

퍼지 신경망에 의한 로봇의 시각구동

°김 태원*, 서 일홍*, 조 영조**

* 한양대학교 전자공학과 ** KIST 제어 시스템 연구실

Visual Servoing of Robot Manipulator by Fuzzy Membership Function based Neural Network

T.W.Kim*, I.H.Suh*, and Y.J.Cho**

* Dept. of Electronics Eng., Hanyang Univ.

** Control System Lab., KIST

Abstract

It is shown that there exists a nonlinear mapping which transforms features and their changes to the desired camera motion without measurement of the relative distance between the camera and the part, and the nonlinear mapping can eliminate several difficulties encountered when using the inverse of the feature Jacobian as in the usual feature-based visual feedback controls. And insted of analytically deriving the closed form of such a nonlinear mapping, a fuzzy membership function (FMF) based neural network is then proposed to approximate the nonlinear mapping, where the sutructure of proposed networks is similar to that of radial basis function neural network which is known to be very useful in function approximations. The proposed FMF network is trained to be capable of tracking moving parts in the whole work space along the line of sight. For the effective implementation of proposed FMF networks, an image feature selection processing is investigated, and required fuzzy membership functions are designed. Finally, several numerical examples are illustrated to show the validities of our proposed visual servoing method.

1. 서론

지난 여러해에 걸쳐 많은 연구가들이 인간 조작의 완전한 감독없이 비조작적인 환경에서 행동하고 조작할수 있는 능력을 로봇에게 주기위한 방법론을 탐구하여 왔다. 로봇의 이러한 지적인 능력은 다수의 환경 센서의 사용으로 이루어 질 수 있고, 이중에서 특히 시각정보는 시스템이 환경을 인식하고 타당한 행동을 결정하도록 하는 가장 강력한 센서 정보의 하나로 여겨져 왔다. 영상처리 장비의 발달에 따라 실시간으로 로봇 end effector의 위치와 방향을 제어할수 있는 feedback 신호로 비전을 채택할 수 있게 되었다. 시각 feedback은 물체의 위치와 방향에 대한 사전 지식없이 로봇이 임의로 움직이는 물체를 조작하고 추적할 수 있게 한다[1]. 시각 feedback 시스템은 seam tracking[2], precision part placement[3], conveyor tracking[4] 과 space telerobots[5]에 응용된다.

시각 feedback 시스템에 대한 초기 방법은 정적인 위치에 근거한 "보고 움직이는(look-and-move)" 구조를 채택했다. 이 시각 시스템은 영상을 열고, 영상 feature에 일련의 미리 지시된 feature를 매칭시킴으로 원하는 물체를 인식한 후, 영상 공간과 로봇의 작업공간 사이의 기구학 관계에 근거하여 원하는 위치와 방향 정보를 정확하게 계산한다. 그리고, 이

로봇 제어 시스템은 물체 위치에 도달하기 위해서 수반되는 동작의 궤적을 계획하고 수행한다. 이 paradigm에서, video routine과 로봇 제어 routine이 순서적으로 수행되기 때문에, 로봇트는 카메라가 새로운 영상을 얻기 전에 완전히 멈추어야 한다. 이 정지상태 때문에 로봇트를 이용하여 움직이는 물체를 추적하는 것이 어렵게 된다. 게다가, feedback 변수로 위치 좌표를 사용할때, 영상 feature로부터 물체의 자세를 결정하는데 on-line 계산이 많이 필요하다. 또한, Cartesian 작업 공간 안에서 물체의 위치와 방향의 정확한 계산은 video 신호 잡음과 시각 시스템의 모델링 불확실성등으로 인해 매우 어렵다.

[6,7,8]에서 보면 대부분의 feature Jacobian은 핀홀(pin-hole) 카메라 모델을 사용하여 어느 정도의 오차는 감수할 수 밖에 없고, feature Jacobian을 사용하려면 로봇트 핸드(hand)에 장착된 카메라와 물체 사이의 거리를 측정하거나, CAD 모델 정보(model data)를 필요로 한다[1,6]. 그리고, 제어가 거리측정 능력을 갖더라도 feature의 선택에 따라 출력 tracking 성능이 많이 다를 수 있다. 최악의 경우 feature Jacobian이 특이(singular)인 경우 시스템을 제어할 수 없게 된다.

반면에, 인간을 포함한 동물은 정확한 3 차원 위치 정보없이도 물체를 보고 잡을 수 있다. 이 사실로부터 시각 구동은 동물에게는 타고난 능력처럼 보인다. 로봇트에게 이러한 능력을 부여하기 위해 몇몇 연구가들이 영상 feature를 사용하여 동작을 제어하고, 반복에 의해 스스로 동작을 향상시키는 방법을 개발하려고 시도했다[4,10,11].

그들 중 Miller는 시각 구동을 위한 신경망을 기초로 한 학습 제어 시스템을 제안했다[4,10]. 이 제어 시스템에서, 한 신경망은 센서 출력과 시스템 명령 변수 사이의 비선형 관계를 재생하기 위해 학습된다. 학습 정보는 센서 출력에서의 원하는 변화를 만드는데 필요한 명령신호를 예측하는데 사용된다. 두번째 신경망은 시스템 명령 변수와 비전 센서 출력 변화 사이의 비선형 관계를 만들기 위한 학습에 사용된다. 이 신경망의 학습 정보는 영상 처리 지연을 효과적으로 보상하기 위해 다른 video 매개변수들을 예측하는데 사용된다. 로봇트 기구학이나 상대적인 물체의 속도나 방향에 대한 사전지식은 가정되지 않았다. 영상 매개변수의 불확실성과 video 영상에서 제어 시스템 추적 오차는 적은 반복횟수만에 낮은 값으로 수렴함이 발견되었다[10]. 그러나, 이러한 supervised 학습 제어를 구현하기 위해 학습 훈련 신경망이 특정 영역 뿐 아니라 전 작업 공간에 걸쳐 원하는 변환을 훈련하여야 한다. 왜냐하면 특정한 작업을 위해 단지 특수한 영역에 대해 훈련된 로봇트 제어기는 환경과 작업의 예상외의 변화에 전혀 응답 못하기 때문이다. 그리고 Hashimoto 등은 joint의 형태와 기하학적 차원에 관계없이 manipulator end-effector의 원하는 위치와 방향을 위해 물체의 영상과 관절각(joint angle) 사이의 feature

Jacobian을 학습하도록 두개의 역전파 신경망에 의한 자기 구성 시각 구동 시스템을 제안했다[10]. 이 시스템의 global network은, 신경망의 일반적 능력이 제어 강인성과 훈련되지 않은 물체 위치에 대한 적응성이 보장된다 보고 먼 거리에 대한 제어 신호와 작은 물체 거리에 대한 local network을 배우도록 훈련됐다. 그러나, 역전파 신경망이 local minimum으로 수렴하는 것은 일반적으로 보장되지 않는다. 따라서, 이 방법을 실제 작업에 적용시키기는 매우 어렵다.

Feature Jacobian을 배우기 위한 신경망 방법과 달리 feature based 시각 구동에 대한 완전히 다른 시도가 [12]에서 저자에 의해 제안되었다. 여기서, feature Jacobian은 카메라와 물체 사이 상대거리의 함수가 아니라, 단지 영상 feature의 함수로 제안되었다. 그리고, 제안된 Jacobian을 유도하는 복잡성을 피하기 위해 supervised 학습 능력을 가진 퍼지 제어기가 제안되었으며, 언어 값에 대한 소속 함수의 중심은 단순한 기울기(gradient) 방법에 의해 반복적으로 훈련된다. 그러한 새로운 Jacobian의 도입 덕분에 고전적인 feature Jacobian을 사용할 때 부딪히는 몇몇 어려움이 제거될 수 있었으나 단순한 gradient 방법 때문에 만족스러운 성능이 나오지 않았다.

본 논문에서는 카메라와 물체 사이의 상대적 거리의 정보없이 feature의 변화량과 원하는 카메라 motion의 변화량 사이에 비선형 사영이 존재한다는 것을 보이고, 비선형 사영은 일상적인 feature based visual feedback 제어 [6,9]에서 처음 inverse feature Jacobian을 사용할 때 부딪히는 어려움을 제거할 수 있다는 것을 보이고자 한다. 그리고, 이 비선형 사영의 닫힌 형태(closed form)를 해석적으로 유도하는 대신, 신경망 퍼지 소속 함수(FMF)를 이용하여 비선형 사영을 근사화하려 한다. 여기서 제안하려는 network의 구조는 함수 근사화에 사용되는 것으로 알려진 radial basis function network[13]과 유사하다.

2. 미분 영상 공간에서 미분 Cartesian 공간으로의 비선형 변환

cX 를 카메라 frame C에 관한 m-차원 상대 위치 벡터라 하고, F를 물체 영상의 n-차원 feature 벡터라 하자. 일반적으로 cX 와 F 사이의 기구학 관계는 다음과 같이 나타내진다.

$$F = I(cX) \quad (1)$$

여기서 I(.)는 $cX \in R^m$ 에서 $F \in R^n$ 으로의 사영이다. 만약 cX 에서 F로의 사영이 일대일 대응이면 역 기구학 (inverse kinematic) 관계는 다음과 같다.

$$cX = I^{-1}(F) \quad (2)$$

여기서, $I^{-1}(\cdot)$ 는 $F \in R^n$ 에서 $cX \in R^m$ 으로의 사영이다.

Feature 공간과 카메라 공간 사이의 미분 관계는 feature Jacobian을 사용하여 나타낼 수 있다. d^cX/dt 와 dF/dt 를 각각 카메라에 대한 물체 속도의 변화와 시간에 따른 영상 feature의 변화라 하면 식(1)의 1차 근사법은 다음과 같이 얻어진다.

$$dF/dt = J(cX) d^cX/dt \quad (3)$$

여기서, $J(cX)$ 는 $dI(cX)/d^cX$ 로 정의되는 $n \times m$ 행렬이다. 만약 행렬 J가 full-rank이면 d^cX/dt 는 $J^{-1}(cX)$, $d^cX/dt = J^{-1}(cX) dF/dt$ 의 유사역(pseudo-inverse)을 사용함으로써 얻어질 수 있다[14].

$$d^cX/dt = J^{-1}(cX) dF/dt \quad (4)$$

식(2) 대신 식(4)를 사용할때 기하학적 시각 모델은 해석적인 미분식이 꽤 단순한 핀홀 카메라 모델이 사용된다. 따라서, 모델링 정확성이 실제 응용에서 제어 문제를 일으킬 수도 있다. 식(4)에서 feature Jacobian의 각 요소는 cX 의 함수이고 이것은 특히 물체의 CAD 정보[1,6]나 물체와 카메라의 거리 측정[9]이 필요하다. 이런 것들이 feature Jacobian을 계산적으로 복잡하게 만들고 측정오차에 민감하게 하여 feature Jacobian 방법을 사용하기 힘들게 한다. 이런 어려움과 더불어, $J(cX)$ 는 물체가 바뀔때마다 물체 변화가 기하학적인 시각관계가 다시 모델링 되어야 하기때문에 새로이 구해져야 한다. 또한, 만약 $J(cX)$ 가 특이라면 inverse Jacobian을 사용하는 방법은 로봇트 제어에 사용할 수 없다.

이러한 어려움을 극복하기 위해 cX 와 F 사이의 미분 관계의 다른 형태를 여기서 제안한다. 이것은 δX 와 δF 를 각각 cX 와 F의 변화량으로 놓으면 식 (2)로부터 다음을 얻는다.

$$\begin{aligned} cX + \delta X &= I^{-1}(F + \delta F) \\ &= I^{-1}(F) + G(F + \delta F) \end{aligned} \quad (5)$$

여기서 $G(F, \delta F)$ 는 다음으로 정의된다.

$$G(F, \delta F) \triangleq \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N (a^k I^{-1}(F) / a^k F^k) \delta F^k \quad (6)$$

만약 $\delta X = G(F, \delta F)$ 를 사용하면, 식 (4)를 사용하는 feature Jacobian에 의해 부딪히는 어려움들이 다음 이유에 의해 제거될 수 있다: i) $G(F, \delta F)$ 는 카메라와 물체 사이의 기하학적 시각 모델이 필요하지 않다, ii) 역 사영이 필요하지 않다, iii) $G(F, \delta F)$ 가 단지 F와 δF 의 m-차원 벡터 함수이므로, $G(F, \delta F)$ 는 물체가 바뀔때마다 다시 모델링될 필요가 없다. 그러나, 이러한 장점에도 불구하고 해석적으로 $G(F, \delta F)$ 를 얻는데 어려움이 있다. 따라서, $G(F, \delta F)$ 의 꼴을 해석적으로 유도하는 대신, 비선형 사영 $G(F, \delta F)$ 를 근사화하기 위해 신경망에 근거를 둔 퍼지 소속함수[15]를 이용하기로 한다.

[12]에서 언급했듯이, 저자는 식(6)에서 $N=1$ 인 $G(F, \delta F)$ 를 근사화하기 위해 supervised 학습 능력을 지닌 퍼지 제어기를 제안했다. 여기서 언어 변수에 대한 퍼지 소속 함수의 중심은 단순한 기울기 방법에 의해 반복적으로 얻어지거나 단순 기울기 방법때문에 만족한 근사값을 얻을 수 없었다. 그러나, 신경망과 퍼지 논리를 이용하여 뛰어난 학습능력을 가진 새로운 형태의 퍼지 소속함수 신경망 (Fuzzy Membership Function Network; FMF Network)을 제안하여 그 효용을 검토한 바 있다[15].

3. FMF network을 이용한 시각 구동의 설계

영상 feature와 카메라의 위치와 자세에서 원하는 변화에 대한 변화량에 관계된 미분 비선형 사영은 Resolved Motion Rate Control(RMRC)구조에서 이용할 수 있다. $G(F, \delta F)$ 를 해석적으로 얻기 어렵기 때문에 $G(F, \delta F)$ 는 [15]에서 제안한 FMF network에 의해 근사화된다.

Visual feedback 제어를 위한 영상 feature의 선택에 있어서, 적어도 6개의 영상 feature들이 3차원의 카메라의 위치와 자세를 결정한다. 즉 다음을 의미한다.

$$\begin{aligned} \delta x_i &= G_i(F_1, F_2, \dots, F_6, \delta F_1, \delta F_2, \dots, \delta F_6), \\ & \quad i=1,2,\dots,6 \end{aligned} \quad (7)$$

그러나, 만약 어떤 $j \neq i$ 에 대해 F_j 와 δF_j 가 G_i 의 발생에 공헌할 수 없도록 F_j 와 δF_j 를 선택한다면 G_i 는 F_j 와 δF_j 에 독립이 되고 따라서 G_i 에 대한 퍼지규칙도 쉽게 설정할 수 있다. 구체적으로 $(\delta x_1, \delta x_2, \delta x_3)$ 와 $(\delta x_4, \delta x_5, \delta x_6)$ 를 카메라

라계의 $\circ X, \circ Y, \circ Z$ 축에 대한 천이와 회전에 대한 미소 변화량을 나타낸다고 가정하자. 그리고 그림 1처럼 object계의 X, Y, Z 축을 $\circ X, \circ Y, \circ Z$ 축으로 할당한다. 이제 그림 2과 같이 영상에서 사각형(특히 기준 영상의 경우 직사각형)을 고려하자. 여기서 $F_i, i=1,2,\dots,6$,는 다음처럼 주어진다.

- F_1 = 영상평면에서 사각형의 무게중심의 X 좌표값
- F_2 = 영상평면에서 사각형의 무게중심의 Y 좌표값
- F_3 = 현재 영상에서 사각형의 크기 / 기준 영상에서 사각형 (혹은 특별한 경우에 직사각형)의 크기
- F_4 = 영상평면에서 X축에 대한 사각형의 두개의 대변 길이의 비율
- F_5 = 영상평면에서 Y축에 대한 사각형의 두개의 대변 길이의 비율
- F_6 = 영상평면에서 사각형의 관성주축의 각도

그리고 $i=1,2,\dots,6$ 에 대해 각 δF_i 는 F_i 와 기준 영상 feature 값 F_i^r 사이의 차로 주어진다. F_i^r 은 목표위치 ($\circ P_{tx}, \circ P_{ty}, \circ P_{tz}$)에서 teach-by-showing 방법에 의해 측정된 값이다. δx_1 과 δx_2 는 기본적으로 $(F_1, F_3, \delta F_1)$ 과 $(F_2, F_3, \delta F_2)$ 에 종속이고 δx_3 는 오직 δF_3 에 종속이라는 것을 얻을 수 있다. 이러한 결과로부터 $\delta x_1, \delta x_2, \delta x_3$ 는 $\delta x_1 \approx G_1(F_1, F_3, \delta F_1)$, $\delta x_2 \approx G_2(F_2, F_3, \delta F_2)$, 그리고 $\delta x_3 \approx G_3(\delta F_3)$ 로 쓸 수 있다. $i=1,2$ 일때 F_i 와 F_3 에 대한 δx_i 의 종속성은 다음과 같이 정의된 d_i 를 사용하여 더 단순화할 수 있다.

d_i = object계 ($\circ X, \circ Y, \circ Z$)에 대하여 ($\circ X, \circ Y$) 평면위에 카메라 위치 벡터를 투영하여 생기는 위치 벡터와 $\circ X_i$ 축 사이의 각

d_i 는 간단히 다음으로 예측할 수 있다.

$$d_i = \tan^{-1}(f \gamma / F_3 / [K_i F_i (\gamma F_3 - 1)]) \quad (8)$$

여기서 K_i 와 f 는 각각 영상 scale factor와 카메라의 초점거리이다. 따라서 $\delta x_i, i=1,2,3$ 은 간단히 $\delta x_i = G_i(d_i, \delta F_i)$, $i=1,2$ 와 $\delta x_3 = G(\delta F_3)$ 로 주어질 수 있다. 비슷하게 $\delta x_i, i=4,5,6$ 도 $\delta x_i = G_i(d_i, \delta F_i), i=4,5$ 와 $\delta x_6 = G(\delta F_6)$ 로 표현할 수 있다.

전체 작업공간에서 움직이는 물체를 시선을 따라 추종하는 능력을 가진 비선형 사영 $G_i, i=1,2,\dots,6$,로 근사화하는 FMF network를 구비하기 위해서는 혼련단계에서 카메라의 경로가 구간이 주어져야 한다. 이를 위해 카메라의 가시각을 고려해야 한다. 즉 ($\circ P_{tx}, \circ P_{ty}, \circ P_{tz}$)에 고정된 목표에 대해 카메라가 전체 물체를 볼 수 있는 가시영역 VR이 그림 3처럼 설정되어야 한다. 그리고 VR의 위쪽 바깥 면을 TVR이라 한다. 경로는 TVR위의 위치에서 object계에서 목표위치 ($\circ P_{tx}, \circ P_{ty}, \circ P_{tz}$)까지 연결된 선형 경로로 주어진다. 여기서 기준좌표계는 object계로 선택한다. 비선형 사영 $G_i, i=1,2,\dots,6$,에서 $G_1(d_1, \delta F_1)$ 와 $G_2(d_2, \delta F_2)$ 에서의 입력변수 d_1 와 d_2 는 퍼지 규칙이 설정되었을 때 매개변수화 기술에 의해 무시할 수 있다. G_1 과 G_2 에서 δx_1 과 δx_2 에 대한 d_1 와 d_2 는 주어진 선형경로에서 일정하다. 그런 다음 d_1 와 d_2 는 $M_1 \times M_2$ 부공간으로 VR을 분할하여 $d^*_{1,1,1}=1,2,\dots,M_1$ 과 $d^*_{2,1,1}=1,2,\dots,M_2$ 로 효과적으로 매개변수화할 수 있다. 각 부공간에 대해 FMF network는 부공간에 속한 각각의 선형 경로를 따라 혼련되어진다. $M_1 \times M_2$ FMF network의 혼련이 완료된 이후에 $M_1 \times M_2$ FMF network는 식 (18)에서 network를 삽입하여 조합한다. 삽입한 network는 식 (20)에서의 J_i 를 최소화하는 방식으로 식(21)에 의해 혼련된다. 비슷하게 G_4 와 G_5 에서의 F_4 와 F_5 도 구좌표계를 적용하여 매개변수화할 수 있다.

단순변수의 scalar 함수 $G_1(d^*_{1,1}, \delta F_1), l=1,2,\dots,M_1$, $G_2(d^*_{2,1}, F_2), l=1,2,\dots,M_2$, $G_3(\delta F_3)$, $G_4(d^*_{4,1}, \delta$

$F_4), l=1,2,\dots,M_4$, $G_5(d^*_{5,1}, \delta F_5), l=1,2,\dots,M_5$, 그리고 $G_6(\delta F_6)$ 을 근사하기 위한 fuzzy 관계는 식(7)처럼 주어진다. 표현을 일치시키기 위해 $G_3(\delta F_3)$ 와 $G_6(\delta F_6)$ 를 $M_3=M_4=1$ 일때 $G_3(d^*_{3,1}, \delta F_3), l=1,2,\dots,M_3$ 와 $G_6(d^*_{6,1}, \delta F_6), l=1,2,\dots,M_6$ 로 표현한다. $G_{il}=G_i(d^*_{i,1}, \delta F_i)$ 로 놓고, $i1R^1, i1R^2, \dots, i1R^{q_i}$ 는 $G_{i1}, i=1, 2, \dots, 6$ 과 $l=1,2,\dots,M_6$ 의 근사를 위한 q_i (홀수) 퍼지 관계라 한다. A_{j1l} 와 B_{j1l} 는 퍼지 관계 $i1R^l$ 의 IF부분과 THEN부분에 사용된 퍼지 집합 값이라 한다. 또한 $\mu^{A_{j1l}}(\delta F_i)$ 와 $\mu^{B_{j1l}}(u_i)$ 를 A_{j1l} 와 B_{j1l} 의 소속 함수라 하자. 각 함수 근사에서 퍼지 규칙의 IF부분에서 퍼지 집합의 소속 함수는 입력변수를 관측하여 만들 수 있다. 단순화하기 위해 소속 함수 $\mu^{A_{j1l}}(\delta F_i)$ 는 그림 4에서처럼 삼각형으로 주어지고 그 식은 다음과 같이 쓴다.

$$\mu^{A_{j1l}}(\delta F_i) = \begin{cases} \frac{(\delta F_i - a_{j1l})}{(a_{j1l} - b_{j1l})}, & \delta F_i \leq a_{j1l} \\ \frac{(\delta F_i - a_{j1l}) + 1}{(c_{j1l} - d_{j1l})}, & \delta F_i > a_{j1l}. \end{cases} \quad (9)$$

$i=1,2,\dots,6, j=1,2,\dots,q, l=1,2,\dots,M_i$

여기서 a_{j1l}, b_{j1l} 와 c_{j1l} 는 결정되어야 할 실수이다. 이제 식 (7)에서 $\mu^{A_{j1l}}(\delta F_i)$ 에 대해 a_{j1l}, b_{j1l} 와 c_{j1l} 를 결정하기 위해 $\delta F_{i\max}$ 를 δF_i 에 대한 최대값으로 놓고 $\delta F_{i\min}$ 를 δF_i 에 대한 최소값으로 놓으면 $\delta F_{i\min} = -\delta F_{i\max}$ 로 주어진다. 또한 $h(M_i, l)$ 를 다음과 같이 정의하자.

$$h(M_i, l) = \begin{cases} (2l-1)/(M_i-1)M_i!, & l=1,2,\dots,M_i, M_i \in \{\text{홀수} > 1\}, \\ 1, & l = M_i = 1 \end{cases} \quad (10)$$

1번째 경로에서 최대 feature값이 $\delta F_{i\max}$ 보다 작게될 것이다. 따라서 이러한 효과를 고려하기 위해 $d^*_{i,1}$ 에서 δF_i 의 비선형 종속성에도 불구하고 $h(M_i, l)\delta F_{i\max}$ 를 1번째 경로에서 최대 feature값이라 하자. 그리고 나서 $i=1,2,\dots,6, j=1,2,\dots,q_i$ 와 $l=1,2,\dots,M_i$ 에 대해 a_{j1l}, b_{j1l} 와 c_{j1l} 는 만약 모든 퍼지 집합값들이 $-h(M_i, l)\delta F_{i\max}$ 로부터 $h(M_i, l)\delta F_{i\max}$ 까지 일정하게 분포한다면 다음과 같이 주어진다.

$$a_{j1l} = (q_i - 2j + 1)h(M_i, l)\delta F_{i\max} / (q_i - 1), \quad (11)$$

$$b_{j1l} = \begin{cases} a_{j+1,1l}, & j=1,2,\dots,q_i-1, \\ \text{not defined}, & j=q_i. \end{cases} \quad (12)$$

그리고,

$$c_{j1l} = \begin{cases} \text{not defined}, & j=1, \\ a_{j-1,1l}, & j=2,3,\dots,q_i. \end{cases} \quad (13)$$

G_{i1} 에 대한 퍼지 집합의 개수 q_i 는 feature 서로 간에 작용하는 $\delta F_{i\max}$ 의 상대적인 크기를 관측하여 결정되어진다. 예를 들면 q_1, q_2 와 q_3 를 결정하기 위해 $\delta F_{1\max}, \delta F_{2\max}$ 와 $\delta F_{3\max}$ 를 서로 비교하여야 한다. 그림 3에서처럼 $\delta F_{i\max}, i=1,2,3$ 은 종종 한 visual 샘플링(sampling) 시간 동안에 $\circ X, \circ Y$ 와 $\circ Z$ 축을 따라 움직이는 카메라의 최대거리를 의미하는 VR에서 $\delta x_{\max}, \delta y_{\max}, \delta z_{\max}$ 에 해당하는 각기 다른 위치 L_1, L_2 와 L_3 에서 계산되어진다. 그림 3의 경우에는 q_1, q_2 와 q_3 를 $q_1 > q_2 > q_3$ 가 되도록 선택한다.

이제 singleton 소속 함수 $\mu^{B_{j1l}}(u_i), i=1,2,\dots,6, j=1,2,\dots,q_i$ 와 $l=1,2,\dots,M_6$ 를 결정하기 위해 $u_{i\max}$ 와

$-u_{i\max}$ 로 주어진 출력 u_i 의 최대 최소값을 사용할 수 있다. 즉, $\mu^{B_{ij}}(u_i)$ 는 다음과 같이 주어진다.

$$\mu^{B_{ij}}(u_i) = \begin{cases} 1, & u_i = \lambda_{ij} \\ & = (q_i - 2j + 1)u_{i\max}h(M_i, 1)/(q_i - 1), \\ 0, & \text{otherwise,} \\ & \text{for } i=1, 2, \dots, 6, j=1, 2, \dots, q_i, \\ & \quad 1, 2, \dots, M_i \end{cases} \quad (14)$$

4. 모의실험 결과

제한한 시각 구동방법에 의한 FMF 신경망의 성능을 증명하기 위해 컴퓨터 모의실험을 하였다. 이 모의실험에선 작업 물체와 카메라간의 기구학 관계만 고려하였다. 시스템의 dynamics를 포함하지 않았기 때문에 카메라의 위치를 이동시키는 명령이 떨어지면 즉시 명령을 수행한다고 가정한다. 그리고 카메라는 핀홀 모델로 가정한다. 영상 feature들은 노이즈를 가지고 있는 상태에서 이상적이며 왜곡되지 않은 2차원 영상 point들로부터 나온다. 왜냐하면 영상 왜곡은 모델화하기 힘들고 빛과 transducer resolution과 선형성에 대해 광범위하게 변화하기 때문이다. 노이즈를 가지고 있는 상태는 이상화된 상태에서 추출한 feature value들에 균등하게 분포된 노이즈의 level들을 변화시키는 것으로 가정한다.

이 모의실험을 위한 물체는 넓이가 0.2m x 0.2m이고 초점거리와 핀홀 카메라의 image scale factor는 각각 14mm와 0.05mm/pixel이다. 기존 영상에 대한 목표위치 (${}^oP_{tx}, {}^oP_{ty}, {}^oP_{tz}$)는 object frame에서 (0.0m, 0.0m, 0.3m)로 정해졌다. 200msec의 visual 샘플링 시간동안 카메라가 X, Y, Z축으로 각각 최대로 갈 수 있는 거리 $\delta X_{\max}, \delta Y_{\max}, \delta Z_{\max}$ 는 50mm이다. 3점의 feature selection과정에서 F_1, F_2, F_3 는 각각 object image의 무게중심의 X, Y축 좌표로서 결정되어지고 물체 영상들의 크기비(size ratio)는 현재의 카메라 위치와 목표 위치 (${}^oP_{tx}, {}^oP_{ty}, {}^oP_{tz}$)에 의해 결정된다. $\delta F_{1\max}$ 와 $\delta F_{2\max}$ 는 각각 (0.05m, 0.0m, 0.35m)와 (0.0m, 0.05m, 0.35m)에서 41pixel로 계산되고 $\delta F_{3\max}$ 는 (0.0m, 0.0m, 0.35m)에서 0.9272이다. $\delta F_{1\max}, \delta F_{2\max}, \delta F_{3\max}$ 를 같은 평면에서 구하였기 때문에 쉽게 $q_1 = q_2 = q_3 = 7$ 이라는 것을 알 수 있다. M_1 과 M_2 는 7을 만들어 주기 위해 정해졌다. 이것은 볼 수 있는 공간의 범위(VR)가 각자 같은 크기를 가지고 있는 7x7 부영역들로 나누어져 있다는 것을 알려준다. 그리고 M_3 는 1로 주어진다. 그리고 식(10)에서 식 (12)을 통해 $i=1, 2, 3, j=1, 2, \dots, q_i, l=1, 2, \dots, M_i$ 일때 a_{ij}, b_{ij} 와 c_{ij} 값을 계산하여 그림 4처럼 입력 소속함수들을 구할 수 있다. 또한 식(14)의 출력 소속함수들도 그림 5에서처럼 $u_{j\max}$ 와 $j=1, 2, 3$ 이 50mm/200msec로 주어졌을때 첫 학습단계에 사용되어진다. [15]의 FMF network의 κ_1 과 β_1 의 값은 0.5와 0.3으로 각각 주어져 있다. δF_i 와 기대출력 δX_{id} 의 쌍에 대해 network은 오차의 제곱이 0.0001 이하가 되도록 학습되어졌다. 49개의 FMF 신경망을 완전히 학습시킨 후 [15]에 있는 보간망(interpolating network)을 학습시킨다. 이 과정을 위해서 식(8)에서의 $i=1, 2, \dots, 7$ 일때 소속 함수인 $\pi_i(d_1)$ 와 $\pi_j(d_2)$ 를 그림 5에서 보듯이 $i=1, 2, \dots, 7$ 일때 γ_i 를 1로 놓고, κ_2 와 β_2 를 0.5와 5로 각각 놓는다.

시선을 따라 움직이는 물체를 추적하는 시각 구동에 기초를 둔 제한된 FMF 신경망의 성능을 검사해 보기로 한다. 이를 위해 다음 2가지 경우를 고려한다; (i) 물체가 $Y=X/2$ 로 주어진 선형 경로를 따라 55.9mm/sec로 움직이는 경우. (ii) 물체가 $X^2+Y^2=(500\text{mm})^2$ 로 주어진 원형 경로를 따라 2 revolutions/min의 각속도로 움직이는 경우. 여기서 시각 구동을 시작할때의 object frame을 기준 좌표계로 선택한다. (i)의 경우에 대한 카메라의 예상 궤적과 실제 궤적이 그림 6에 있다. 카메라의 모터들이 X축과 Y축으로 각각 10mm와 5mm의 정상상태 궤적의 차이를 볼 수 있다. 정상상태 궤적의 차이는 한 샘플링 주기동안에 일어나는 계산상의 시간지연 때문이다. 그러므로 궤적의 차이를 없애기 위해 예측 능력이 있는 퍼지

제어 기술들이 필요할 수도 있다.

그림 7의 (a)와 (b)는 (ii)의 경우에서 카메라 모터들의 출력의 궤적과 물체의 궤적을 보여주고 있는데, (i)의 경우와 유사함을 알 수 있다. 궤적의 차이가 있다하더라도 경로오차는 항상 그림 7의 (c)처럼 거의 무시할 정도로 작다.

그림 8는 물체의 영상이 노이즈의 영향을 받을때 보간망이 있는 제한된 FMF 신경망을 사용하는 제어기와 feature Jacobian 방법을 사용한 제어기의 성능들을 따라가는 경로를 보여준다. 그림 8로부터 제한한 시각 feedback 제어기는 노이즈에 강하고 반면 역 feature Jacobian을 사용한 방법을 사용한 시각 제어기는 민감할 정도로 노이즈에 민감하다.

5. 결론

신경망에 근거한 퍼지 소속 함수(FMF)는 시각 구동의 비선형 사영을 근사화하기 위해 제안되었는데, 제한된 network의 구조는 radial basis 신경망 구조와 흡사하다. 제안된 FMF network은 시야에 따라 모든 작업공간 내의 움직이는 부분들을 추적할 수 있도록 학습되어졌다. 제한된 FMF network을 더욱 효과적으로 이용하려면 영상 feature를 선택하는 과정이 연구되어야 하고 필요한 퍼지 소속 함수들을 만들어야 한다. 이 모의실험에서 제안한 FMF 신경망에 기초한 시각 구동 방법은 성공적으로 일을 수행했고 기존의 시각 구동 방법보다 경로의 정확성, 노이즈에 강한 점, 모든 로봇트 작업 공간 내에서의 움직이는 물체를 추적하는 면에서 우수했다. 그리고 이 시각 구동 제어기는 설계하기가 용이하며, 학습 속도가 빠르고, 계산상의 복잡성이 없다는 점에서 실질적으로 쉽게 이용할 수 있다. 그러나 시간 지연과 로봇트 Dynamics를 잘 해결할 수 있는 효과적인 기술이 필요하다.

Reference

- [1] J.T.Feddema, C.S.G.Lee and O.R.Mitchell, "Weighted Selection of Image Features for Resolved Rate Visual Feedback Control," IEEE Trans. on Robotics and Automation, vol.7, no.1, pp.31-47, Feb. 1991.
- [2] P.K.Khosla, C.P.Neuman and F.B.Prinz, "An algorithm for seam tracking applications," Int. J. Robotics Research, vol.4, no.1, pp.27-41, Spring 1985.
- [3] J.Mochizuki, M.Takahashi and S.Hata, "Unpositioned workpieces handling robot with visual and force sensors," IEEE Trans. Ind. Electorn., vol.IE-34, no.1, pp.1-4, Feb. 1987.
- [4] W.T.Miller, "Sensor based control of robotic manipulators using a general learning algorithm," IEEE J. of Robotics and Automation, vol.RA-3, no.2, pp.157-165, April 1987.
- [5] B.Wilcos, D.B.Gennery, B.Bon, and T.Litwin, "The sensing and perception subsystem of NASA research telerobot," in Proc. Workshop on Space Tele-robotics, vol. II, G.Rodriguez, Ed., JPL Pbu.87-13, pp.3-8, Jly 1987.
- [6] J.T.Feddema and O.R.Mitchell, "Vision-Guided servoing with Feature-Based Trajectory Generation," IEEE Trans. on Robotics and Automation, vol.RA-5, no.5, pp.691-700, Oct. 1989.
- [7] A.C.Sanderson and L.E.Weiss, "Image-based visual servo control of robots," Proc. SPIE, vol.360, pp.164-169, Aug. 1982.
- [8] A.C.Sanderson and L.E.Weiss, "Adaptive visual servo control of robots," in Robot Vision, A.Pugh, Ed., New York: Springer-Verlag, pp.107-116, 1983.

- [9] K.Hashimoto et. al., "Manipulator control with image-based visual servo," IEEE Int. Conf. Robotics and Automation, Sacramento, CA, pp.2267-2272, 1991.
- [10] W.T.Miller, "Real-Time Application of Neural Networks for Sensored-Based Control of Robots with Vision," IEEE Trans. on System, Man and Cybernetics, vol.SMC-19, no.4, pp.825-831, July/Aug. 1989.
- [11] H.Hashimoto, T.Kubota, M.Sato and F.Harashima, "Visual Servo Control of Robotic Manipulators Based on Artificial Neural Network," Proc. of IEEE Int. Conf. on Industrial Electronics, pp.770-774, 1989.

- [12] I.H.Suh et. al., "Visual Servoing by a Fuzzy Reasoning Method," IEEE/RST Int. Workshop on Robotics and Systems (Osaka,Japan), pp.111-116, Nov. 1991.
- [13] T.Poggio and F.Girosi, "Regularization algorithms for learning that are equivalent to multilayer networks," Science, vol.247, pp.978-982, 1990.
- [14] G.Strang, *Linear Algebra and Its Applications*, 2nd Ed., Academic Press, 1980.
- [15] I.H. Suh and T.W. Kim, "Nonlinear Function Approximation by the Fuzzy Membership Function based Neural Networks," Proc. of the Korea-Japan Joint Conf. on Fuzzy Systems and Eng. (Seoul,Korea), pp.153-156, Aug. 1992.




그림 1. 카메라와 물체의 좌표계
Fig. 1. Camera and Object Frame




그림 2. 물체 image에서의 사각형
Fig. 2. A quadrangle in the object image




그림 3. 가시영역과 TVR
Fig. 3. Visible Range(VR) and TVR




그림 4. 퍼지규칙의 IF 부분의 삼각형 소속함수
Fig. 4. Membership functions of the triangular type for the fuzzy set values in the 'IF' part of the fuzzy rules




그림 5. 퍼지규칙의 THEN 부분의 Singleton 소속함수
Fig. 5. Singleton membership functions for the fuzzy set values in the 'THEN' part of the fuzzy rules


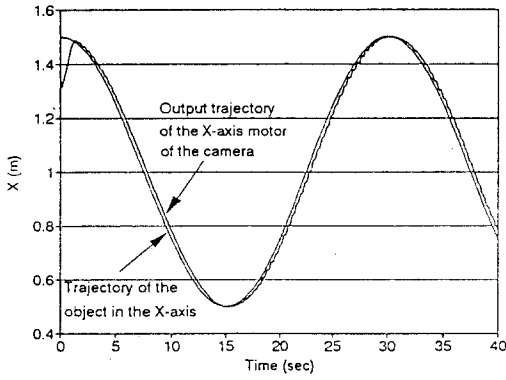
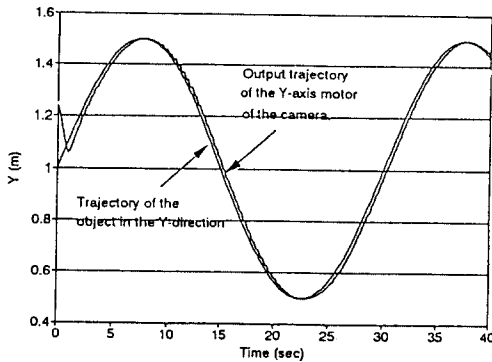



그림 6. 제한한 시각 제거기의 직선 경로 추적 성능
Fig. 6. Tracking performances of our proposed visual controller for the case when the object moves along a linear path given as $Y=X/2$ with a velocity of 55.9mm/sec.



(a) Object trajectory in the X-direction and output trajectory of the X-axis motor of the camera.



(b) Object trajectory in the Y-direction and output trajectory of the Y-axis motor of the camera.



(c) Paths of the object and the camera in X-Y plane of the world coordinate.

그림 7. 제안한 시각 제어기의 원형 경로 추적 성능
 Fig. 7. Tracking performances of our proposed visual controller for the case when the object moves around a circular path $X^2 + Y^2 = (500\text{m})^2$ with the angular velocity of 2 revolution/min.

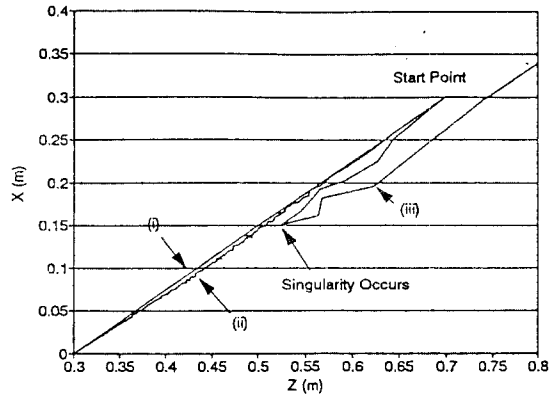


그림 8.(a) Feature Jacobian 방법을 이용한 제어기의 경로 추종 성능

Fig. 8.(a) Path following performances for the controller using feature Jacobian approach

- (i) the case when the object is not corrupted by noises
- (ii) the case when the image feature values F_i are randomly varying to $0.98F_i$ thru $1.02F_i$
- (ii) the case when the image feature values F_i are randomly varying to $0.95F_i$ thru $1.05F_i$




그림 8.(b) 제안한 FMF network을 이용한 제어기의 경로 추종 성능

Fig. 8.(a) Path following performances for the controller using the proposed FMF neural networks with the interpolating network

- (i) the case when the object is not corrupted by noises
- (ii) the case when the image feature values F_i are randomly varying to $0.98F_i$ thru $1.02F_i$
- (ii) the case when the image feature values F_i are randomly varying to $0.95F_i$ thru $1.05F_i$