)와 같다.

$$\hat{y} = \beta_0 + \sum_{i=1}^4 \beta_i x_i + \sum_{i=1}^4 \sum_{j=i}^4 \beta_{ij} x_i x_j \quad (1)$$

$$\hat{y} = \beta_0 + \sum_{i=1}^4 \beta_i \ln x_i \quad (2)$$

위의 식에서  $x_1, x_2, x_3, x_4$  는 용접 입력변수로서 순서대로 플라즈마 용접 전류, MIG 용접 전압, 와이어 송급속도 그리고 용접속도이다. 각 입력변수의 값은 0에서 1의 값으로 표준화(normalization)을 한 값을 사용하였다.  $\hat{y}$  는 종속변수로 각 모델에 의해 예측되어진 인장강도 값이다. 또한  $\beta_0$ 는 회귀 모델의 절편이고,  $\beta_i, \beta_{ij}$ 는 독립변수의 계수값을 나타낸다. 각각의 계수는 최소제곱법(method of least squares)으로 추정한다. 각 모델의 계수는 Table 3과 4와 같다.

회귀 모델을 이용하여 얻어진 용접부의 인장강도 예측 결과는 Fig. 4와 5와 같다. 그림에서 가로 축은 예측된 인장강도를 세로 축은 실제 실험에서 얻어진 인장강도 이다. 그러므로 그래프내의 직선에 가까울수록 예측 성능이 우수하며, 정성적으로 확인할 때 2차 다항회귀 모델이 좀 더 예측을 잘하고 있음을 확인할 수 있다.




Fig. 4 Estimation results of model I(second order polynomial regression model)




Fig. 5 Estimation results of model II (multiple nonlinear regression model)

Table 4 Coefficients for regression model I

|              |              |              |              |              |
|--------------|--------------|--------------|--------------|--------------|
| $\beta_0$    | $\beta_1$    | $\beta_2$    | $\beta_3$    | $\beta_4$    |
| 182          | -97.7        | 150          | 45.1         | 13.7         |
| $\beta_{11}$ | $\beta_{12}$ | $\beta_{13}$ | $\beta_{14}$ | $\beta_{22}$ |
| 62.4         | -153         | -76.7        | 131          | -45.4        |
| $\beta_{23}$ | $\beta_{24}$ | $\beta_{33}$ | $\beta_{34}$ | $\beta_{44}$ |
| -30.1        | 86.9         | -16.6        | 55           | -128         |

Table 5 Coefficients for regression model II

|           |           |           |           |           |
|-----------|-----------|-----------|-----------|-----------|
| $\beta_0$ | $\beta_1$ | $\beta_2$ | $\beta_3$ | $\beta_4$ |
| 201       | -145      | 61.6      | 6.7       | 17.5      |

### 4.2 신경회로망 예측 모델

용접부의 인장강도를 예측하기 위해서 인공지능형 알고리즘의 하나인 신경회로망 모델을 이용하였다. 용접 공정변수에 대한 인장강도의 예측이 비선형이 강하므로 이를 잘 반영할 수 있는 신경망 모델을 또 다른 예측모델로 선정하였다. 신경회로망 모델은 학습하는 능력을 가지고 있으므로 용접공정과 같이 수학적으로 모델링하기 어려운 비선형적 요소를 많이 포함한 분야에 대하여 광범위하게 적용되고 있다<sup>10,11)</sup>.

본 논문에서 사용되는 신경회로망 모델 (Model III)은 Fig. 6과 같다. 신경회로망 구조(architecture)를 얻기 위하여 선형적(heuristic)으로 1개의 입력층(input layer)과 2개의 은닉층(hidden layer) 그리고 출력층(output layer)으로 구성하여 몇 가지 구조의 조합에 대하여 오버피팅(overfitting)이 되지 않도록 은닉층의 노드의 개수를 다양하게 학습을 수행하였고, 최소의 노드를 이용하도록 학습성을 테스트 한 후 Fig. 6과 같은 모델을 선정하였다.

각 노드의 연결 강도를 학습시키기 위한 알고리즘으로 오류 역전파(error backpropagation) 알고리즘을 사용하였다. 학습율(learning rate)은 0.1 이고, 지역적 최소점(local minimum)문제와 빠른 수렴으로 학습 속도를 위해 모멘텀 방법을 이용하였으며, 모멘텀 계수(momentum coefficient)는 0.9로 설정하였다. 각 레이어의 전달함수(transfer function)는 입력층과 1차 은닉층 사이에는 탄젠트 시그모이드(tan-sigmoid) 전달함수를 1차와 2차 은닉층 간과 2차 은닉층과 출력층 간의 전달함수는 1차 선형(purelin) 전달함수를 사용하였다.

Fig. 7은 신경회로망 모델의 예측 결과이다. 그림에서 보는 바와 같이 회귀모델의 예측 보다는 직선에 가까운 것을 확인할 수 있다. 이것은 비선형성이 큰 용접에서는 학습의 효과와 비선형을 잘 표현해 줄 수 있는 인공신경회로망의 모델의 예측 성능이 우수함을 확인할 수 있다.




Fig. 6 Neural network model architecture




Fig. 7 Estimation results of model III(neural network model)

Table 6 Average error rate comparison for each model

| Model | I     | II    | III   |
|-------|-------|-------|-------|
| AER   | 0.125 | 0.238 | 0.021 |

### 4.3 예측모델의 성능 비교

본 논문에서는 Plasma-MIG 용접을 적용한 알루미늄 Al 5083 합금의 용접부 인장강도를 예측하는 모델을 제안하였다. 제안된 모델은 총 3개로서 2개의 회귀 모델과 1개의 신경회로망 모델이다. 이러한 모델의 예측 성능을 정량적으로 평가하기 위하여 평균 오차율(average error rate: AER)을 이용하여 각 예측 모델을 비교하였다. 평균오차율의 식은 식 (3)과 같다.

$$AER = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \tag{3}$$

여기서  $i$ 는 실험 번호이고,  $n$ 은 총 실험 횟수로 26이다.  $y$ 는 측정된 인장강도이며,  $\hat{y}$ 는 예측모델에 의해 예측된 값이다.

각 예측성능을 비교한 결과는 Table 6과 같다. 2개의 회귀 모델 중에서는 2차 다항회귀모델의 평균오차율이 0.125로 높았지만, 전체 3개의 모델 중에서는 신경회로망 모델이 0.021로 인장강도 예측 모델 중 가장 우수한 모델임을 알 수 있었다.

## 5. 결 론

본 연구는 알루미늄 Al 5083 6t 합금에 대한 Plasma-MIG 용접을 실험계획법에 따라 수행하였으며, 용접부

의 인장강도를 예측할 수 있는 모델을 개발하였다. 요약된 논문의 결론은 아래와 같다.

1) Al 5083 6t 합금의 Plasma-MIG 용접에서 용접 공정변수인 플라즈마 전류, MIG 용접 전압, 와이어 송급속도, 용접속도에 따른 용접 특성을 용접부 인장 시험을 통하여 파악하였다. 용접부는 입열에 따른 용입 특성에 따라 강도 변화를 확인할 수 있었다.

2) 용접부의 강도에 대한 예측 모델을 2차 다항 회귀모델, 그리고 다중 비선형 회귀모델, 그리고 인공지능 알고리즘을 이용한 신경회로망 모델을 이용하여 3개의 강도 예측 모델을 개발하였다.

3) 각 모델의 정량적 예측 성능을 평균 오차율을 이용하여 비교하였고, 전체 3개의 모델 중에서는 학습의 효과와 비선형을 잘 표현해 줄 수 있는 신경회로망 모델의 평균 오차율이 0.021로 가장 우수한 모델임을 확인하였다.

## 후 기

이 논문은 부경대학교 자율창의학술 연구비(2014년)에 의하여 연구되었음

## References

1. G. Mathers, The Welding of Aluminum and Its Alloys, Woodhead Publishing Ltd., 2002
2. C.H. Lee and R.W. Chang, Weldability of Al Alloys, Part I :Cracking and Porosity, *Journal of the KWS*, 10(3) (1992), 1-12 (in Korean)
3. H. Ton, Physical Properties of the Plasma-MIG Welding Arc, *Appl Phys.*, 8(4) (1975), 922 - 933
4. W.G. Essers and R. Walter, Heat transfer and penetration mechanisms with GMA and plasma-GMA welding, *Weld Journal*, 60(2) (1981), 37 - 42
5. K. Ono, Z. Liu, T. Era, T. Uezono, T. ueyama, M. Tanaka and K. Nakata, Development of a Plasma MIG Welding System for Aluminum, *Welding International*, 23(11) (2009), 805-809
6. C.H. Kim, Y.N. Ahn, J.K. Choi and S.H. Rhee, Process Evaluation of Plasma-GMA Welding for Al 5052 and 6061 Alloy, *Journal of KWJS*, 28(6) (2010), 58-62 (in Korean)
7. J.S. Jung, J.J. Lee, H.K. Lee and Y.W. Park, Weldability Evaluation in Plasma-GMA Hybrid Welding for Al-5083 Using Analysis of Variance, *Journal of KWJS*, 32(1) (2014), 28-33 (in Korean)
8. KS B ISO 4136:2008, Destructive tests on welds in metallic materials-Transverse tensile test, 2008
9. ANSI, AWS D1.2, Structural Welding Code-Aluminum (3th Edition), 1997
10. J.H. Cho, Prediction of Arc Welding Quality through Artificial Neural Network, *Journal of KWJS*, 31(3) (2013), 44-48 (in Korean)
11. J.H. Cho, Proper Arc Welding Condition Derivation of Auto-body Steel by Artificial Neural Network, *J. of Welding and Joining*, 32(2) (2014), 43-47 (in Korean)