
신경회로망을 이용한 용접현상 해석 및 용접 품질판단에 관한 연구

이준희* · 최성욱** · 신동석*** · 강성인*** · 김관형***

A Study on Weld Pattern Analysis and Weld Quality Recognition using Neural Network

Jun-hee Lee* · Sung-wook Choi** · Dong-suk Shin*** · Sung-in Kang*** · Gwan-hyung Kim***

요 약

최근 용접공정은 무인화 및 자동화 시스템의 구축이 급속하게 발전하고 있으며 정확한 용접현상의 해석을 위하여 여러 가지 신호처리 알고리즘을 적용하고 있다. 본 논문에서는 아크용접의 모니터링시스템 구성에 있어서 용접 품질을 실시간으로 판단할 수 있는 효율적인 신경회로망을 제시하고, 학습 데이터의 선정을 위한 전처리 과정을 제시하며, 학습된 신경회로망을 이용하여 실제 용접이 이루어지는 파형에 대한 평가를 보다 정밀하고 정확하게 평가할 수 있는 방법을 제시한다.

ABSTRACT

Recently, in Weld Processing field, unmanned and automatic system construction has experienced the rapid growth, and diverse signal processing has been employed in order to translate the exact weld pattern.

In this paper, We will suggest the effective neural network which can decide the weld quality in arc weld and monitoring system in real time. In addition, We will present the pre-processing for selecting the study data, and the method to evaluate the wave of weld more precisely and accurately through known Neural Network.

키워드

아크용접, 신경회로망, 용접품질, 아크용접 모니터링시스템

I. 서 론

최근 용접공정은 무인화 및 자동화 시스템의 구축이 급속하게 발전하고 있으며 정확한 용접현상의 해석을 요구한다. 예를 들어, 로봇시스템을 구축하여 용접할 경우에는 현장에서의 작업자가 지속적으로 용접품질을 감시할 수 없기 때문에 용접 품질 모니터링 및 용접 품질

판단 시스템의 중요성이 점차 강조되고 있다.

이러한 품질모니터링을 위해, 아크용접에 있어서 대표적인 모니터링 인자인 용접전류, 용접전압을 활용하고 있으며 현재는 이 인자들을 수치해석적인 방법으로 용접의 강도나 품질을 판단하고 있다. 하지만 이러한 방법으로는 다양한 용접분야에 적용하기 위한 수식적인 분석 및 공식화가 어려우며 고정된 수식으로 모니터링

* 동명대학교 정보통신공학과

** 부산인적자원개발원 연구위원

*** 동명대학교 컴퓨터공학과

을 하기 때문에 용접 환경의 변화가 발생하면 불량 판단의 기준이 모호해지고, 기준 설정이 애매한 경우에는 판단하기 곤란한 경우가 발생할 수 있다. 그러나 이러한 분야에 신경회로망을 적용하면 수식적으로 공식화하기 힘든 비선형적인 용접 현상을 보다 쉽고 편리하게 분석해 낼 수 있으며, 용접 현상과 같은 애매하고 불확실한 분야에 더욱 우수하고 유연성 있는 성능을 제공할 수 있다[1].

II. 본 론

일반적으로 아크용접에서 우수한 용접 품질을 얻기 위한 중요한 과제는 아크의 안정화에 있다. 아크의 안정화란 용접 시 발생하는 와이어와 용융지 사이에 닿게 되는 단락 현상이 규칙적으로 나타나게 되는 것을 의미하며, 이러한 규칙적인 현상은 용접 품질 또한 우수하다고 볼 수 있는 확률이 높다는 것을 의미한다.

우선, 용접현상의 관찰을 위해서 선결되어야 하는 부분이 용접시스템의 모니터링이다. 대표적인 모니터링 인자로는 용접속도, 와이어 송급속도, 용접전류, 용접전압 등을 대표적인 인자로 두고 있다. 그러나 본 논문에서는 용접전류와 용접전압을 중심으로 실험하였다.

또한, 용접 시 발생하는 용접전류, 용접전압 데이터를 이용하여 용접패턴을 분류하기 위해 사용된 학습 알고리즘은 오류 역전파 알고리즘(Error Backpropagation Algorithm)으로, 신경회로망의 출력벡터와 원하는 출력벡터 사이의 오차를 줄여나가는 학습알고리즘이다. 즉, 신경회로망 내부의 연결강도를 반복적으로 조정하는 알고리즘이며 다음의 식(1)~(5)와 같이 계산되고 갱신되어진다[2][3].

Calculate cycle error

$$E(t+1) = E(t) + \frac{1}{2}(d_k - o_k)^2 \quad (1)$$

for $k = 1, 2, \dots, K$

Adjust weights of output layer

$$w_{kj}(t+1) = w_{kj}(t) + \eta \delta_{ok} y_j \quad (2)$$

for $k = 1, 2, \dots, K$ and $j = 1, 2, \dots, J$

Adjust weights of hidden layer

$$v_{ji}(t+1) = v_{ji}(t) + \eta \delta_{yj} z_i \quad (3)$$

for $j = 1, 2, \dots, J$ and $i = 1, 2, \dots, I$

Calculate error δ_o, δ_y

$$\delta_{ok} = (d_k - o_k)(1 - o_k)o_k \quad (4)$$

$$\delta_{yj} = y_j(1 - y_j) \sum_{k=1}^K \delta_{ok} w_{kj} \quad (5)$$

for $k = 1, 2, \dots, K$ and $j = 1, 2, \dots, J$

본 논문에서 적용한 신경회로망의 구조는 패턴인식에 있어서 선형분리 성능이 우수한 하이오더(higher-order) 구조로 설계하였고, 학습방법은 오류 역전파 알고리즘을 사용하였다[4][5][6][7].

III. 패턴추출 및 분류

아크 용접 모니터링 시스템의 구성은 그림 1과 같다.



그림 1. 아크용접 모니터링 시스템 구성도
Fig. 1 Architecture of Arc welding monitoring system

위와 같은 시스템에서 추출된 샘플링 주파수는 5KHz로 샘플링 하였으며, 정상용접 파형 5개와 불량용접 파형 5개의 샘플 데이터를 얻었다. 이때 불량용접 파형은 임의로 불량용접 발생 상황을 재연하여 데이터를 추출하였으며, 그림 2와 그림 3에 실험 데이터를 제시하였다. 각 그래프 상단의 파형은 전류, 하단의 파형은 전압을 나타내었으며, 4~5초 동안의 실험 결과 파형이다.




그림 2. 정상용접 파형
Fig. 2 The wave of good welding

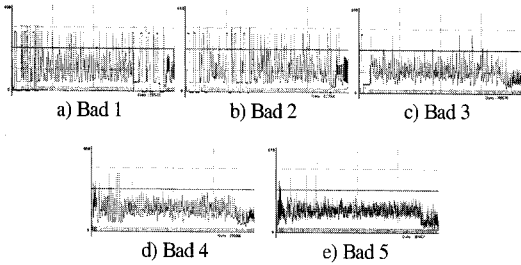


그림 3. 불량용접 파형
Fig. 3 The wave of bad welding

IV. 실험 및 구현

본 실험에서는 정상 및 불량용접 각각 5 종류의 학습 패턴을 추출하였으며, 신경회로망 학습을 위해 데이터 전처리 과정을 거쳤다. 이때 용접 기동과 종료 시 발생하는 잡음구간을 제외한 용접 데이터에서 214=16384개씩 추출하고, 그림 4와 같이 전처리 과정 및 정규화 과정을 거쳐 전압에 대한 63개의 데이터와 전류에 대한 63개의 데이터로 각각 전처리하였다. 이러한 전처리 과정과 정규화 과정을 그림 4에 제시하였다.

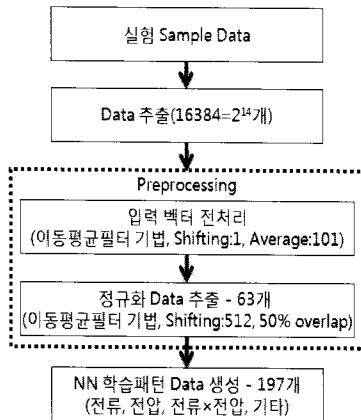



그림 4. 데이터 전처리 및 정규화 과정 순서도
Fig. 4 The flow chart of data preprocessing and normalization

이러한 용접 데이터의 추출과 전처리 과정을 그림 5와 같이 MS Visual C++로 구현하여 각 과정을 단계별로 수행하였다.



1. 필터 전 용접 그래프 2. 필터 후 용접 그래프
3. 그래프 정보 4. 전류·전압(IV)그래프

그림 5. 용접 데이터 전처리 및 정규화 프로그램
Fig. 5 The preprocessing and normalization program of Welding Data

본 논문에서의 실험데이터는 하이오더 신경회로망을 사용하기 위해서 데이터 추출 단계의 일정 구간에 대한 전류, 전압 각각의 최대값, 최소값, 평균값 세가지를 추출하였다. 또한 신경회로망의 선형분리 성능을 향상시키기 위해 63개의 전류×전압 데이터, 그리고 전류×전압의 최대값, 최소값을 재추출하여 입력의 차원을 늘린 후 이를 신경회로망의 입력으로 사용하였다.

실험에 사용된 신경회로망의 입력 뉴런 수는 용접 전압 63개, 용접전류 63개, 전류×전압 63개, 전압최대값 1개, 전압최소값 1개, 전압평균값 1개, 전류최대값 1개, 전류최소값 1개, 전류평균값 1개, 전류×전압 최대값 1개, 전류×전압 최소값 1개로 선정하였으며, 종합적으로 1개의 입력 패턴에 대한 197개의 신경망 입력데이터로 확장하여 학습하였다. 그리고, 학습에 사용된 벡터의 총 패턴 수는 정상용접 5개와 불량 용접 5개로 선별하여 학습을 진행하였다. 그러므로 총 데이터 용량은 10개의 입력 패턴에 대한 1970개의 입력벡터와 각각의 출력에 대응하는 10개의 출력 패턴 데이터로 학습을 하였다.

그림 6은 추출된 패턴 별 197개의 데이터 벡터를 신경회로망의 입력 뉴런에 입력하고 주어진 입력에 대한 정상과 불량 의 각 패턴별 분류를 위해 목표값을 HEX 코드(0001~1010)에 대응시켜 학습 하였다.





그림 6. 신경회로망과 목표값
Fig. 6 Neural Network and desired value

본 논문에 적용한 신경회로망의 구조는 입력층 뉴런 197개, 은닉층 뉴런 10개, 출력층 뉴런 4개, 학습률 0.9, 허용오차는 0.001로 선정하여 학습하였으며 학습 진행 과정은 그림 7과 같다.



1. 패턴별 에러 그래프
2. 전체 에러 하강 그래프
3. 뉴런 네트워크 정보

그림 7. 오류 역전파 과정
Fig. 7 The processing of Error Backpropagation Algorithm

학습 완료 후 결정된 연결 가중치를 토대로 그림 8과 같은 순서로 용접패턴을 인식하였다.





그림 8. 용접패턴 인식과정 순서도
Fig. 8 The flow chart of welding pattern decision processing

테스트 데이터를 신경회로망에 입력하기 전에 데이터 전처리 및 정규화 순서도에 맞추어 데이터 처리과정을 차례로 거친 후, 추출된 데이터를 학습된 신경회로망에 입력한다. 이때 가공되는 데이터는 214=16384개씩 차례로 실시되며 사용자가 선택하는 중첩(overlap) 이동범위만큼 데이터를 디스플레이 할 수 있도록 하였다. 그 결과 입력된 테스트 데이터가 기존의 목표값으로 대응시켰던 HEX 코드로 분리되어 출력층으로 출력되었고, 출력값을 유클리드 거리로 재판별하여 효율적인 패턴 분리뿐만 아니라 미학습된 패턴을 구별 할 수 있게 하였다. 이러한 기능들을 그림 9와 같이 구현하여 나타내었다.



1. 전류·전압(IV)그래프
2. 그래프 정보
3. Output Layer(HEX Code)
4. Test Data 용접 파형
5. 벡터 거리 및 판별 결과

그림 9. 용접 품질판별 프로그램
Fig. 9 The decision program of welding quality

신경회로망의 성능실험을 위한 테스트 데이터인 미지의 용접패턴 6개를 입력하여 출력된 신경회로망의 인식 결과는 표 1과 같이 판별되었다. 이때 사용된 유사도 판별은 신경회로망의 출력벡터에 대한 10개의 목표값과 유클리드 거리를 계산하여 학습패턴과의 유사도가 85% 이하이면 미지의 학습패턴으로 판별하고, 85% 이상일 경우에는 유사도가 높은 벡터의 HEX 코드로 분류하였다.

표 1에서 우측의 수치는 각 테스트 데이터의 데이터 개수이며 50%씩 중첩 이동하며 판단한 결과 4~6개의 구간으로 나뉘어졌다. 그리고 구간별로 나누어진 각 테스트 데이터는 학습된 패턴 중 가장 높은 유사성을 가진 패턴으로 판별이 되었음을 볼 수 있다.

표 1. 테스트 데이터 인식 결과
Table. 1 The recognition result of test data

Data	구간 인식 결과						최종판별	Data개수
1	G5	G5	G5	G5	G5	G5	G	56009
2	G5	G5	G5	G4	G5	G5	G	56249
3	B5	G5	U	U	G5	G5	B	56099
4	G5	U	G1	U	U	G5	U	57246
5	B3	B3	B4	B3	G5	G5	B	46107
6	G4	G1	B3	G3	G4	B5	B	57794

(G1~G5 : Good Pattern, B1~B5 : Bad Pattern, U : Unknown)

데이터 1, 2의 경우에는 모든 구간이 정상패턴으로 분류가 되었고, 데이터 5의 경우에는 모든 구간에서 불량패턴으로 분류가 되었다. 반면에 데이터 6의 경우에는 정상패턴과 불량패턴이 섞여있음을 볼 수 있는데, 그림 10과 같이 정상적인 용접의 진행 중 불량이 발생한 것으로 볼 수 있다.




그림 10. 데이터 6의 실제 용접 결과
Fig. 10 The result of welding data 6

데이터 3, 4에서는 테스트 데이터 중 학습한 패턴 이외의 새로운 패턴이 존재하기 때문에 이 구간을 미지의 학습패턴으로 분류해 내는 결과를 보여주고 있으며 이러한 미지의 학습패턴의 분류는 앞에서 언급한 학습패턴과 테스트 데이터의 유사도에 따라 판별된 것이다. 이와같이 유사도에 따른 용접품질 인식률은 그림 11과 같이 나타낼 수 있으며 유사도가 90%이상일 경우 더욱 정밀하게 패턴의 분류가 가능하지만 미지의 패턴이 늘어나 인식률이 떨어지는 것을 알 수 있다.




그림 11. 유사도에 따른 용접품질 인식률 그래프
Fig. 11 The similarity graph of welding quality decision rate

V. 결 론

본 연구에서는 학습 데이터의 선정을 위한 전처리 과정을 제시하였고, 신경회로망을 이용하여 아크용접의 용접 품질을 실시간으로 판단할 수 있는 프로그램을 구현하였다.

학습패턴을 HEX 코드의 목표값으로 학습한 후 새로운 테스트 데이터를 신경회로망을 이용하여 인식한 결과 정상용접과 불량용접, 그리고 미지의 용접패턴으로 품질별 패턴분리가 가능했다. 이러한 신경회로망의 적용은 기존의 수치해석적인 방법에서의 복잡한 기준설정을 보다 간편하고 명확하게 하였고, 용접환경의 변화에도 더 유연한 패턴분리가 가능함을 확인할 수 있었다.

향후 연구 방향은 실시간 모니터링 중 미지의 용접패턴의 발생 시 즉시 새로운 패턴의 추가로 재학습하여 더욱 정밀하고 정확한 용접 품질판단이 되도록 하고, 아크용접뿐만 아니라 타 용접에도 적용할 수 있도록 연구하고자 한다.

참고문헌

- [1] 모니텍 코리아, "Welding Monitoring System", 모니텍 코리아, 2007
- [2] Jinhan M&B, "신경망 이론과 응용(I)", 김대수, 2005
- [3] Jacek M. Zurada, Introduction to Artificial Neural System, West Publishing Company, 1992
- [4] 한학용, 하성욱, 허장인, Multimedia Sound Programming, 영진닷컴, p170~176, 2003
- [5] 김관형, 강성인, 신경회로망을 이용한 용접 Root Gap 검출과 모니터링에 관한 연구, 한국해양정보통신학회논문지, 10권 7호, 2006. 2
- [6] 김관형, 강성인, 이태오, 신경회로망을 이용한 지능형 가공 시스템 제어기 구현, 한국해양정보통신학회논문지, 8권 6호, 2004. 7
- [7] 윤성운, 김창현, 김재열, 용접결합의 패턴인식을 위한 분류기 알고리즘의 성능 비교, 한국공작기계학회논문집, Vol15 No3, 2006. 6

저자소개



이준희(Jun-hee Lee)

2009년 동명대학교 정보통신공
학과 졸업예정(공학사)

※관심분야: 인공지능, 마이크로프로세서



최성욱(Sung-wook Choi)

2007년 한국해양대학교 전자통
신공학과 공학박사
2004년 10월 ~ 2006년 02월
(주) 넷솔루트 부설연구소
연구소장

2007년 부산인적자원개발원 연구위원

※관심분야: USN, SOGi, UPnP



신동석(Dong-suk Shin)

1985년 부산수산대학교 전자공학과
(공학사)
1987년 부산수산대학교 전자공학과
(공학석사)

1996년 부경대학교 전자공학과 (공학박사)

1992년 2월 ~ 2006년 2월 동명대학 컴퓨터정보처리
과 부교수

2006년 3월 ~ 현재 동명대학교 컴퓨터공학과 부교수

※관심분야: 유비쿼터스, 임베디드 시스템, RFID



강성인(Sung-in Kang)

2004년 한국해양대학교 전자통
신공학과 공학박사

2000년~현재 동명대학교
컴퓨터공학과 전임강사

※관심분야: 인공지능, 신호처리, 임베디드 시스템



김관형(Gwan-hyung Kim)

2001년 한국해양대학교
전자통신공학과 공학박사

2000년~현재 동명대학교
컴퓨터공학과 전임강사

※관심분야: 최적제어, 인공지능, ASIC 설계, USN