

Fuzzy Neural Network-based Visual Servoing ; part I

金 兌 垣*·徐 一 弘**
(Tae-Won Kim·Il-Hong Suh)

Abstract—It is shown that there exists a nonlinear mapping which transforms image features and their changes to the desired camera motion without measuring of the relative distance between the camera and the object. This nonlinear mapping can eliminate several difficulties occurring in computing the inverse of the feature Jacobian as in the usual feature-based visual feedback control methods. Instead of analytically deriving the closed form of this mapping, a Fuzzy Membership Function-based Neural Network (FMFNN) incorporating a Fuzzy-Neural Interpolating Network is used to approximate the nonlinear mapping. Several FMFNN's are trained to be capable of tracking a moving object in the whole workspace along the line of sight. For an effective implementation of the proposed FMF network, an image feature selection process is investigated. Finally, several numerical examples are presented to show the validity of the proposed visual servoing method.

Key Words : Fuzzy-Neural Network(퍼지신경망), Visual Servoing(시각구동), FMFNN, FNIN.

1. 서 론

최근들어 로봇의 응용이 지능화됨에 따라 시각센서를 이용한 로봇의 제어에 많은 관심을 기울이고 있다[1~9]. 시각센서를 이용하게 되면 물체의 위치나 운동상태에 대한 사전 지식(previous knowledge) 없이도 임의의 방향으로 움직이는 물체를 집거나 추적할 수 있게 되어 용접선 추적, 정밀부품 조작, 칸베이어 추적, 우주 로봇의 원격 제어 등과 같은 여러 분야에 응용할 수 있다.

지금까지의 대다수 시각 로봇 시스템(visual robot system)은 실제 영상 특징(actual image feature)을 케환 신호(feedback signal)로 사용해 왔다[1~9]. 그 중 대다수 방법은 물체의 영상 특징량의 변화에 따른 카메라의 위치 변화량을

계산하기 위해 영상 특징 자코비안의 역(the inverse of the feature Jacobian)을 사용했다[1,3~6]. 그러나, 영상 특징 자코비안의 역을 이용하는 경우, 영상 특징의 변화량이 크게 되면 카메라의 이동량 오차도 크게 되는 단점이 있어 다른 보조 방법을 이용하여 이러한 오차를 보상해야 한다[3,4,5]. 또한, 이러한 보조 방법을 사용하더라도 영상 특징 자코비안을 이용하느데는 몇개의 부수적인 어려움이 있다. 첫째, 기존의 영상 특징 자코비안은 카메라를 핀홀 모델(pin-hole model)로 간주하였기 때문에 실제 카메라와는 약간 다른 특성을 나타낼 수 있다[3,4,5]. 둘째, 영상 특징 자코비안을 사용하는 경우는 물체와 카메라 사이의 거리를 알아야 하므로 실제 적용에 문제가 따른다. 거리를 알기 위해 로봇 제어기에 스테레오 비전(stereo vision)이나 레이저(laser)를 이용한 거리측정 장치를 부착하더라도 영상 특징 자코비안이 영상 특징 변화량에 민감하므로 추적 성능(tracking performance)은 영상 특징의 선택에 달려있다[1]. 끝으로, 영상 특징 자코비안이 특이(singular)인 경우엔 역이

*正會員：漢陽大 大學院 電子工學科 博士課程

**正會員：漢陽大 工大 電子工學科 教授·工博

서울大 新技術研究센터 研究員

接受日字：1994年 11月 19日

1次修正：1994年 4月 25日

존재하지 않으므로 영상 변화만으로는 로봇을 제어할 수 없게 된다.

한편, 동물이나 사람이 물건을 보고 접는 것을 살펴보면, 부잡하고 정밀한 계산없이도 본능적으로 가능함을 알 수 있다. 이러한 능력은 태어나면서부터 가지고 있으며 자라면서 반복적으로 학습되어 향상되는 것이다. 이 특성을 이용하기 위해, 몇몇 과학자들이 영상 특징을 이용할 뿐 아니라 반복 학습 능력을 갖는 새로운 제어 방법을 제안했다[2,7,8].

그중에서, Miller는 시각 구동(visual servoing)을 위해 CMAC(Cerebellar Model Arithmetic Computer) 메모리를 학습에 이용하는 '신경망을 이용한 학습 제어 시스템(a neural-network-based learning control system)'을 제안하였다. 이 제어 시스템은 로봇의 기구학(kinematics)이나 로봇에 대한 물체의 상대속도·자세 등과 같은 사전지식을 필요로 하지 않는다. 그러나 단순한 반복 작업을 위해 전체 작업 공간 중 어느 특정 부분만을 학습했을 경우, 일반적인 작업에 이용할 수 없고 환경이나 작업이 갑자기 바뀌는 경우에는 처음부터 다시 학습시켜야 한다는 단점이 있다.

그리고 Hashimoto 등은 로봇의 관절 형태나 기하학적인 크기에 상관없이 특정 자코비안을 배우도록 두개의 역전파 신경망(back-propagation neural network)을 기초로한 자기 구성 시각 구동 시스템(a self-organizing visual servo system)'을 제안하였다[8]. 그러나, 이 방법을 실제로 적용하려면 Miller의 방법과 마찬가지로 로봇의 전체 작업 공간(work space)을 모두 배워야만 하는 어려움이 있다. 그리고 역전파 신경망은 일반적으로 전역 최소값(global minimum)을 보장하지 않으므로, 이 방법을 실제 작업에 적용하기는 매우 힘들다.

본 논문에서는 지금까지의 기존 방법들의 단점을 보완하며 인간의 시각구동에 가까운 새로운 방법을 제안하고자 한다. 이를 위해 2장에서는 카메라와 물체 사이의 상대적인 거리 정보를 영상 특징과 그에 해당하는 카메라의 이동량을 알 수 있는 비선형 사영(nonlinear mapping)이 존재함을 보인다. 그리고 3장에서는 이러한 사영의 특정 형태(closed form)를 해석적으로 유도하는 대신 퍼지 소속 함수 신경망(Fuzzy Membership Function-based Neural Networks; FMFNN)과 퍼지 신경 보간망(Fuzzy-Neural Interpolating Network)[17,18]으로 근사화(approx-

imate)할 수 있음을 보이고, 4장에서는 이들을 이용한 새로운 구동 방법에 대해 알아본다.

본 논문에서는 FMFNN을 좀더 효율적으로 사용하기 위하여 영상 특징 선택 과정을 추가하였으며, 제안한 시작구동 방법의 타당성을 보이기 위해 몇 개의 예를 5장에서 보인다.

2. 영상 공간에서 수직좌표 공간으로의 비선형 변환

cX 를 카메라 좌표계 C 에서의 물체의 m 차 상태 위치 벡터라 하고, F 를 물체 영상(object image)의 n 차 특징 벡터(feature vector)라 하자. 그러면 cX 와 F 사이의 기구학 관계(kinematic relationship)는 일반적으로 다음과 같이 나타낼 수 있다.

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

여기에서 $I(\cdot)$ 는 ${}^cX \in R^m$ 에서 $F \in R^n$ 으로의 사영(mapping)이다. 만약 cX 에서 F 로의 사영이 일대일(one-to-one)이라면, 역기구학 관계(inverse kinematic relationship)는 다음과 같이 나타낼 수 있다.

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

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

한편, 영상 특징공간(feature space)과 카메라 공간(camera space) 사이의 관계는 영상 특징 자코비안(feature Jacobian)을 이용하여 나타낼 수 있다. $d{}^cX/dt$ 를 물체의 이동속도, dF/dt 를 시간에 대한 영상특징의 변화량이라 하면, 식(1)의 1차 근사식은 다음과 같다.

$$dF/dt = J({}^cX)dX/dt, \quad (3)$$

여기에서 $J({}^cX)$ 는 $\partial I({}^cX)/\partial {}^cX$ 로 정의된 $n \times m$ 행렬이다. 만약 행렬 J 가 full rank라면, $d{}^cX/dt$ 는 J 의 의사역(pseudo-inverse)인 $J^+({}^cX)$ 나타낼 수 있다.

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

식 (4)를 사용하는 경우, $J^+(^cX)$ 를 구하기 위해 카메라의 기하학적 광학 모델(geometric optic model)을 필요로 하는데 이를 해석적으로 정확히 구하기는 힘들므로 보통 간단한 핀홀 모델(pin-hole model)을 사용한다. 따라서 실제 응용하는 경우 모델링 정확도에 따라 제어 문제를 일으킬 수도 있다. 또한, 식(4)의 특징 자코비안의 각 요소는 카메라와 물체 사이의 상대적 거리인 cX 의 함수이기 때문에 이를 구하기 위해 물체의 CAD정보[1,3]나, 스테레오 비전이나 레이저을 이용한 거리 측정 등 보조방법을 필요로 한다. 그리고 로봇이 움직일 때마다 카메라와 물체 사이의 거리에 민감하므로 실제 적용하기가 힘들다. 이러한 문제점외에 물체가 바뀌면 기하학적 광학 관계가 다시 모델링되어야 하므로 $J({}^cX)$ 는 새로 구해져야 한다. 게다가 $J({}^cX)$ 가 특이(singular)면 영상 특징 자코비안의 역을 이용하는 방법은 로봇 제어에 이용할 수 없게 된다.

이러한 문제점을 극복하기 위해 cX 와 F 사이의 미분관계를 새롭게 표현하고자 한다. 이를 위해, δX 와 δF 를 각각 cX 와 F 의 미소 변화량이라 하면, 식(2)에서 다음 식을 얻을 수 있다.

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

여기에서 $G(F, \delta F)$ 는

$$\begin{aligned} G(F, \delta F) &= \lim_{N \rightarrow \infty} \sum_{k=1}^N (\partial^k I^{-1}(F) / \partial F^k) \delta F^k \quad (6) \end{aligned}$$

로 정의된다. 따라서 $\delta X = G(F, \delta F)$ 로 정의되고, 이를 이용하면 식(4)를 이용했을 때 발생하는 여러 문제점이 다음과 같은 이유때문에 해결된다; i) $G(F, \delta F)$ 는 카메라와 물체 사이의 기하학적 광학 모델을 필요치 않아 매번 계산하지 않아도 된다. ii) 역사영(inverse mapping)이 필요치 않아 특이 평가가 필요없다. iii) $G(F, \delta F)$ 는 F 와 δF 만의 함수이므로, 물체가 바뀌어도 새로 모델링할 필요가 없다. 그러

나, 이러한 좋은 특성에도 불구하고 $G(F, \delta F)$ 를 해석적으로 구하기가 힘들다. 따라서, 본 논문에서는 $G(F, \delta F)$ 를 계산식 형태로 구하는 대신 FMFNN을 이용하여 근사화하고자 한다.

3. 퍼지소속함수 신경망과 보간망[17,18]

입력 변수가 p 개이고 출력이 하나인 함수를 표현하기 위하여 다음과 같은 q 개의 퍼지 규칙을 생각해 보자.

$$R : \text{If } y_1 \text{ is } A_{i1}, y_2 \text{ is } A_{i2}, \dots, \text{and } y_p \text{ is } A_{ip}, \text{ then } u \text{ is } B_i, \text{ for } i=1,2,\dots,q \quad (7)$$

여기에서, $y_j (j=1,2,\dots,p)$ 는 입력 변수이고, u 는 싱글톤(singleton)소속 함수로 퍼지화된 출력 퍼지변수이다. 그리고 A_{ij} 와 B_i ($i=1,2,\dots,q, j=1,2,\dots,p$)는 각각 입출력 언어(퍼지집합) 변수이고, A_{ij} 와 B_i 의 소속함수를 각각 $\mu_{ij}^A(y_j)$, $\mu_i^B(u)$ 라 하자. 만약 $\mu_i^B(u)$ 를 모든 i 에 대하여 $u=\lambda_i$ 에 위치한 노말 싱글톤(normal singleton)이라고 하면, 추론을 위해 비퍼지화에 보통 사용되는 무게중심법을 적용하는 경우, 스칼라 출력 u 는 다음과 같이 구해진다.

$$u = \sum_{i=1}^q \lambda_i \frac{\Phi_i(y_1, y_2, \dots, y_p)}{\sum_{k=1}^q \Phi_k(y_1, y_2, \dots, y_p)} = \sum_{i=1}^q \lambda_i \Phi_i(\underline{y}) \quad (8)$$

여기에서 $\Phi_i(y_1, y_2, \dots, y_p)$, y_0 와 $\Phi_i(\underline{y})$ 는 다음과 같이 정의된다.

$$\Phi_i(y_1, y_2, \dots, y_p) = \min\{\mu_{ij}^A(y_j) | j=1,2,\dots,p\} \quad (9.1)$$

$$\underline{y} = (y_1, y_2, \dots, y_p) \quad (9.2)$$

$$\tilde{\Phi}_i(\underline{y}) = \frac{\Phi_i(y_1, y_2, \dots, y_p)}{\sum_{k=1}^q \Phi_k(y_1, y_2, \dots, y_p)} \quad (9.3)$$

여기에서 λ_i 는 학습시켜야 할 가중치(weight)이다. 식(8)을 살펴보면, 그 형태가 함수 근사화에 많이 사용되는 Radial Basis Function

(RBF)과 유사함을 알 수 있다[13]. 즉, 퍼지 규칙에서 유도되었음에도 불구하고 그 형태는 신경망과 유사하여, 퍼지 소속함수를 기본 함수(Basis Function)로 하고, 퍼지 규칙을 이용하여 가중치의 초기값을 정한 후, 학습에 의해 미세 조정하여 함수를 근사화할 수 있다. 이때 식(8)을 퍼지 소속 함수 신경망(Fuzzy Membership Function based Neural Network ; FMFNN)이라 한다. 식 (8)을 적용하여 함수를 근사화할 때 함수 출력력을 원하는 크기로 맞추기 위한 비례인자(scaling factor) K 와 함께 출력 노드에 아래와 같은 비선형 스칼라 함수 $g: R \rightarrow R$ 를 넣는다[8].

$$g(u) = (1 - \exp(-\beta_1 u)) / (1 + \exp(-\beta_1 u)). \quad (10)$$

여기에서 β_1 은 상수로서 출력 노드 함수를 만들기 위한 기울기이다. 식 (10)은 기존의 역전파 신경망(Back-Propagation Neural Network ; BPNN)에 널리 사용되는 시그모이드 함수(Sigmoid function)의 출력을 -1 에서 1 까지 확장한 함수이다. $f(\underline{y})$ 를 근사화될 스칼라 함수라 하고, $u(\underline{y})$ 를 $f(\underline{y})$ 의 근사값이라 하면, FMFNN을 이용한 함수의 근사값은

$$u(\underline{y}) = K g \left(\sum_{i=1}^q \lambda_i \Phi_i(\underline{y}) \right) \quad (11)$$

가 된다. 한편 성능지수 $J = 1/2(f(\underline{y}) - u(\underline{y}))^2$ 를 최소화하기 위해 기울기 하강법(gradient descent method)을 적용하면 학습 규칙(learning rule)은 다음과 같이 구할 수 있다.

$$\lambda_i^{t+1} = \lambda_i^t + K \eta_1 \beta_1 \{f(\underline{y}) - u^t(\underline{y})\} \{1 - (g \sum_{i=1}^q \lambda_i \Phi_i(\underline{y}))^2\} \Phi_i(\underline{y}) / 2, \quad (12)$$

여기에서 t 는 학습 횟수를 나타내는 정수이고, η_1 은 학습율이다. p 개의 입력과 하나의 스칼라 출력을 가진 FMFNN의 개략도는 그림 1과 같다.

FMFNN을 이용하면 비선형 함수를 근사화 할 수 있음에도 불구하고, 함수 근사화를 위해 입력변수가 많이 필요한 때는 퍼지 규칙이나

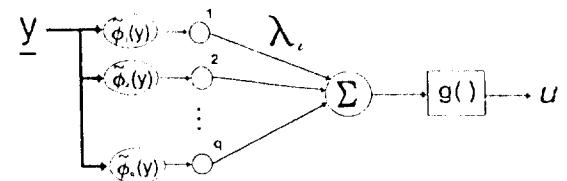


그림 1 FMFNN의 개략도

Fig. 1 The schematic diagram of an FMFNN

필요한 소속함수를 결정하는데 어려움이 따른다. 이러한 어려움을 극복하기 위하여 함수의 대표적인 값 몇개를 배운 후, 나머지는 이 대표값으로 대치하는 퍼지 신경 보간망(fuzzy-neural interpolating network)이 제안되었다 [17,18].

보간망은 전체 성능지수

$$\Delta J_i = \sum_{(\underline{y} \in S_i)} [u(\underline{y}) - f(\underline{y})]^2 \quad (13)$$

를 최소화하기 위해 기울기 하강법에 의해 가중치 r_i 를 다음과 같이 수정한다.

$$r_i^{t+1} = r_i^t + k \beta_1 \beta_2 \eta_2 \pi_i(\underline{y}) u(\underline{y}) [1 - f(\underline{y})]^2 \hat{g}(\pi_i(\underline{y})) \\ r_i^t \{1 - \hat{g}(\pi_i(\underline{y}) r_i)\} \sum_{\underline{y} \in S_i} (u(\underline{y}) - f(\underline{y})) \quad (14)$$

여기에서 $0 < \eta_2 \leq 1$ 는 학습률이며, $\hat{g}(\cdot)$ 은 기울기가 β_2 인 시그모이드 함수이다. 보간망의 전체 구조는 그림 2에서 보듯이 FMFNN의 가중치 λ_i 와 소속함수 Φ_i 가 보간망에서는 r_i 와 π_i 로 바뀐 것이다.

4. FMFNN을 이용한 시각구동 방법

$G(F, \delta F)$ 를 해석적으로 구하기 힘들기 때문에 앞 절에서 설명한 FMFNN과 퍼지 신경 보간망을 이용하여 $G(F, \delta F)$ 를 구하기로 한다.

물체의 3차원 위치 및 자세를 표현하기 위해 적어도 6개의 특징이 필요한데, 이는 다음과 같이 나타낼 수 있다.

6가지를 이용하기로 한다.

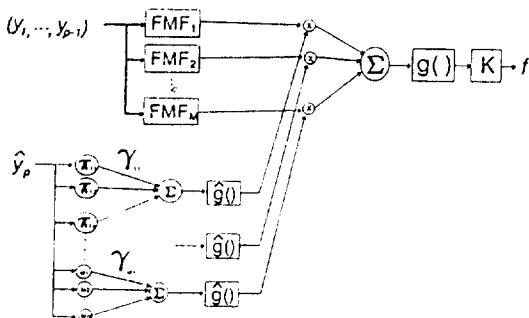


그림 2 퍼지 신경 보간망의 개략도

Fig. 2 The schematic diagram of the Fuzzy-Neural Interpolating Network

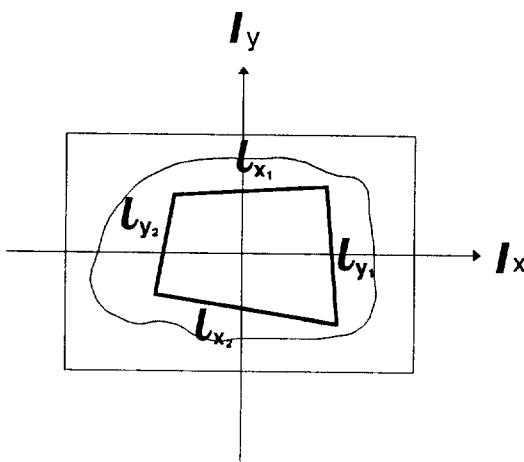


그림 3 물체 영상에서의 사각형

Fig. 3 A quadrangle in the object image

$$\delta x_i = G_i(F_1, F_2, \dots, F_6, \delta F_1, \delta F_2, \dots, \delta F_6), \quad \text{for } i=1,2,\dots,6. \quad (15)$$

$(\delta X_1, \delta X_2, \delta X_3)$ 와 $(\delta X_4, \delta X_5, \delta X_6)$ 을 카메라 좌표계 $^cX, ^cY, ^cZ$ 각 축 방향의 위치와 자세의 변화량이라 하자. 그리고 $^oX, ^oY, ^oZ$ 를 물체 좌표계에서의 X, Y, Z 축이라 하자. 영상 특징과 물체의 위치 및 자세 사이의 관계를 살펴보기 위해 그림 3과 같이 화면에 비친 사각형 물체에 대해 생각하기로 한다. 이 사각형을 이용하여 구할 수 있는 영상 특징은 많으나 다음의

- F_1 =영상에서의 사각형의 무게 중심의 x 좌표
- F_2 =영상에서의 사각형의 무게 중심의 y 좌표
- F_3 =현재 영상에서의 사각형의 크기÷기준 영상에서의 사각형의 크기
- F_4 =영상에서 사각형의 마주 보는 두 수직 대변의 길이 비
- F_5 =영상에서 사각형의 마주 보는 두 수평 대변의 길이 비
- F_6 =영상에서 사각형의 최소 관성 주축(the axis of minimum moment of inertia)의 각도

$\delta F_i (i=1,2,\dots,6)$ 은 기준 영상에서의 영상 특징 값 F_i^r 과 현재 영상에서의 영상 특징 값 F_i 사이의 차이다. F_i^r 은 목표 위치 $(^oP_{tx}, ^oP_{ty}, ^oP_{tz})$ 에서 측정된 F_i 값이다. 일반적으로 δX_1 과 δX_2 는 주로 $(F_1, F_3, \delta F_1)$ 과 $(F_2, F_3, \delta F_2)$ 의 영향을 받고 δX_3 는 δF_3 에 주로 영향을 받는다. 이러한 관찰을 토대로 $\delta X_1, \delta X_2, \delta X_3$ 는 각각 $\delta X_1 = G_1(F_1, F_3, \delta F_1), \delta X_2 = G_2(F_2, F_3, \delta F_2), \delta X_3 = G_3(\delta F_3)$ 로 쓸 수 있다. 따라서 다음과 같이 변수 d_i 를 정의하면 δX_i 에 영향을 미치는 F_i 와 F_3 의 관계는 쉽게 표현될 수 있다.

d_i =물체 좌표계(X, Y, Z)에서의 카메라 위치 벡터와 X_i 좌표축 사이의 각도

i 가 1,2인 경우엔 d_i 는 다음과 같이 나타낼 수 있다.

$$d_i = \tan^{-1}(f\sqrt{F_3}/[K_i F_i (\sqrt{F_3} - 1)]), \quad \text{for } i=1 \text{ and } 2 \quad (16)$$

여기에서 K_i 는 영상 크기 계수(image scale factor), f 는 카메라의 촛점거리이다. 따라서 $i=1,2$ 인 경우는 $\delta X_i = G_i(d_i, \delta F_i)$ 로 간단히 표현할 수 있게 된다. 이와 유사하게 $i=4,5$ 인 경우에도 $\delta X_i = G_i(d_i, \delta F_i)$ 로 나타낼 수 있다.

영상 특징의 설정이 끝났으므로, 움직이는 물체 추적을 위한 입출력 학습 데이터를 결정하는 방법에 대해 알아보자. 움직이는 물체를 추적하기 위해 FMFNN은 전체 작업 공간에서 시선

(line of sight)을 따라 움직이도록 학습되어야 한다. 그러나 카메라를 항상 물체쪽을 바라보며 움직이도록 하면, 물체에 바짝 다가서기 전까지는 최대 속도로 움직이고 어느 일정거리 이내에서만 서서히 움직이도록 하면 된다. 이러한 어느 일정거리를 가시영역(visible region ; VR)이라 하고 그림 4와 같이 표현하기로 한다. 여기에서는 VR의 높이를 카메라가 한 샘플링 시간동안 시선 방향으로 최대 움직일 수 있는 거리로 결정하고 VR의 제일 윗면을 TVR이라 한다. TVR에 있는 위치들과 목표위치 (${}^0P_{tx}$, ${}^0P_{ty}$, ${}^0P_{tz}$)를 연

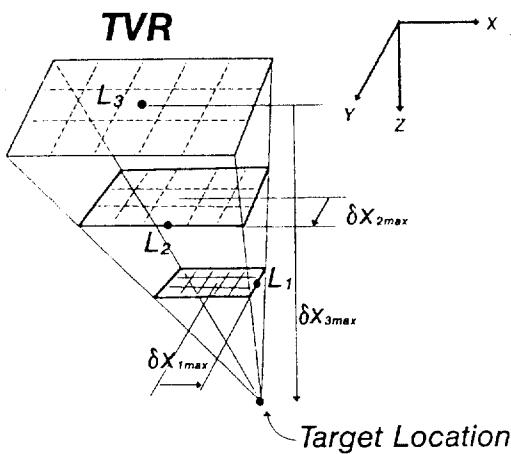


그림 4 가시 영역과 TVR

Fig. 4 Visible range(VR)and TVR

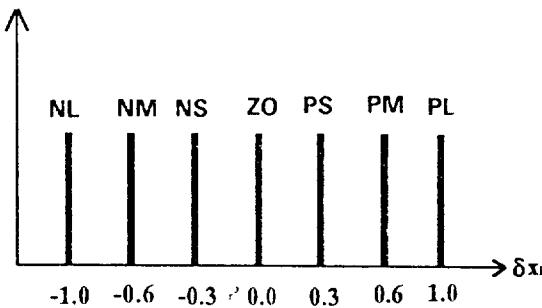


그림 5 퍼지 규칙의 THEN부분에 사용된 싱글톤 소속함수

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

결하는 직선 경로를 이용하여 FMFNN의 학습데이터를 만든다. 즉, 카메라는 물체를 바라보며 d_i 의 각도를 유지하며 물체로 다가 오다가 VR에 다다르면 FMFNN에 의해 학습된 변화량만큼만 움직여 목표점에 정지하게 된다. 이와같이 하면, 전체 영역을 모두 학습할 필요없이 VR만을 학습하므로 학습 데이터가 상당히 줄어든다. 이 원리는 인간이 자동차 운전을 하는 것과 유사한데, 목표점이 먼 경우에는 그 방향만 유지하고 다가간후 목표점 근처에서 서서히 속도를 줄여원하는 목표점에서 서는 것과 같다. 이때 목표점과 현재 위치 사이의 거리는 인간이 느끼는 물체의 크기 비(본 논문에서 사용한 영상 특징 F_3)로 대강 결정되며 운전 경력이 많을수록 이 거리 예측이 정확해지는데, 이는 FMFNN의 초기 퍼지 규칙이 학습에 의해 정밀조정 되는 것과 같다.

이러한 인간의 시각 구동 원리를 이용하여 제안한 제어기의 입출력 학습 데이터를 생성한다. 만약 카메라와 물체 사이의 거리가 샘플링 시간당 움직일 수 있는 최대 이동 거리보다 멀면 카메라는 최대 속도로 물체쪽으로 다가가고, 그렇지 않으면 카메라는 천천히 움직이도록 한다. 따라서 그림 4의 VR에서의 입출력 데이터를 이용하여 학습한다. VR에서의 원하는 입출력 데이터를 추출하기 위해 TVR을 $M_1 \times M_2$ 의 격자로 나누고, 각 격자의 중심에서 목표점까지를 연결하는 직선 경로를 만든다. 이렇게하면 VR은 $M_1 \times M_2$ 의 부공간(subspace)으로 나뉠 수 있다. 원하는 입출력 데이터는 각 부공간의 중심을 지나는 직선 경로에서 얻을 수 있는데, 각 직선에서의 샘플링 갯수는 사용될 퍼지 값의 갯수에 따라 결정된다. 샘플링 위치를 δX_i 라 하면, 각 δX_i 에서의 F_i 와 δF_i ($i=1,2,\dots,6$)을 알 수 있으므로 이를 학습 데이터로 사용한다. 한편, 비선형 사영 $G_i(d_i, \delta F_i)$ 에서 $G_1(d_1, \delta F_1)$ 과 $G_2(d_2, \delta F_2)$ 에 사용되는 입력 변수 d_1, d_2 는 직선 경로에서는 일정하므로 δX_1 과 δX_2 를 만드는 퍼지 규칙에는 사용되지 않는다. 따라서 G_1, G_2 를 근사화하는데 δF_1 과 δF_2 만이 사용된다. 그러나 각 직선 경로를 따라가기 위한 퍼지 규칙은 각각 조금씩 다르다.

이러한 복잡성을 피하기 위하여 각 직선 경로마다 소속함수는 다르나 퍼지 규칙을 같이 사용한다. 이러한 퍼지 규칙의 예는 다음과 같다.

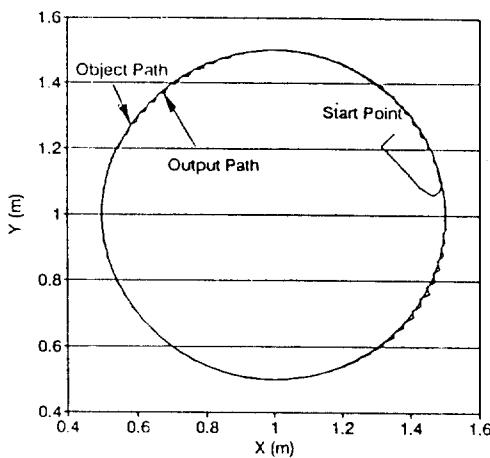


그림 6 물체가 $X^2 + Y^2 = (500\text{mm})^2$ 의 원형 경로를 따라 2rpm 의 속도로 움직일 때의 시각구동 성능

Fig. 6 Tracking performances of our proposed visual controller for the case when the object moves around a circular path $X^2 + Y^2 = (500\text{mm})^2$ with the angular velocity of 2rpm .

If δF_i is Negative Large, then δx_i is Positive large, or

If δF_i is Negative Medium, then δx_i is Positive Medium, or

If δF_i is Negative Small, then δx_i is Positive Small, or

If δF_i is Zero, then δx_i is Zero, or

If δF_i is Positive Small, then δx_i is Negative Small, or

If δF_i is Positive Medium, then δx_i is Negative Medium, or

If δF_i is Positive Large, then δx_i is Negative Large.

그림 1에서 ϕ_i 는 IF부분의 소속함수이고, 초기 λ_i 는 퍼지 규칙의 THEN 부분의 소속함수이다. 그리고 q 는 퍼지값의 갯수로서 본 논문의 경우 'Positive Large(PL)', 'Positive Medium(PM)', 'Positive Small(PS)', 'Zero(ZE)', 'Negative Small(NS)', 'Negative Medium(NM)', 'Negative Large(ML)'의 7개이므로 q 는 7이다.

주어진 퍼지 규칙의 THEN 부분 소속 함수는

싱글톤으로 그림 6와 같이 초기에 주어진 후, 주어진 δF_i 에 대해 원하는 δX_i 가 나오도록 식 (14)처럼 해당 소속 함수의 중심 위치를 이동시킨다. 예를 들어 δF_i 가 NL과 NM사이의 값이나, 퍼지 규칙에 의해 계산된 δX_i 가 원하는 δX_i 와 다를 때, 식 (14)에 의해 THEN부분 소속함수인 PL과 PM의 중심 위치가 적절히 이동된다.

5. 모의실험

FMFNN을 이용한 시각 구동 방법의 성능을 보기 위해 컴퓨터 모의실험을 수행했다. 모의실험에는 물체와 카메라 사이의 기구학 관계(Kinematic relation)을 고려하고, 카메라는 핀홀(pin-hole) 렌즈로 모델링한다. 실영상(real image)에서의 노이즈(noise) 성분을 모델링하기 위해 이상적으로 추출된 영상특징에 노이즈를 추가하였다. 또한 계산을 간단히 하기 위하여 물체의 위치만을 고려하기로 한다.

모의실험을 위해 물체는 $0.2\text{m} \times 0.2\text{m}$ 사각형으로 주어졌고, 핀홀 카메라의 촛점거리와 영상 크기 인수(image scale factor)는 각각 14mm 와 0.05mm/pixel 이라 가정한다. 그리고 기준 영상을 위한 목표위치 (${}^0P_{tx}, {}^0P_{ty}, {}^0P_{tz}$)는 물체좌표계에서 $(0.0\text{m}, 0.0\text{m}, 0.03\text{m})$ 로 한다. 200msec 샘플링 시간동안 카메라가 X, Y, Z 축을 따라 움직일 수 있는 최대 이동거리 $\delta X_{max}, \delta Y_{max}, \delta Z_{max}$ 는 모두 50mm 라 한다. 4절에서의 영상특징 선정과정에 의해 영상특징 F_1, F_2 는 각각 물체영상의 무게중심의 x, y 좌표이고, F_3 는 목표위치 (${}^0P_{tx}, {}^0P_{ty}, {}^0P_{tz}$)와 현재위치에서 얻은 물체영상의 크기비이다. 그러면 δF_{1max} 와 δF_{2max} 는 $(0.05\text{m}, 0.0\text{m}, 0.35\text{m})$ 와 $(0.0\text{m}, 0.05\text{m}, 0.35\text{m})$ 에서 모두 41pixel 이 되고 δF_{3max} 는 $(0.0\text{m}, 0.0\text{m}, 0.35\text{m})$ 에서 0.9272가 된다. 모의 실험에서는 M_1 과 M_2 를 모두 7로 한다. 즉 가시영역(VR)은 7×7 의 부영역으로 나뉘고 이들은 모두 같은 크기이다. 그리고 M_3 는 1로 가정한다. 식 (10)에서의 시그모이드(sigmoid) 함수의 기울기 β_1 은 0.5, 학습률 η_1 은 3.0이다. δF_i 와 원하는 출력 δX_{id} 의 관계를 배우기 위해 FMFNN은 오차(error)의 제곱이 0.0001보다 작거나 같아질 때까지 학습한다. 각 학습에 있어서 학습횟수는 250을 넘지 않았다. 입출력 관계를 배우기 위한 250회의 반복 학습은 일반적인 신경망을 이용하는

방법과 비교하면 상당히 적은 횟수라 할 수 있다. 49개의 FMFNN 학습이 끝난 후 보간망을 학습시킨다. 이를 위해 식 (14)에서 사용된 퍼지 신경 보간망의 시그모이드 함수의 기울기 β_2 는 0.5, 학습률 η_2 는 5.0으로 한다.

FMFNN을 이용한 시각 구동 방법의 능력을 보기 위해 학습이 안되어 있는 경로를 따라 움직이는 물체를 추적하기로 한다. 이를 위해 물체가 $X^2 + Y^2 = (500\text{mm})^2$ 의 원형 경로를 따라 2rpm 으로 움직이는 경우를 고려한다.

그림 6은 물체 궤적과 카메라의 출력 궤적이다. 그림에서 보듯이 경로 오차는 상당히 적다. 따라서 보간망을 가진 FMFNN은 전체 작업 영역 중 작우 부분을 배우면 추가 학습없이 임의의 경로를 따라 움직이는 물체를 추적할 수 있음을

알 수 있다.

그림 7은 물체 영상에 노이즈가 있을 때, FMFNN을 이용한 방법과 기존의 영상 특징 자코비안을 이용하는 방법에 의한 로봇 제어기의 경로 추종 성능이다. 그림에서 보면 영상 특징 자코비안의 역을 이용하는 방법은 노이즈에 강함을 알 수 있다. 이러한 모의 실험을 통해 FMFNN을 이용한 시각구동 방법이 성공적으로 동작함을 알 수 있고 다른 방법에 비해 노이즈에 강하고, 로봇의 전체 작업공간에서 추적 성능이 우수함을 알 수 있다. 또한 제안한 시각 구동 방법은 설계가 간단하고, 학습 속도가 빠르며, 학습한 내용을 재생(retrieving)할 때 계산이 간단하기 때문에 기존의 제어기에서도 쉽게 구현할 수 있을 것이다.

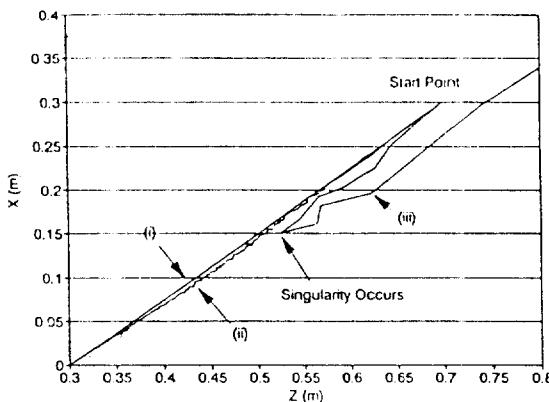


그림 7 (a)영상특징 자코비안을 이용한 제어기의 경로 추종 성능

- (i) 노이즈가 없을 경우
- (ii) 영상 특징 F_i 가 $0.98F_i$ 에서 $1.02F_i$ 까지 변하는 경우
- (iii) 영상 특징 F_i 가 $0.95F_i$ 에서 $1.05F_i$ 까지 변하는 경우

Fig. 7 (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 then the image feature values F_i are randomly varying to $0.98F_i$ thru $1.02F_i$
- (iii) the case then the image feature values F_i are randomly varying to $0.95F_i$ thru $1.05F_i$

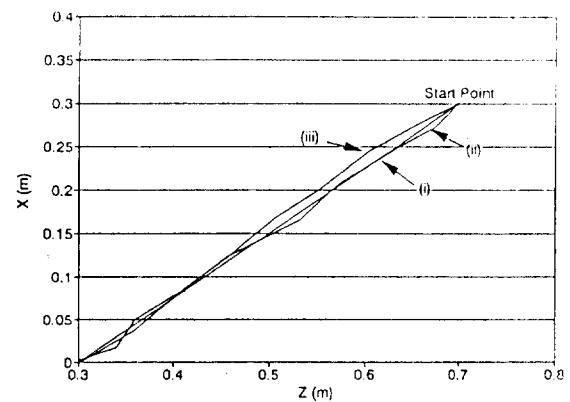


그림 7 (b)FMFNN과 보간망을 이용한 제어기의 경로 추종 성능

- (i) 노이즈가 없을 경우
- (ii) 영상 특징 F_i 가 $0.98F_i$ 에서 $1.02F_i$ 까지 변하는 경우
- (iii) 영상 특징 F_i 가 $0.95F_i$ 에서 $1.05F_i$ 까지 변하는 경우

Fig. 7 (b)Path following performances for the controller using the FMFNN with the interpolating network;

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

5. 결 론

본 논문에서는 FMFNN을 이용한 시각구동방법을 제안했다. 사용된 FMFNN을 효과적으로 적용하기 위해 영상특징을 선정하는 방법에 대해 알아 보았다. 모의실험을 통해 FMFNN에 의한 시각구동방법이 성공적으로 동작함을 보였고, 제안한 방법이 경로정확도, 노이즈에 대한 강인성, 전체 로봇 작업 공간에서 이동 물체에 대한 추적성능 등에서 다른 방법보다 우수하다는 점을 보였다. 또한 본 방법은 제어기 설계가 쉽고, 학습이 빠르며, 학습내용 재생시 계산이 간단하기 때문에 기존의 제어기에 쉽게 적용할 수 있다. 그러나, 계산 시간 지연(computational time delay)을 보상하는 것과 로봇 동역학(dynamics)을 고려한 실험이 추후 과제로 남아있다.

참 고 문 헌

- [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] 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 – 167, April.1987.
- [3] 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,
- [4] A.C.Sanderson and L.E.Weiss, "Image–based visual servo control of robots," Proc. of SPIE, vol.360, pp.164 – 169, Aug.1982.
- [5] 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.
- [6] K.Hashimoto *et. al.*, "Manipulator control with image–based visual servo," Proc. of IEEE Int. Conf. on Robotics and Automation (Sacramento, USA), pp.2267 – 2272, 1991.
- [7] W.T.Miller, "Real–Time Application of Neural Networks for Sensed–Based Control of Robots with Vision," IEEE Trans. on system, Man and Cybernetics, vol.SMC – 19, no.4, pp.825 – 831, July/Aug. 1989.
- [8] 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.
- [9] I.H.Suh, T.W.Kim *et. al.*, "Visual Servoing by a Fuzzy Reasoning Method," Proc. of IEEE/RST Int. Workshop on Robotics and Systems(Osaka, Japan), pp.111 – 116, Nov. 1991.
- [10] T.Poggio and F.Girosi, "Regularization algorithms for learning that are equivalent to multilayer networks," Science, vol.247, pp. 978 – 982, 1990.
- [11] T.D.Sanger, "A Tree–Structured Adaptive Network for Function Approximation in High–Dimensional spaces," IEEE Trans. on Neural Network, vol.2, no.2, pp.285 – 293, March. 1991.
- [12] D.E.Rumelhart *et. al.*, "Learning internal representations by error propagation," in Parallel Distributed Processing, Cambridge, MA : MIT Press, Ch.8, pp318 – 336, 1986.
- [13] S.Chen, C.F.N.Cowan and P.M.Grant, "Orthogonal least square learning algorithm for radial basis function networks," IEEE Trans. on Neural Networks, vol.2, no.2, pp. 302 – 309, March. 1991.
- [14] K.S.Narendra and K.Paithasarathy, "Identification and Control of Dynamical Systems using Neural networks," IEEE Trans. on Neural Networks, vol.1, no.1, pp.4 – 27, March. 1990
- [15] W.Pedrycz, Fuzzy control and Fuzzy systems, Research Studies Prss LTD., 1989.
- [16] G.Strang, Linear Algebra and its applications, 3rd Ed., Academic Press, 1988
- [17] 서일홍, 김태원, "퍼지 신경망을 이용한 비선형 함수 근사화," 한국 퍼지시스템학회 논문지, vol.2, no.4, pp.17 – 24, 1992.

[18] I.H.Suh and T.W.Kim, "Nonlinear Function Approximation by Fuzzy-Neural Interpolat-

ing Networks", Proc. of the 5th IFSA World Congress(Seoul, Korea), pp.1177-1180, 1993.

저자소개

김태원(金兌垣)

1965년 12월 28일생. 1988년 한양대 전기공학과 졸업. 1990년 동대학원 전기공학과 졸업(석사). 현재 한양대 대학원 전자공학과 박사과정.



서일홍(徐一弘)

1955년 4월 16일생. 1977년 서울대 공대 전자공학과 졸업. 1982년 한국 과학기술원 전기 및 전자공학과 졸업(공박). 1982년 대우중공업 기술 연구소 근무. 1987~88년 미국 미시간대 객원연구원. 현재 한양대 공대 전자공학과 교수.

