

레이저 카메라를 이용한 용접선의 추적

A Seam Tracking Algorithm Based on Laser Vision

조 현 중, 류 현, 오 세 영

포항공과대학교 전자전기공학과 (Tel: 279-2904; Fax: 279-2903; E-mail: hjoong@surf3.postech.ac.kr)

Abstracts A Seam tracking control system with a tool position control and a camera orientation control, has been developed here. For the camera orientation control, SOFNN was used to learn the expert control signal. The SOFNN algorithm can adjust the fuzzy set parameters and determine the fuzzy logic structure.

Keywords FNN, SOFNN

1. 서론

용접 환경의 열악함을 극복하기 위한 자동화의 시도는 많은 연구가 되어 있고 실제 용접에 많이 사용되고 있다. 특히 아크용접 분야는 용접봉의 자세 및 위치 제어의 어려움, 용접선에 높은 정밀도 필요등 적용 조건이 비교적 까다롭고 용접선 검출에 고도의 기술이 요구되어 자동화의 보급 및 실용화가 늦어지고 있다. 용접선 검출 센서는 크게 접촉식과 비접촉식으로 구분한다. 접촉식 센서는 구조가 간단하지만 용접선의 모양, 개선의 크기에 따라 접촉부의 모양을 달리해야 하고, 측정 위치와 용접 토치 간의 거리를 보상하는 방법이 필요하다. 또한, 작업물의 표면 여건, 낫은 정밀도로 인해 제한적인 적용 범위를 가진다. 반면 비접촉식은 접촉식보다는 상대적으로 복잡한 구조를 가진다. 비접촉식 센서로는 아크 센서와 비전 센서를 들 수 있는데, 아크 센서는 용접 시 사용하는 전류의 양을 측정함으로써 용접봉과 모재의 거리를 측정하기 때문에 용접 과정과 센싱 과정이 결합되어 불필요하게 용접봉을 weaving 시켜야 하고 곡률이 심한 곳이나 맞대기 이음의 경우 적용이 곤란한 제약을 받는다.

비전 센서로 레이저 카메라를 사용하면 위의 제약이 없어질 뿐 아니라 아크광의 잡음을 필터링 할 수 있고 weaving 이 없으므로 속도의 제약도 사라지게 된다. 본 논문에서는 레이저 generator 와 마이크로 카메라를 이용하여 용접선을 추적하는 시스템을 제안하고 카메라 방향 제어에 사용되는 새로운 SOFNN(Self-Organizing Fuzzy Neural Network) Algorithm 을 제안한다.

2. 전체 시스템의 구조와 특징

용접선 추적을 위한 시스템은 비전 시스템과 로봇 시스템, 그리고 이 두 시스템의 통신을 위한 직렬 통신 시스템으로 구성된다. 용접선 추적 시스템은 카메라가 툴의 앞쪽에 위치해서 앞의 용접선의 위치를 먼저 측정하고 측정된 정보에 따라 용접 토치가 따라 움직이는 look-ahead 구조로 되어 있다. 따라서 측정된 비전 정보로 로봇의 경로를 생성해야 하고 동시에 카메라의 시야에서 용접선이 벗어나지 않도록 카메라를 위치 시켜야 한다. 이를 위해 툴의 위치를 Position-based control, 카메라의 방향은 Feature-based control 하는 두 가지 방법을 결합한 Seam-Tracking Algorithm 을 제안한다. 이중 정밀한 제어가 필요없는 카메라의 방향 제어

기는 숙련된 조작자의 제어 신호를 배워 제어 규칙을 알아내는 SOFNN 을 사용한다.

3. 영상 처리

3.1 레이저 카메라의 구조

영상 보드는 Data Translation 사의 DT2867 을, Panasonic 사의 소형 카메라와 광각 렌즈, Power Technology 사의 690nm 레이저 다이오드(PM25(690-30)L2), Corion 사의 690nm 의 중심 파장과 11nm 의 대역폭을 가지는 대역 통과 필터를 사용한다.

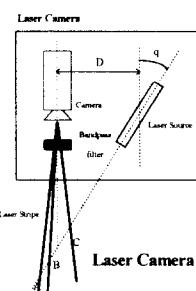


그림 1. 레이저 카메라의 구조

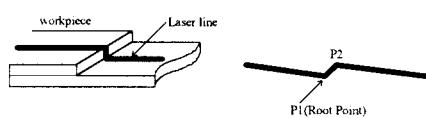


그림 2. 겹치기 이음에 대한 영상, 특징점

용접선을 추적하기 위해 용접 토치 바로 앞에 조사한 레이저를 CCD 카메라로 잡아 용접선의 위치를 알아내는 레이저 카메라를 사용한다. 그림 1에서 D 와 q 가 레이저 카메라의 시야와 해상도를 결정한다.

3.2 영상 처리

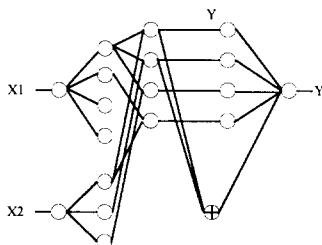
교정된 레이저 카메라로부터 영상을 얻어 제어에 필요한 특징을 찾는다. 본 논문에서는 겹치기 이음만을 고려하므로 복잡한 모델 매칭은 구현하지 않고 그림 2의 특징점 PI를 찾는 것을 목적으로 한다. 640x480 화소를 처리하는 대에는 많을 시간이 필요하기 때문에 초기에 아무런 정보도 없을 때에는 화면 전 영역을 처리하고 그 다음부터는 특징점 부근만을 처리하는 방법을 택한다. 얻어진 영상의 각 열중 일정 두께의 Gray level이 가장 큰 곳의 가운데 점을 용접선의 위치로 하고, 패스트 라인 드로잉 방법으로 그 틈을 메운다. 이렇게 해서 얻어진 곡선을 보다 고차원적인 인식을 위한 준비 단계로써 선분으로 근사화 하는데 실시간 처리에 적합한 ‘hop along spilt and merge’방법을 쓴다.

4. 카메라 방향 제어를 위한 SOFNN

퍼지 시스템은 시스템의 설계자가 제어 대상의 동역학을 잘 알거나 적어도 그것의 제어 규칙을 알고 있어서 퍼지 집합의 소속 함수 모양과 변수, 룰들이 정량적으로 정의되어야 한다. 일반적으로 이 과정은 시행착오를 거쳐 결정되어지므로 오랜 시간이 걸리게 된다. 이를 극복하기 위해 NN(Neural Network)과 퍼지 시스템의 장점을 결합하는 방법이 많이 연구되고 있는데 이것을 FNN(Fuzzy Neural Network)이라 한다. NN의 학습능력을 퍼지로직 시스템이 가짐으로써 NN에 좀 더 인간적인 추론 능력을 부여할 수 있고, NN 보다 명확한 의미의 변수를 사용하므로 용이한 초기화를 통해 빠르고 정확한 수렴을 기대할 수 있다.

C.T.Lin은 구조 학습 과정과 변수 학습 과정으로 이루어진 Hybrid Learning Algorithm을 제안했다. 구조 학습에서는 Kohonen의 Feature map Algorithm으로 입출력 퍼지 집합의 소속 함수를 결정하고 Competitive Learning Algorithm으로 퍼지룰을 학습한 뒤 rule elimination 과 rule combination으로 최적의 시스템 구조를 찾고 변수 학습 과정에서 Back Propagation Algorithm으로 퍼지 집합의 평균과 분산을 미세 조정한다. Carpenter 와 Grossberg는 퍼지 데이터를 다룰 수 있는 FNN을 제안했는데 퍼지 weight를 가지는 Adaptive Resonance Theory Network을 제안했다. 본 논문에서는 전진부 퍼지 집합의 수와 소속 함수가 결정되고 퍼지룰이 학습되고 난 후, 그 변수가 미세 조정되는 FNN을 제안한다.

4.1 FNN의 구조



layer1: Input layer

$$O_i^1 = x_i$$

layer2: Fuzzifier

$$O_i^2 = \exp\left(-\left(\frac{U_i^1 - m_{x_{i,j}}}{\sigma_{x_{i,j}}}\right)^2\right)$$

layer3: rule node

$$O_i^3 = U_j^3 \cdot O_i^2$$

layer4-5: Defuzzifier

$$y = \sum \overline{y}_i \cdot O_i^3 / \sum O_i^3$$

U_j^n : n 번째 layer의 j 번째 입력

O_i^n : n 번째 layer의 j 번째 출력

위 시스템은 singleton fuzzifier, product inference rule, center average defuzzifier, Gaussian membership function을 사용한다.

4.2 학습

A. 전진부 학습(clustering)

두개의 입력 x_1, x_2 과 하나의 출력 y 를 가지는 FNN을 설계한다. 입력 x_i 의 퍼지 집합을 $T_{x_{i,j}}$ 라 정의하고 x_i 의 퍼지 집합 수를 $|T_{x_i}|$ 라 한다. 주어진 입력 training pattern으로 입력 공간을 clustering하는데, 표준편차 σ 값과 threshold 값이 주어지면 입력에 따라 $T_{x_{i,j}}$ 를 학습시키거나 새로운 $T_{x_{i,new}}$ 를 생성한다. 즉, 입력 i_{x_i} 와 가장 가까운 평균 $m_{x_{i,j}}$ 를 가지는 집합 $T_{x_{i,j}}$ 에서 $\frac{(|i_{x_i} - m_{x_{i,j}}| - \sigma\sqrt{\pi})}{\sigma\sqrt{\pi}}$ 가 주어진 threshold 값보다 크면 평균값을 i_{x_i} 로 하는 새로운 $T_{x_{i,new}}$ 를 생성하고, threshold 값보다 작으면 $m_{x_{i,j}}$ 를 Kohonen의 Feature Map Algorithm으로 학습시킨다.

$$m_{x_{i,j}}(t+1) = m_{x_{i,j}}(t) + \alpha \cdot (i_{x_i} - m_{x_{i,j}}(t))$$

$\sigma\sqrt{\pi}$ 는 Gaussian 소속 함수를 삼각형으로 근사했을 때, 밑변 길이의 절반에 해당한다. 전진부의 소속 함수가 결정된 후 rule node 갯수는 $|T_{x_1}| \times |T_{x_2}|$ 으로 모든 연결을 다 생각한다. 이상의 방법으로 x_i 의 입력 공간을 적당한 퍼지 집합들로 clustering 한다.

B. 후진부 학습

전진부 학습에서 결정된 $m_{x_{i,j}}$ 값들을 고정시키고 난 후, training pair $(i_{x_{1,p}}, i_{x_{2,p}}, y_p)$ 가 주어지면, 거리 $\|m_{x_{i,j}} - i_{x_i}\|$ 가 가장 작은 $m_{x_{i,j}}$ 를 각 입력마다 하나씩 고르고 이들로 이루어진 rule node를 $|T_{x_1}| \times |T_{x_2}|$ 중에서 하나 결정할 수 있는데 이 node를 winning rule node라 부른다. Winning rule node에 해당하는 후진부 \bar{y} 값을 training pair y_p 로 학습시킨다.

$$\bar{y}_w(t+1) = \bar{y}_w(t) + \alpha \cdot (\bar{y}_w(t) - y_p)$$

rule node 중에 한 번도 winning rule node가 되지 못하는 node는 training pair에서 입력과 출력의 관계가 없음을 의미함으로 불필요한 이런 rule node는 삭제한다.

C. Parameter 학습

모든 feed-forward Network에는 back-propagation algorithm의 적용이 가능하다. 역시 FNN도 마찬가지인데 error를 다음과 같이 정의하고

$$e^o = \frac{1}{2} [f(x^o) - d^o]^2$$

위의 값을 최소화하기 위해서 $m_{x_{i,j}}$, \bar{Y} 값을 미세 조정한다.

$$\sum o_i^3 = b$$

d : desired output

$$\bar{y}^i(t+1) = \bar{y}^i(t) - \alpha \frac{\partial e}{\partial y^i}$$

$$\frac{\partial e}{\partial y^i} = (y - d) \frac{o_i^3}{b}$$

$$m_{x_{i,j}}(t+1) = m_{x_{i,j}}(t) - \alpha \frac{\partial e}{\partial m_{x_{i,j}}}$$

$$\begin{aligned} \frac{\partial e}{\partial m_{x_{i,j}}} &= \sum \frac{\partial e}{\partial o_i^3} \frac{\partial o_i^3}{\partial m_{x_{i,j}}} \\ &= (y - d) \sum \frac{\bar{y} - y}{b} o_i^3 \frac{2(x_i^p - m_{x_{i,j}})}{\sigma_{x_{i,j}}} \end{aligned}$$

위 식에서 합은 x_i 의 j 번째 퍼지 집합이 연결된 모든 rule을 합한 것을 뜻한다.

$$\sigma_{x_{i,j}}(t+1) = \sigma_{x_{i,j}}(t) - \alpha \frac{\partial e}{\partial \sigma_{x_{i,j}}}$$

$$\begin{aligned} \frac{\partial e}{\partial \sigma_{x_{i,j}}} &= \sum \frac{\partial e}{\partial o_i^3} \frac{\partial o_i^3}{\partial \sigma_{x_{i,j}}} \\ &= (y - d) \sum \frac{\bar{y} - y}{b} o_i^3 \frac{2(x_i^p - m_{x_{i,j}})^2}{\sigma_{x_{i,j}}} \end{aligned}$$

5. Seam Tracking Algorithm

용접선 추적 시스템은 로봇의 팔끝에 카메라를 장치한 eye-in-hand 구성이고 카메라가 툴이 가야할 경로를 먼저 측정하는 look-ahead 구성으로 되어 있어서 툴의 위치와 카메라의 방향을 동시에 제어해야 하는데 조작자의 제어 신호를 학습한 SOFNN이 카메라의 방향 제어를 하고, 툴의 위치는 절단 및 용접시 직교 좌표상에서 등속으로 연속적으로 움직여야 하므로 영상좌표를 제어하기 편리한 직교 좌표계로 변환한 값을 사용한다. 아래에 전체 시스템의 블럭 다이어그램을 나타내었다.

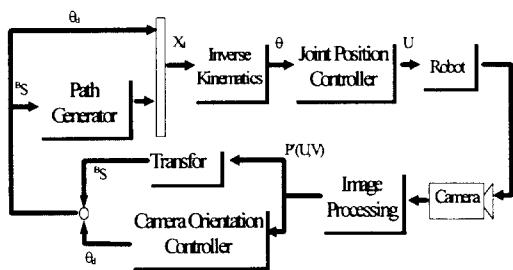


그림 3. 용접선 추적 시스템의 블럭 다이어그램

$p(u,v)$ 는 영상 특징 좌표를 나타내고 θ_d 는 카메라 방향 제어기의 출력을, x_d 는 카메라의 방향과 툴의 위치로 구성된 상태 변수를, U 는 로봇에게 주어지는 명령어를 각각 나타낸다.

카메라가 손목에 고정되어 있으므로 로봇에게 명령을 주기 위해

동차 변환 행렬을 이용한 로봇 베이스 좌표계로의 변환이 필요하다. 툴이 등속으로 움직여야 하고 측정된 용접선의 위치를 통과해야 하므로 로봇의 변환된 좌표를 이용한 선형 보간법을 써서 쉽게 경로를 생성할 수 있다.

실제 카메라의 방향 제어에는 예측이 필요하다. 즉 지금의 용접선 위치에서 다음에 측정될 위치를 예측한 후 카메라의 방향을 바꾸게 되는데, 이 때의 여러 제어 규칙들이 각각 퍼지 rule을 이를 수 있다. 조작자가 알고 있는 이런 제어 규칙들을 퍼지 rule로 SOFNN이 학습하게 된다.

6. Simulation 과 실험

본 논문에서 제안한 SOFNN이 조작자의 신호를 학습함을 Simulation을 통해 보인다. SOFNN 시스템은 위치 정보와 속도 정보의 두 입력과 카메라의 방향을 나타내는 하나의 출력을 mapping하는 시스템으로, 초기에 threshold 값을 1로, 전건부의 σ 을 각각 6, 0.25로 학습시킨다. 전건부 학습을 거쳐 각 입력 당 9 개의 퍼지 집합이 생성되고, 후건부 학습에서 9x9 개의 가능한 rule node 중 출력에 영향을 미치는 49 개 만이 남는다. 변수 학습으로 에러값을 0.3342 까지 줄일 수 있다. 전건부 학습과 후건부 학습에서의 Learning rate는 0.01로 각각 100 번의 iteration을 했으며 변수 학습에서 Learning rate는 0.001-0.0000001 까지 바꾸어 가며 실험했다.

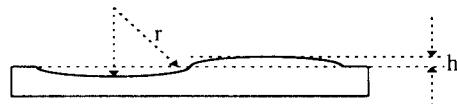


그림 4. 용접선의 모양

그림 4에서 $r=5mm$ 일 때의 조작자의 제어 신호를 얻어 그 신호를 SOFNN이 배우도록 했다. 구조 학습만으로 충분해 작은 에러값의 SOFNN을 구현할 수 있는데, 실제 조작자의 제어에서는 동일한 영상 특징에 대해서도 다른 제어 신호를 줄 수 있는데 이러한 불일치 때문에 오차값이 어느 정도 이하로는 떨어지지 않는다.

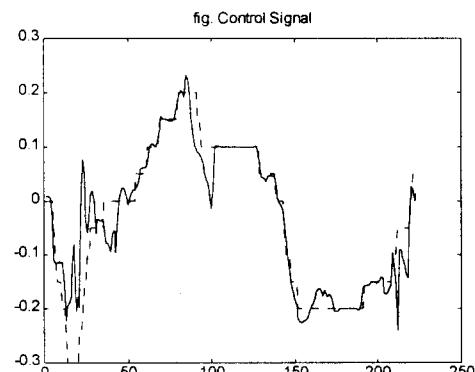


그림 5. 제어 신호. 점선은 조작자의 제어 신호를, 실선은 학습

후의 SOFNN 의 제어 신호를 나타낸다.

표 1. 퍼지 집합의 평균값들. 첫번째 열은 영상 좌표를 나타내는 입력(x_1)의 퍼지 집합의 평균값(단위:화소). 첫번째 행은 영상 좌표의 변화를 나타내는 입력(x_2) 퍼지 집합의 평균값(단위: 화소/시간, 5 개의 집합만을 나타냈다). 각 간의 값은 $T_{x_1,j}$ 과 $T_{x_2,j}$ 로 이루어진 rule 의 후건부의 평균값(단위:회전속도)을 나타낸다. 빈칸은 삭제된 rule 이다.

m	-0.069	-0.676	-1.289	-1.740	0.387
250.289	0.016	-0.125	-0.164	-0.165	
239.085	-0.133	-0.102	-0.055	-0.283	-0.054
228.726				0.023	0.281
215.314			0.014	-0.009	
204.577	0.098	0.103	0.061		0.119
260.997		-0.171	-0.204	-0.199	
275.868				-0.199	
291.124	-0.214	-0.178	-0.1671	-0.236	-0.211
302.981	0.051	0.041	0.050		0.047

7. 결론 및 향후 과제

본 논문에서는 카메라와 룰을 각각 독립적으로 제어하는 시스템을 제안하였고, 이 중 카메라 방향 제어를 위해, 퍼지 시스템의 집합 수와 룰, parameter 를 동시에 학습하는 SOFNN 을 개발하고 그 실험 결과를 보였다. 제안된 SOFNN 은 전건부 학습, 후건부 학습, 변수 학습으로 나누어져 있고 이런 학습을 통해서 불필요한 퍼지 집합이나 룰이 없는 적절한 시스템 사이즈를 가질 수 있다.

앞으로는 온라인 상에서도 효율적인 동작이 가능한 SOFNN 의 개발을 연구 목표로 하고 이를 바탕으로 여러 용접 자동화의 문제점을 극복하고자 한다.

참고 문헌

- [1] B.Chen. and L.L.Hoberock, "A Fuzzy Neural Network Architecture for Fuzzy Control and Classification", *Proceedings of the ICNN*, vol.4, pp.1168-1173, 1996.
- [2] C.T.Lin, *Neural Fuzzy Control Systems With Structure and Parameter Learning*, World Scientific, 1994
- [3] C.T.Lin and Y.C.Lu, "A neural fuzzy system with linguistic teaching signals", *IEEE Transactions on Fuzzy Systems*, vol. 3, pp.169-189, May 1995.
- [4] D.P.Chi, "A study on the weld seam tracking and selection of welding parameters in thin plate welding using vision sensor," Master's thesis, KAIST, 1994.
- [5] Li-Xin Wang, *Adaptive Fuzzy Systems And Control*, Prentice Hall, 1995
- [6] J.S.Sin, "A study on seam tracking and arc data monitoring system in lap joint," Master's thesis, KAIST, 1991.
- [7] T.Kohonen, *Self-Organizing and Associative Memory*, Springer-Verlag, 1992.
- [8] Hyun Ryu, "A robot weld seam tracking controller based on laser vision and a self-organizing fuzzy neural network", Master's thesis, POSTECH, 1995.