
Modular 신경 회로망을 이용한 GMA 용접 프로세스 모델링

김경민*, 강종수*, 박중조**, 송명현***, 배영철*, 정양희*

* 여수대학교 전기공학과

** 경상대학교 제어계측공학과

*** 순천대학교 전기제어공학과

A Modular Neural Network for The GMA Welding Process Modelling

Kyoung-min Kim, Jong-su Kang, Joong-jo Park, Myeong-hyun Song, Young-chul Bae,

Yang-hee Jung

Yosu National Univ.

E-mail : kkm@info.yosu.ac.kr

Abstract

In this paper, we propose the steps adopted to construct the neural network model for GMAW welds. Conventional, automated process generally involves sophisticated sensing and control techniques applied to various processing parameters. Welding parameters are influenced by numerous factors, such as welding current, arc voltage, torch travel speed, electrode condition and shielding gas type and flow rate etc. In traditional work, the structural mathematical models have been used to represent this relationship. Contrary to the traditional model method, neural network models are based on non-parametric modeling techniques. For the welding process modeling, the non-linearity as well as the coupled input characteristics makes it apparent that the neural network is probably the most suitable candidate for this task.

Finally, a suitable proposal to improve the construction of the model has also been presented in the paper.

Keywords : neural network, welding process, GMA welding

1. 서론

일반적으로 용접품질상태는 작업자의 경험에 의한 감각과 육안 그리고 hammering으로 판단하고 있다.

이는 작업자에 따라 판정 기준이 달라지고, 용접 품질의 평가 자체가 표준화되지 못하므로 용접 프로세스의 가장 핵심적인 관리

기준중의 하나인 작업 연속성의 품질확보에 위협을 받고 있는 상태이다. 따라서 용접 품질을 객관적으로 판단할 방법을 강구해야 할 상태이다.

용접 프로세스는 arc, molten pool 그리고 surrounding heat - affected zone의 물리학의 복잡성 때문에 모델링하는 것이 거의 불가능하다. 아직도 안정도와 보편성 그리고

물리적 모델링의 부족으로 실시간 범용 제어기의 설계 또한 어려운 현실이다. 일반적으로 용접 프로세스의 입력과 출력의 관계는 비선형관계이며, 프로세스 변수 또한 중복되어 서로의 파라미터에 영향을 미치고 있다. 보편적으로 아크 용접 프로세스는 수많은 파라미터에 의해 제어되며, 따라서 용접품질의 합, 부 판정을 위한 표준 수치값과 용접 품질에 대한 규격화가 요구된다. 그리고, 이를 기초로 하여 용접부 상태진단을 위한 체계적인 진단 알고리즘의 개발이 요구되어진다.

용접 기술은 철강산업의 기초분야로 그 중요도가 대단히 높지만 이 분야의 기술개발과 연구가 계속 요구되는 분야이다. Welder의 용접 불량이나 고장 요인은 크게 Hardware와 Software적인 것으로 분류할 수 있으며 Hardware적인 것은 용접설비의 성능에 기인하므로 새로운 설비의 도입 및 용접 기술 개발 등으로 용접불량과 고장을 개선할 수 있다. Software 분야는 정밀 제어기술과 시스템의 신뢰도를 높이기 위한 제반 기술을 말한다. 본 논문에서는 Software 분야로서 용접 파라미터와 조업 data을 분석, 채취하여 용접 파라미터를 세분화하고 적정 용접 진단 Table을 구하여 용접 품질상태를 진단하는 조업의 신뢰도를 확보할 수 있는 시스템을 개발하는 것이다.

일반적으로 용접 프로세스에서 용접에 미치는 공정 변수는 primary parameter인 용접 전류, 용접 속도, 전극 가압력, 소재의 종류, 부재의 두께, Overlap 량, Overlap 형태, Plainish 가압력(or 유무)이 있고, secondary parameter로는 전원의 종류(AC, DC, 주파수, Waveform), 구동계의 방식 및 정밀도, Clamping 상태, 전극 휠의 표면상태, 소재의 표면 상태등으로 분류할 수 있다.

용접 프로세스에 대한 제어와 모델링에 관한 연구는 Andersen, Cook, Nunes, Tsai 등에 의해 행하여졌으며, 제한된 실험 데이터를 가진 모델에 어떻게 신경 회로망을 구성할 것인가에 대한 연구가 진행되고 있다.[1]~[4]

II. 신경망 프로세스 모델링

신경회로망을 이용한 용접 프로세스 모델링에 대한 연구는 많이 되어져 왔다.[1][2] 신경 회로망의 모델의 장점은 용접 프로세스에 직접적인 물리적 특성에 기인하지 않기 때문에 실제 조업중

의 데이터들의 입출력 관계만을 가지고 학습하게 된다. 본 논문에서 사용되어지는 입력 데이터는 electrode diam., electrode extension, welding current, voltage 그리고 travel speed의 6개 성분으로 구성되며, 출력 데이터는 fusion area(A), bead width(W), bead height(H), penetration(P), L. reinforcement boundary(C_1) 그리고 L.

fusion boundary(C_2)이다.




그림 1 Definition of weld parameters

첫 번째 실험에서는 그림 2와 같은 일반적인 다층 구조의 역전파 신경 회로망의 기본 구조를 사용하였으며, 학습 계수의 조절은 error feedback learning 방법을 이용하였다.




그림 2 역전파 신경 회로망의 기본 구조

본 연구에서는 은닉층의 개수를 단층과 2층으로 구성하여 은닉층의 개수와 학습 수렴과의 관계를 비교하였으며, 뿐만 아니라 각각의 경우에 대해 은닉층 노드 수를 변화시켜가며 노드 수에 따른 최종 학습오차와 학습 결과에 대한 각각의 모델링에 대한 테스트 결과

를 비교 실험하였다.

그리고 그림 3과 같이 본 연구에서는 입력 데이터와 출력 데이터의 coupling을 학습시 최소화하기 위해 각 모듈의 출력 노드에 대해 별도의 학습을 하도록 하였으며, 이를 통해 학습 향상과 성능개선이 되도록 실험하였다.

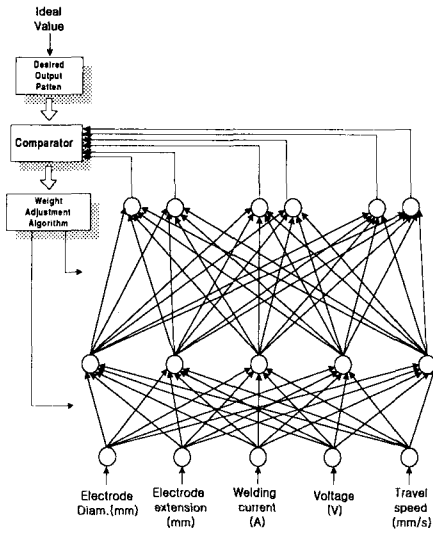


그림 3 신경망 프로세스 모델링

III. 모의실험 및 검토

본 실험에서는 일상 조업 데이터를 분석하여 용접 조건표를 얻고, 이를 신경 회로망을 이용한 모델링으로 새로운 용접 조건을 구하여 실제 data set과 비교하여 이의 타당성을 입증하였다.

본 연구에서 사용되어진 data set은 55개이며, 학습 데이터는 40개, 학습에 사용되지 않고 테스트용으로 사용된 데이터 수는 15개이다. 일반적으로 학습 데이터는 모델링한 프로세스가 보간 즉 일반화할 수 있는 능력을 가져야 하며, 또한 네트워크의 중복 학습을 피하도록 구성해야 한다. 또한 본 논문에서는 논문[1]에서 사용한 테스트 데이터를 사용하였다.

본 실험에서 사용한 학습율과 모멘트는 각각 0.5, 0.3의 값으로 하였으며, 학습회수는 동일하게 50,000회로 하였다. 다음의 그림들은 은닉층의 수를 변화시켰을 때의 각 테스트 데이터에 대한 error 비율을 도시하였다. 표 1은 은닉층의 수가 하나일 때의 일반적인 역전파 학습 알고리즘에 의한 실험 결과들을 도시하였으며, 각 노드 수의 변화에 따른 학습 오차와 출력 오차를 기술하였다. 그림 4는 각 6개의 출력에 대하여 노드수에 따른 오차를

그림으로 도시하였다.

표 1. 노드수에 따른 학습 오차와 출력 오차비율

Hidden Layer	6	8	16	20
Fusion Area	41.93	42.55	29.77	31.58
Bead Width	77.49	80.04	48.07	67.96
Bead Height	37.64	46.26	59.34	53.80
Penetration	29.72	40.69	32.21	31.30
Length of Reinforcement	35.46	36.27	51.35	42.32
Length of Fusion	68.64	56.32	58.30	61.86
Total Error	3.40E-02	2.28E-02	3.72E-03	1.79E-03




그림 4. 노드수에 따른 오차 비(BP 학습시)

표 2와 그림 5는 동일한 조건하에서 학습시의 프로세스 모델링을 modular BP로 하였을 경우에 대한 결과들을 도시하였다. 실험을 검토한 결과 노드수의 증가와 그에 따른 오차는 비례관계에 있지 않음을 알 수 있으며, 뿐만 아니라 각각의 error값을 동시에 만족시키는 노드수는 명확하게 규정되지 않음을 알 수 있었다.

표 2. 노드수에 따른 학습 오차와 출력 오차비율(modular NN)

Hidden Layer	6	8	16	20
Fusion Area	33.89	26.13	33.20	23.06
Bead Width	36.31	76.94	61.35	46.55
Total Error	9.78E-04	3.04E-04	6.40E-05	7.15E-05
Bead Height	40.16	29.59	69.75	45.75
Penetration	24.26	31.91	21.82	24.10
Total Error	1.12E-03	7.39E-04	2.11E-05	2.52E-05
Length of Reinforcement	45.48	37.52	39.48	54.13
Length of Fusion	46.35	52.03	44.11	54.55
Total Error	2.55E-03	2.12E-03	7.56E-05	1.07E-04

Hidden Layer	4 2	8 4	12 4	12 6
Fusion Area	46.11	32.76	48.35	55.02
Bead Width	145.69	36.93	59.03	156.38
Bead Height	24.42	43.84	133.35	67.30
Penetration	37.68	29.70	55.59	54.20
Length of Reinforcement	41.08	37.42	34.86	78.09
Length of Fusion	40.39	32.04	56.45	50.27
Total Error	8.57E-02	2.31E-02	1.53E-02	6.00E-03

표 4. 노드수에 따른 학습 오차와 출력 오차비율(modular NN)




그림 5. 노드수에 따른 오차 비(modular NN 학습시)

표 3, 4는 은닉층의 수를 2층으로 하면서 일반적인 BP와 modular 기법을 사용하였을 경우에 대한 학습 오차와 출력 오차를 도시하였다. 이 또한 어떤 규칙성은 밝힐 수 없지만 단층과 일반BP에 비해 상대적으로 적은 error값을 갖는 모델을 구성할 수 있음을 실험을 통해 알 수 있다. 특히 노드 수가 4, 2일 경우에는 error 값 다른 노드의 에러값에 비해 상대적으로 양호한 값을 가짐을 실험을 통해 입증하였다. 위의 실험 결과를 검토한 결과 출력값들 사이에는 서로 영향을 미치는 것으로 보인다. 그림 7은 modular network를 구성하여 학습한 결과값을 그림으로 나타낸 것으로, 각 node수에 따른 error값의 변화에 대해서 실험을 통해 그 결과를 도시하였다.

표 3, 4는 은닉층의 개수를 이층으로 한 경우이며, 역시 노드 수에 따른 학습 오차와 출력값의 오차율을 도시하였다. 표 4는 modular network를 구성하여 학습한 결과 값을 나타낸다.

표 3. 노드수에 따른 학습 오차와 출력 오차비율

Hidden Layer	4 2	8 4	12 4	12 6
Fusion Area	23.66	29.74	34.42	23.31
Bead Width	40.12	38.77	45.08	37.35
Total Error	1.82E-03	1.36E-04	5.47E-05	3.19E-05
Bead Height	28.66	41.52	55.00	44.92
Penetration	28.73	45.60	37.32	41.24
Total Error	5.11E-03	6.40E-05	6.18E-06	4.47E-06
Length of Reinforcement	29.53	32.91	37.22	44.60
Length of Fusion	29.53	57.23	53.41	55.77
Total Error	4.99E-03	1.95E-04	1.86E-05	1.07E-05

각각의 테스트 결과에 대한 error값의 비율과 각 node수에 따른 error 값의 변화는 그림 6, 7에 도시하였다. 신경망 모델링 프로세스를 modular network로 구성하고, 은닉층의 개수를 이층으로 했을 경우에는 기존의 단일 모델링에 비해 상대적으로 양호함을 실험 결과를 통해 확인할 수 있다. 특히 표 4에 보듯이 은닉층의 노드수를 4, 2로 구성하였을 때의 오차가 가장 적으며 양호하다는 것을 알 수 있다.

종합하면 그림 4, 6의 일반적인 역전파 학습방법에 비해 그림 5, 7과 같이 modular network를 구성했을 경우가 각 출력값에 대한 오차가 매우 적으며, 양호한 결과를 만들어 냄을 실험을 통해 입증하였다.




그림 6. 노드수에 따른 오차 비(일반 역전파 학습시)




그림 7. 노드수에 따른 오차 비(modular network 구성시)

IV. 결론

본 연구에서는 역전파 신경 회로망을 이용해서 GMA 용접 프로세스 모델링을 시도하였다. 프로세스내의 데이터들의 복잡성과 커플링의 비선형성으로 인한 모델링의 난점을 신경 회로망을 통해 해결하였다. 또한 출력 신호의 영향을 서로 줄이기 위해 각각 출력 신호에 대해 독립적인 modular 신경 회로망을 구성하였으며, 이를 조합하여 원하고자 하는 값을 제어하도록 하였으며, 그리고 기존의 학습 방법과 비교해 그 타당성을 입증하였다. 그러나 높은 정밀도를 위해서는 용접 프로세스에 대한 이해와 data set에 대한 정밀한 해석이 요구되어지며, 그 정확도에 의해 신경회로망 모델링 또한 높아지리라 여겨진다.

World Cong., Sanfrancisco. pp.709-719, 1996.

[6] Patton, R. J. , P. M. Frank, R. N. Clark (eds). *Fault Diagnosis in Dynamical Systems. - Theory and Applications*, Prentice Hall (control engineering series), 1989

[7] P. Balle, D. Juricic, A. Rakar, S. Ernst, "Identification of Nonlinear Processes and Model Based Fault Isolation Using Local Linear Models", AACC, 1997.

[8] 김경민 외 "Diagnosis for the Welding Condition of the CAL Process using Neuro-Fuzzy System", pp. 885-894, Vol. 4, No. 4, 2000.

[9] 김경민 외 "A Modular Neural Network for The Arc Welding Process Modelling ", pp. 937-942, Vol. 4, No. 5, 2000.

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

참고문헌

- [1] Di Li, T. Srikanthan, R. S. Chandel, "Neural network based modeling of GMA welding process using small data sets", 5th ICARCV,, Singapore, 9-11 Dec., pp.474-479. 1998
- [2] Cook, G. E., Andersen, K. and Barnet, "Feedback and adaptive control in automated arc welding systems, Metal Construction, Vol. 13, No. 9, Sep., 1981
- [3] Cook, G. E., Andersen, K. and Barnet, "Welding modeling and control using artificial neural networks" IEEE Trans. on Industry Application, Vol. 31, No. 6, Nov.-Dec, pp. 1484-1491, 1995
- [4] K. Andersen, G. E. Cook, Barnett, "Gas Tungsten Arc Welding Process Control Using Artificial Neural Networks"
- [5] Iserman, R., P. Balle, "Trends in the Application of Model-based Fault Detection and Diagnosis of Technical Process", 13th IFAC