

<학술논문>

DOI:10.3795/KSME-A.2010.34.4.399

## 손 동작을 모사하기 위한 신경회로망과 커널 회귀의 모델링 비교 연구<sup>§</sup>

양학진\* · 김형태\* · 김성근\*<sup>†</sup>

\* 호서대학교 자동차공학과

### Comparative Study of Modeling of Hand Motion by Neural Network and Kernel Regression

Hac Jin Yang\*, Hyung Tae Kim\* and Seong Kun Kim\*<sup>†</sup>

\* Dept. of Automotive Engineering, Hoseo Univ.

(Received June 29, 2009 ; Revised February 10, 2010 ; Accepted February 17, 2010)

**Key Words:** Hand Motion(손 동작), Neural Network(신경 회로망), Kernel Regression(커널 회귀)

**초록:** 강력한 파지와 정밀 조작이 가능한 인간형 로봇 손에 대한 연구는 인간의 손동작을 파악하여 메커니즘을 분석하고, 로봇 손에 적절하게 응용하여야 한다. 본 논문에서는 최소의 자유도를 적용한 실용적인 인간형 로봇 손의 파지 동작을 모사하고자, 고속카메라를 사용하여 인간의 손동작에 대한 움직임을 추출하고, 이를 분석하였다. 이러한 촬영 데이터를 필터링하여 실험 데이터를 얻었으며, 이를 활용한 수학적 모델을 구하였다. 또한, 말절골(DIP)은 중절골(PIP) 및 기절골(MCP)의 움직임과 비선형 관계 모델을 고찰하여, 신경회로망 및 커널 회귀 모델을 사용한 인간형 로봇 손의 파지 모델을 얻었다. 신경회로망과 커널 회귀를 이용한 과정을 비교함으로써, 커널 회귀 알고리즘을 통한 모델링이 실험 데이터와의 근접성이 우수한 유효 모델임을 입증하였다.

**Abstract:** The grasping motion of a person's hand for a simplified degree of freedom was modeled by using the photographic motion measured by a high-speed camera. The mathematical expression of distal interphalangeal (DIP) motion was developed by using relation models of the metacarpophalangeal (MCP) and proximal interphalangeal (PIP) motions to reduce the degree of freedom. The mathematical expression for humanoid-hand operation obtained using a learning algorithm with a neural network and using a kernel regression model were compared. A feasible model of hand operation was obtained on the basis of comparative data analysis by using the kernel regression model.

#### 1. 서 론

인간형 로봇 손은 다른 로봇 손과 달리 불특정 환경 및 도구에 대한 적응이 쉽고, 비교적 강력한 파지와 정밀 조작이 가능하며, 외형상 사람의 손과 유사하여 거부감이 적은 장점이 있다. 이러한 인간형 로봇 손에 대한 연구는 인간의 손동작을 파악하여 메커니즘을 분석하고, 로봇 손에 적용시킬 수 있어야 한다.

인간의 손은 유연한 작업을 하기 위하여 일반 손가락(엄지 손가락을 제외한 나머지 손가락)은 각각 5

자유도, 엄지 손가락은 4 자유도로 총 24개의 자유도로 구성되어 있으며, 이러한 손으로 정밀 조작 및 비교적 강력한 파지 등의 유연한 작업 능력을 보여주고 있다.

이러한 자유도를 로봇 손에 실용적으로 적용하기에는 형상과 복잡도의 크기가 너무 커지는 단점이 있다. 따라서 자유도를 줄이는 방법(DLR II,<sup>(1)</sup> Gifu Hand II<sup>(2)</sup>)과 메커니즘을 구현하는 데 필요한 구동 장치를 손 외부에 장착함으로써 형상을 작게 하는 방법(Utah/M.I.T Hand,<sup>(3)</sup> Shadow Hand<sup>(4)</sup>)으로 연구가 진행되고 있다. 또한, 로봇 손을 실현하기 위해서 물체의 파지 및 조작에 관한 연구가 이루어졌으며,<sup>(5)</sup> 손가락 표면을 이용하는 물체의 파지 및 조작에 관한 운동학 및 형상 물체와 손가락 표면의 접촉 문제를 해석하는 연

§ 이 논문은 대한기계학회 2009년도 충청지부 춘계학술대회 (2009. 5. 15., 대전컨벤션센터) 발표논문임

† Corresponding Author, kimskun@hoseo.edu

구도 진행되고 있다.<sup>(6)</sup> 하지만 이러한 로봇 손 동작은 인간 손에 비하여 안전성 및 정밀성이 떨어지므로, 인간의 동작을 적절히 모방하여 장점을 활용하는 것이 필요하므로, 여기서는 자유도간의 상관관계를 응용하여 모델을 구축하는 시도를 하였다.

본 논문에서는 (1) 고속카메라를 이용하여 손 동작에 대한 실험 데이터를 추출한다. (2) 선형 모델의 가능성을 검토하기 위해 선형 함수를 도출한다. (3) 신경회로망(Neural Network)과 커널 회귀(Kernel Regression)<sup>(7)</sup> 알고리즘을 이용하여 비선형 모델을 도출한다. (4) 위의 실험데이터와 데이터 검증용 선형함수 그리고 비선형함수(신경회로망, 커널회귀)를 비교함으로써 손 동작에 대하여 실용적 적용이 가장 가능한 상관 모델을 찾을 수 있으며, 이 과정을 통하여 손 동작 모델을 구성하고자 한다.

## 2. 사람 손 동작 고찰

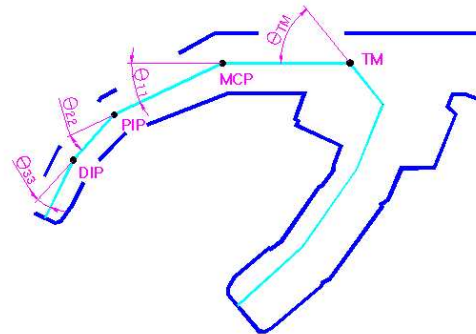
### 2.1 실험 방법

사람의 손가락은 크게 일반 손가락과 엄지 손가락으로 나눌 수 있으며, 일반 손가락의 구성은 Fig. 1과 같이 손바닥과 연결된 기절골(MCP), 중절골(PIP), 말절골(DIP)로 되어 있다. 말절골과 중절골은 1 자유도로 경첩 관절이며, 기절골은 3 자유도로 경첩 관절과 절구 관절을 형성하고 있다. 위와 같이 구성된 손의 움직임을 고찰하고, 동작 패턴을 설정하고 관절간의 관계를 파악함으로써 관절간의 상관관계를 기반으로 하는 수학적

모델을 확립하고 로봇 손에 적용시킬 수 있다고 판단하였다.

Fig. 1에서와 같이 각 관절을 연결하여 각 관절에 대하여  $\theta_{TM}$ ,  $\theta_{11}$ ,  $\theta_{22}$  그리고  $\theta_{33}$ 의 최소 자유도를 정의하였다. 이 각도에 대한 기구학적인 모델은 각 사람의 손 관절 근육과 동작 패턴에 따라 각기 달라지는 복잡성과 다양성을 갖게 되므로, 본 연구에서는 기구학적 모델링의 접근 방식 대신에 동작측정 데이터를 통한 소프트 모델링 방식을 취하였다.

고속카메라(Phantom V4.3-4 기가 카메라)를 이용하여 실험자의 손가락 관절(TM, MCP, PIP, DIP)을 표시하고 줍 운동을 반복함으로써 촬영 데이터를 추출하였으며, 촬영 데이터를 1회 줍 운동 구간씩

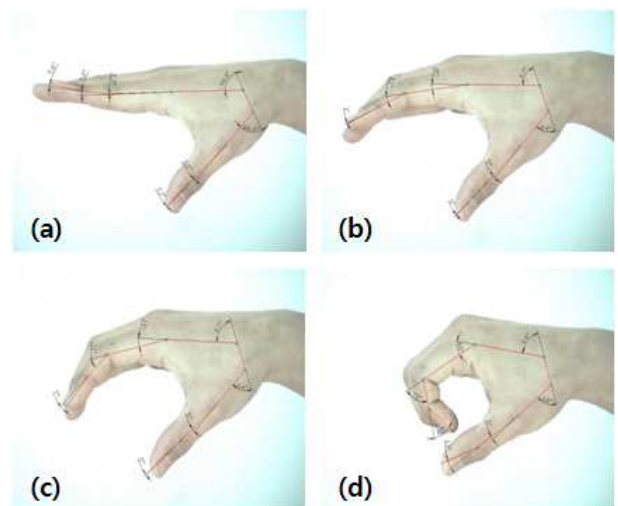


**Fig. 1** Geometry of a human hand -  $\theta_{TM}$ ,  $\theta_{11}$ ,  $\theta_{22}$  and  $\theta_{33}$  are the joints of MCP(Metacarpophalangeal), PIP(Proximal Interphalangeal) and DIP(Distal Interphalangeal), respectively

**Table 1** Measured data of the degree( $\theta_{TM}$ ,  $\theta_{11}$ ,  $\theta_{22}$  and  $\theta_{33}$ )

( Unit : ° )

| No | X             |               |               |               | No | Y             |               |               |               |
|----|---------------|---------------|---------------|---------------|----|---------------|---------------|---------------|---------------|
|    | $\theta_{TM}$ | $\theta_{11}$ | $\theta_{22}$ | $\theta_{33}$ |    | $\theta_{TM}$ | $\theta_{11}$ | $\theta_{22}$ | $\theta_{33}$ |
| 1  | 64            | 47            | 82            | 58            | 11 | 66            | 48            | 90            | 57            |
| 2  | 61            | 33            | 82            | 52            | 12 | 67            | 50            | 97            | 61            |
| 3  | 61            | 50            | 89            | 62            | 13 | 58            | 53            | 83            | 56            |
| 4  | 61            | 61            | 92            | 68            | 14 | 64            | 37            | 49            | 40            |
| 5  | 59            | 11            | 48            | 31            | 15 | 60            | 15            | 16            | 16            |
| 6  | 59            | 22            | 69            | 45            | 16 | 61            | 34            | 47            | 40            |
| 7  | 58            | 39            | 83            | 52            | 17 | 60            | 41            | 74            | 45            |
| 8  | 59            | 53            | 91            | 64            | 18 | 68            | 31            | 59            | 41            |
| 9  | 59            | 26            | 59            | 35            | 19 | 68            | 39            | 74            | 44            |
| 10 | 58            | 37            | 75            | 47            | 20 | 65            | 22            | 13            | 22            |



**Fig. 2** Photographic motion by high-speed camera (Phantom V4.3-4)

나누고, 구간당 10등분하여 각 관절의 위치 데이터를 얻었다(Fig. 2). Table 1은 3명의 실험자가 각각 줍 운동을 반복하면서 얻은 측정 데이터의 일부를 나타낸다.

2.2 수학적 모델

각 관절에 대한 측정 데이터를 이용하여 산출된 각도 데이터들은 비슷한 곡선의 형태를 보였으나, 몇몇 군데에서 각도의 변화가 심한 것을 알 수 있었다. 이러한 각도 변화는 손 동작 자체에서 나온 것이 아니라, 촬영중에 생기는 불연속성과 개인 동작 특이성에 의해서 생기는 것으로 판단하고, 이를 필터링하기 위한 모델을 구성하였다.

이러한 각도 변화량( $\Delta\theta_{TM11,22,33}$ )은 일반성을 갖는 과지 동작 모델을 적용하는 데 문제가 있으므로 각도 변화량(식 (1))에 대한 기울기 필터링을 적용하여 모델 학습데이터를 구성하였다(Fig. 3).

$$\Delta\theta = \frac{\theta_i - \theta_{i-1}}{\theta_{(i)interval} - \theta_{(i-1)interval}} \quad (i = 1, 2, 3, \dots, 10) \quad (1)$$

$$\because \theta_{(i)interval} - \theta_{(i-1)interval} = 1$$

$$\therefore \Delta\theta = \theta_i - \theta_{i-1}$$

여기서,  $\theta_{(i)interval} - \theta_{(i-1)interval} = 1$ 은 촬영 데이터에서 구간을 균등분하여 위치 데이터를 생성하였기 때문이며,  $\theta_0$ 은 구간 시작 시점을 의미한다.

이러한 부적절한 데이터들을 제거하기 위하여 다음 식 (2)과 같이 범위를 선정하였다.

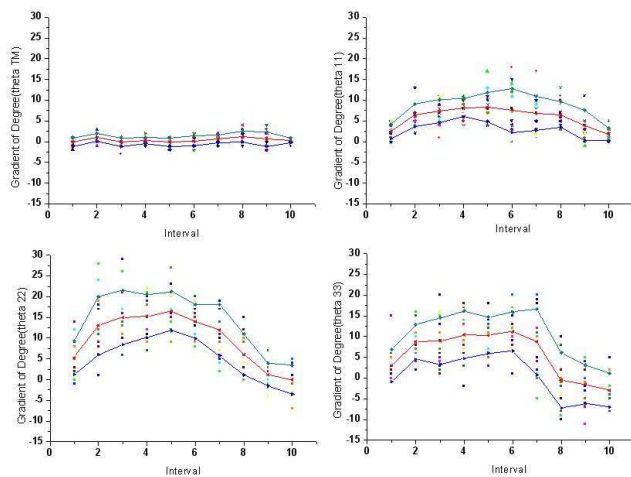


Fig. 3 Gradient of the degree( $\theta_{TM}$ ,  $\theta_{11}$ ,  $\theta_{22}$  and  $\theta_{33}$ )

$$f'_{avar}(i) - \sigma_f \leq f'(i) \leq f'_{avar}(i) + \sigma_f \quad (2)$$

여기서,  $i$ 번째 각도 함수를  $f(i)$ 라 하면,  $f(i)$ 의 기울기는  $f'(i) = (y_i - y_{i-1}) / (x_i - x_{i-1})$ 로서,  $i$ 번째 등분에 대한 각도 측정데이터( $y_i$ )와  $(i-1)$ 번째 등분에 대한 각도 측정데이터( $y_{i-1}$ )로 계산할 수 있다.  $\sigma_f$ 는  $f(i)$ 의 기울기에 대한 표준편차로서 측정 데이터의 신뢰 수준을 68.27%로 하여 처리하였으며, 이 신뢰 구간에 있는 데이터를 검증 데이터로 인식하였다.

$\theta_{TM}$ ,  $\theta_{11}$ ,  $\theta_{22}$  그리고  $\theta_{33}$ 에 대입하고, 변수 a, b를 구하면 다음과 같다(Fig. 4).

$$y = a * x^b$$

$$\theta_{TM} = 60.09 * x^{0.02}$$

$$\theta_{11} = 7.22 * x^{0.96}$$

$$\theta_{22} = 12.51 * x^{0.93}$$

$$\theta_{33} = 11.38 * x^{0.80} \quad (3)$$

또한, Table 2는 선형 함수에 대한 추정량의 정확성을 나타내는 측도인 표준 오차 값이다.

Table 2 Standard error of the linear function ( Unit : ° )

| Parameter | $\theta_{TM}$ | $\theta_{11}$ | $\theta_{22}$ | $\theta_{33}$ |
|-----------|---------------|---------------|---------------|---------------|
| a         | ± 0.921       | ± 0.838       | ± 3.345       | ± 2.767       |
| b         | ± 0.009       | ± 0.057       | ± 0.132       | ± 0.121       |

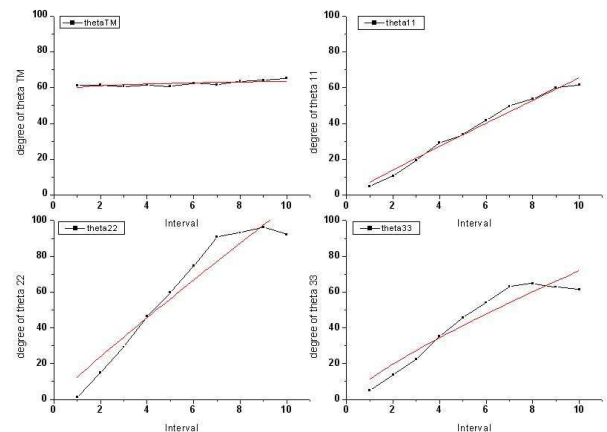


Fig. 4 Average value( $\theta_{TM}$ ,  $\theta_{11}$ ,  $\theta_{22}$  and  $\theta_{33}$ ) and the mathematical function




Fig. 5 The structure of the neural network

### 3. 적응 알고리즘

#### 3.1 신경 회로망(Neural Network)

실험을 통하여 추출한 각도변화의 상관 모델링을 위하여 신경회로망을 적용하여 말절골( $\theta_{33}$ )에 대한 모델을 도출하였다. 입력과 전달함수 사이의 가중치값은 최적 탐색 알고리즘(Gradient Decent Algorithm)에 의하여 학습이 되도록 하였으며, 국부 최소(Local Minimum)를 피하기 위한 방법들을 적용하여 학습시켰다. 식 (4)는 일반화된 델타 법칙을 말하며, 바이어스 가중치의 경우에는 입력이 항상 1이므로 위의 식에서 입력  $x_i$  대신에 1을 대입한다.

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij} \quad (4a)$$

$$= w_{ij}(t) + \eta(y_{out,j} - y_{Cal,j})f'(s_j)x_i$$

$$b_j(t+1) = b_j(t) + \Delta b_j \quad (4b)$$

$$= b_j(t) + \eta(y_{out,j} - y_{Cal,j})f'(s_j) * 1$$

역전과 알고리즘은 Fig. 5와 같이 구성되었으며, 전달함수는 비선형 함수 중에 미분이 가능한 함수로서 연속함수인 시그모이드 함수(Sigmoid Function)와 탄젠트 함수(Tangent Hyperbolic Function)를 사용하여 결과값을 비교하여 학습을 진행하였다. 역전과 알고리즘을 이용한 계산순서는 다음과 같다.<sup>(8)</sup> (1) 입력층  $\theta_{TM}$ ,  $\theta_{11}$  그리고  $\theta_{22}$  가 주어지면 은닉층과 출력층에서 식 (5~8)에 의하여 합(S)과 출력(y)을 한다. 식 (6a)와 식 (8a)은 시그모이드 함수에 관한 식이며, 식 (6b)와 식 (8b)는 탄젠트 함수에 관한 식이다. (2) 신경망의 출력( $y_o$ )과  $\theta_{33}$ 를 비교하여 오차(E)를 계산한다. (3) 은닉층과 출력층에 대한  $\delta$ 를 계산한다(식

(9~10)). (4) 은닉층과 출력층의 가중치를 식 (11~14)에 의하여 계산하며,  $\eta$ 는 학습률로서 0.9를 설정하였다. (5) 식 (15~18)에 의하여 가중치를 업데이트한다. 여기서,  $\alpha$ 란 모멘텀 상수로서 전가중치의 활용률을 얘기하며, 0.9를 사용하였다. (6) 모든 오차의 RMS(root mean square)를 구한 다음(식 (19)), 설정 오차( $\epsilon$ )와 비교한다(식 (20)). 여기서 만족할 때까지 (1)에서 (6)까지 반복하거나 반복회수(10000회)에 의하여 반복이 끝나면 다음 단계로 진행한다. (7)은 검증 데이터를 통한 학습 평가를 한다.

$$S_j = \sum_{i=1}^n (w_{ij} * \theta_i) + b_{ij} \quad (5)$$

$$y_{hj} = \frac{1}{1 + e^{-S_j}} \quad (6a)$$

$$y_{hj} = \frac{1 - e^{-S_j}}{1 + e^{-S_j}} \quad (6b)$$

$$S_k = \sum_{j=1}^n (w_{jk} * y_j) + b_{jk} \quad (7)$$

$$y_{ok} = \frac{1}{1 + e^{-S_k}} \quad (8a)$$

$$y_{ok} = \frac{1 - e^{-S_k}}{1 + e^{-S_k}} \quad (8b)$$

$$\delta_k = E * f'(S_k) \quad (9)$$

$$\delta_j = f'(S_j) \sum_{k=1}^n \delta_k w_{jk} \quad (10)$$

$$\Delta w_{jk} = \eta * \delta_k * y_{hj} \quad (11)$$

$$\Delta w_{ij} = \eta * \delta_j * \theta_i \quad (12)$$

$$\Delta b_k = \eta * \delta_k \quad (13)$$

$$\Delta b_j = \eta * \delta_j \quad (14)$$

$$w_{jk}(t+1) = w_{jk}(t) + \Delta w_{jk} + \alpha(w_{jk}(t) + w_{jk}(t-1)) \quad (15)$$

$$b_k(t+1) = b_k(t) + \Delta b_k + \alpha(b_k(t) + b_k(t-1)) \quad (16)$$

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij} + \alpha(w_{ij}(t) + w_{ij}(t-1)) \quad (17)$$

$$b_j(t+1) = b_j(t) + \Delta b_j + \alpha(b_j(t) + b_j(t-1)) \quad (18)$$

$$E_d = \sqrt{E_1^2 + E_2^2 + \dots + E_n^2} \quad (19)$$

$$\sum E_d < \epsilon \quad (20)$$

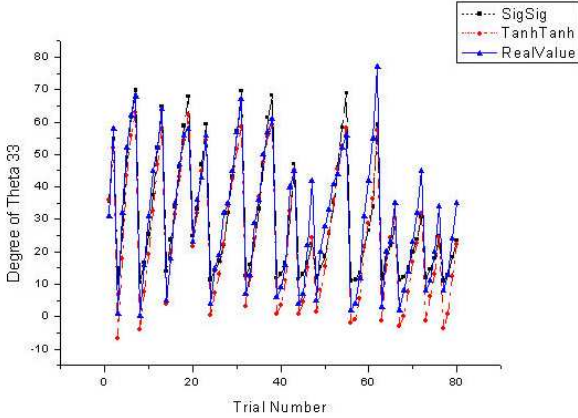


Fig. 6 Comparison between Sigmodial-to-Sigmodial, Tanh-to-Tanh and experiment value.

Fig. 6에서 보이는 바와 같이 탄젠트 전달함수 ( $E_{NW, \tanh} = 67.99$ )보다 시그모이드 전달함수 ( $E_{NW, sigmodial} = 64.24$ )를 사용했을 때,  $RMS$ 가 더 작게 나타났다.

### 3.2 커널 회귀(Kernel Regression)

이상 데이터에 대한 강인성을 얻기 위해 주목 받고 있는 커널 회귀 방법은 표본 데이터 쌍( $\theta_{TM}, \theta_{11}, \theta_{22}, \theta_{33}$ )이 주어졌을 때, 이를 가지고 함수의 근사치를 구하고자 할 때, 입력 데이터와의 유클리디안 거리(Euclidean Distance)를 계산하여 최소 에러( $E_{min}$ )를 찾는다. 이러한 근사치 함수( $\hat{Y}$ )는 식 (21)과 같이 표현할 수 있다.

$$\hat{Y}(x) = \frac{\sum_{i=1}^n [K_h(X_i - x) Y_i]}{\sum_{i=1}^n K_h(X_i - x)} \quad (21)$$

여기서,  $X_i$ 와  $Y_i$ 는 표본 데이터이며,  $K_h(X_i - x)$ 는 커널 함수(Kernel Function)라고 하며, 가우시안 커널(Gaussian Kernel)로 표현하면 식 (22)와 같으며,  $h$ 는 커널의 폭(Band Width)을 의미한다.

$$K_h(d) = \frac{1}{\sqrt{2\pi h^2}} e^{-d/2h^2} \quad (22)$$

그리고 유클리디안 거리는 식 (23)과 같으며,  $d_{ij}$ 가 작을수록 에러가 작다는 것을 의미하는 데, 가우시안 커브에서는 상대적으로 더 높은 값을 부여하게 된다.

$$d_{ij} = \|x_i - x_j\|^2 \quad (23)$$

커널 회귀에 대한 알고리즘은 Fig. 7과 같으며, 이를 이용한 계산순서는 다음과 같다.<sup>(9)</sup> (1) 표본




Fig. 7 Structure of the kernel regression.

데이터에서 입력층 데이터에 대한 유클리드 거리를 계산한다(식 (24)). 여기서,  $x_j$ 는 표본 데이터의 입력층이며,  $X_j$ 는 검증 데이터의 입력층이다. (2) 가우시안 커널을 이용하여 가중치(식 (25a) 및 커널 폭(식 (25b))을 구하였으며,  $h_0$ 는 0.1,  $\Delta h$ 는 0.5로 설정하였다. (3)  $w_j, x_{\theta_{33,j}} * w_j$ 의 합을 이용하여  $y_o$ 를 구한다.(식 (26)). (4) 모든 값들에 대한  $RMS$ 를 구하며(식 (27)), 설정 오차( $\epsilon$ )와 비교한다(식 (28)). 여기서 설정 오차보다 작으면,  $\epsilon = E_{d_i}$ 로 하고, 커널 폭이 만족하는 범위에서 (1)에서 (4)까지를 계속 반복하여  $RMS$ 의 최소값에 대한  $h$ 를 구한다.

$$d_{\theta,j} = \sqrt{\sum_{j=1}^n (x_j - X_j)^2} \quad (24)$$

$$w = K_h(d) = \frac{1}{\sqrt{2\pi h^2}} e^{-d_{\theta,j}/2h^2} \quad (25a)$$

$$h = h_0 + \Delta h \leq h_{max} \quad (25b)$$

$$y_o = \frac{\sum_{j=1}^n x_{\theta_{33,j}} * w_j}{\sum_{j=1}^n w_j} \quad (26)$$

$$E_d = \sqrt{E_1^2 + E_2^2 + \dots + E_n^2} \quad (27)$$

$$\sum E_d < \epsilon \quad (28)$$

Fig. 8에서 알 수 있듯이  $h = 10.1$ 로 설정했을 때,  $RMS$  ( $E_{KR, h=10.1} = 51.206$ )가 제일 작게 나타났다으며, Fig. 9는 실험 데이터와 수학적 모델, 신경회로망 그리고 커널 회귀를 이용하여 구한  $\theta_{33}$ 을 비교한 값으로서, 커널회귀를 이용한 모델링이 실험 데이터와 더 근접하다는 것을 알 수 있다.




Fig. 8 Comparison between bandwidth of the kernel regression( $h=0.1, 1.1, 2.1, \dots, 12.1$ )




Fig. 9 Comparison between the predicting value and the experiment value

신경회로망과 커널 회귀를 선택하여 비교한 것은 데이터 상관관계를 기반으로 모델링하는 소프트 모델링으로의 적용을 위한 것이며, 로봇 손에 있어서 가장 적용성이 우수하다고 판단되는 방법을 비교하고자 하였다. 데이터 특성에 따라 적합성이 다르게 되지만 측정 결과와의 비교를 통해서 자유도를 축소한 로봇 손의 파지의 상관 모델링에 있어서는 커널 회귀가 더 유용하다고 판단되었다. 앞으로 모델링 인자가 늘어나는 경우에 대해서는 자유도 축소를 위하여 주성분 분석을 통해 상관 변수를 필터링하고 커널 회귀를 적용하는 것이 더 적합하다고 판단된다.

#### 4. 결론

최소의 자유도를 적용하여 실용적인 로봇 손 파지 모델을 구하고자, 본 논문에서는 고속카메라를 이용하여 촬영한 실험 데이터와 수학적 모델, 신경회로망 및 커널 회귀 모델을 사용하여 로봇 손 파지 모델을 구하였다. 신경회로망과 커

널 회귀를 이용한 과정을 비교함으로써, 커널 회귀 알고리즘을 통한 모델링이 실험 데이터와의 근접성이 우수한 유효 모델을 구할 수 있다는 것을 알 수 있었다.

신경회로망에서의 전달함수와 뉴런수의 조합관계, 커널회귀에서의  $h_{optimum}$ 를 빠르게 찾는 방법, 함수 종류에 대한 RMS 관계를 알고 최소화시키는 연구가 진행된다면, 에러율이 더 작고, 빠르게 손 동작에 대한 예측이 가능할 것이다.

#### 후 기

이 논문은 호서대학교의 재원으로 학술연구비 지원을 받아 수행된 연구임(2007-0017).

#### 참고문헌

- (1) Butterfass, J., Grebenstein, M., Liu, H. and Hirzinger, G., 2001, "DLR-Hand II: Next Generation of a Dexterous Robot Hand," Proceedings of the IEEE International Conference on Robotics and Automation, pp.109~114.
- (2) Kawasaki, H., Komatsu, T. and Uchiyama, K., 2002, "Dexterous Anthropomorphic Robot Hand With Distributed Tactile Sensor: Gifu Hand II," *IEEE/ASME Transactions on Mechatronics*, Vol.7, No.3, pp.296~303.
- (3) Jacobsen, S. C., Iversen, E. K., Knutti, D. F., Johnson, R. T. and Biggers, K. B., 1986, "Design of the Utah/M.I.T Dexterous Hand," Proceedings of the IEEE International Conference on Robotics and Automation, pp.1520~1532.
- (4) Lovchic, C. S. and Diftler, M. A., 1999, "The Robonaut Hand, A Dexterous Robot Hand for Space," Proceedings of the IEEE International Conference on Robotics and Automation, pp.907~912.
- (5) Chi, H. J., Lee, S. H., Choi, B. J. and Choi, H. R., 2006, "Design of a Dexterous Anthropomorphic Robot Hand," *Trans. of the KSME (A)*, Vol. 30, No. 4, pp.357~363.
- (6) Hwang, C. S., 2005, "Kinematics of Grasping and Manipulation of Curved Surface Object with Robotic Hand," *Trans. of the KSME (A)*, Vol. 29, No. 1, pp.1~13.

- (7) Ramsay, J. O., 1991, "Kernel Smoothing Approaches to Nonparametric Item Characteristic Curve Estimation," *PSYCHOMETRIKA*, Vol.56, No.4, pp.611~630.
- (8) Jung, S., 2007, "Artificial Intelligence System 1, The Instructions and Structure of the Neural Network," CNUPRESS, pp.76~107.
- (9) Hines, J. W., Garvey, D., Seibert, R. and Usynim, A., 2008, "Technical Review of On-Line Monitoring Techniques for Performance Assessment Vol. 2 : Theoretical Issues," U.S.NRC, pp.23~29.