

論文99-36C-8-5

# Polhemus 센서의 궤적 정보 해석을 이용한 스트로크 기반의 손 제스처 인식

(Stroke Based Hand Gesture Recognition by Analyzing a Trajectory of Polhemus Sensor)

金麟哲\*, 李南昊\*\*, 李容範\*\*, 秦成一\*

(In Cheol Kim, Nam Ho Lee, Yong Bum Lee, and Sung Il Chien)

## 요 약

본 논문에서는 원격 작업 환경에서 명령자의 제스처를 자동으로 인식하기 위하여 글로브 센서 기반의 인식 기법을 이용한 3차원 제스처 인식 시스템을 구현하였다. 인식 시스템은 PinchGlove에 부착하여 사용되는 Polhemus 센서로부터 획득한 손 궤적의 3차원 위치 좌표열을 입력으로 사용한다. 또한 본 논문에서는 제스처 인식을 위해 제스처를 구성하는 스트로크를 기본 인식 단위로 사용하는 방법을 제안한다. 각 스트로크는 이산 HMM으로 모델링 되며 이들 HMM을 연결하여 생성된 결합 HMM으로 원격 작업에 사용될 각 제스처들을 모델링 한다. 이 방법은 새로이 정의되는 제스처에 대해 추가의 학습 과정을 필요로 하지 않아 인식 시스템의 확장성을 높일 수 있다. 16개의 제스처를 사용한 인식 실험에서 스트로크 기반의 결합 HMM은 제스처를 기본 단위로 사용한 HMM에 비해 더 좋은 인식 성능을 나타냄을 확인할 수 있었다.

## Abstract

We have developed glove based hand gesture recognition system for recognizing 3D gestures of operators in remote work environment. Polhemus sensor attached to the PinchGlove is employed to obtain the sequence of 3D positions of a hand trajectory. These 3D data are then encoded as the input to our recognition system. We propose the use of the strokes to be modeled by HMMs as basic units. The gesture models are constructed by concatenating stroke HMMs and thereby the HMMs for the newly defined gestures can be created without retraining their parameters. Thus, by using stroke models rather than gesture models, we can raise the system extensibility. The experiment results for 16 different gestures show that our stroke based composite HMM performs better than the conventional gesture based HMM.

## I. 서 론

손 제스처는 사람과 사람 사이의 대화를 위한 중요한 수단중의 하나이다. 이러한 손 제스처를 사람과 기계사이의 자연스러운 인터페이스 수단으로 적용하고자 하는 노력이 계속되어왔다. 손 제스처 인식은 크게 컴퓨터 비전 기반(vision based)의 인식 방법과 글로브 센서 기반(glove based)의 인식 방법으로 나눌 수 있다<sup>[1]</sup>. 컴퓨터 비전 기반의 인식 방법은 글로브 센서

\* 正會員, 慶北大學校 電子電氣工學部

(School of Electronic and Electrical Engineering, Kyungpook National University)

\*\* 正會員, 韓國 原子力 研究所

(Korea Atomic Energy Research Institute)

接受日字:1999年3月8日, 수정완료일:1999年7月19日

기반의 인식 방법에 비해 좀더 자연스러운 인간과 기계 사이의 인터페이스를 구현할 수 있다. Rehg와 Kanade<sup>[2]</sup>가 개발한 DigitEyes라는 실시간 손 추적 시스템과 Starner와 Pentland<sup>[3]</sup>의 수화 해석을 위한 손 제스처 인식 시스템은 이러한 비전 기반의 인식 기법을 이용한 것이다. 그러나 이 방법은 임의의 배경에서 손 부분을 추출하는 문제와 손의 위치를 추적하는 문제 등에서 아직까지 기술적인 어려움을 가지고 있다. 이러한 문제에 대한 부담을 줄이기 위한 방법으로서 글로브 센서 기반의 인식 기법이 적용되고 있는데 Fels와 Hinton<sup>[4,5]</sup>의 Glove-Talk와 Glove-Talk II, 그리고 Lee와 Xu<sup>[6]</sup>의 인터랙티브 제스처 인식 시스템을 예로 들 수 있다. 이 기법은 다소 부자연스럽고 비싼 장비를 사용해야 하는 단점은 있으나 비전 기반의 인식 기법에 비해 높은 인식률 및 신뢰성을 가진다. 본 논문에서는 원자력 발전소내의 방사능 노출 지역이나 심해 등과 같은 열악한 환경에서 원격으로 로봇을 안정되게 제어하기 위해 글로브 기반의 인식 기법을 적용하여 손 제스처 인식 시스템을 구현하였다.

일반적으로 손 제스처는 손의 형태와 움직임으로 이루어진다. 손 또는 손가락 형태와 관련된 정보는 VPL research사의 DataGlove 혹은 Virtual Technologies사의 Cyberglove를 이용해 얻을 수 있으며 손의 움직임과 관련된 정보는 Polhemus Inc. 사의 Polhemus 센서를 이용해 얻을 수 있다.<sup>[7]</sup> 이때 Polhemus 센서는 일반적으로 DataGlove에 부착되어 함께 사용되어지며 손의 3차원 위치를 나타내는 좌표열을 발생시킨다. 손의 형태와 움직임을 함께 사용하여 제스처를 정의하는 경우에는 더 많은 제스처를 표현할 수 있지만 제스처의 수가 많아질 수록 그 형태가 복잡해져 인식이 상당히 어려워진다. 본 논문에서는 효율적이고 안정된 제스처 인식을 위해 손의 형태는 사용하지 않고 그 움직임만으로 제스처를 정의하여 인식에 사용한다.

일반적으로 3차원 공간에서 발생한 손의 궤적은 2차원에서의 경우에 비해 더 많은 공간적인 복잡성을 가지므로 그 해석이 좀더 어려워진다. 그러나 손 제스처의 발생을 2차원 공간으로 제한할 경우에는 실제 환경에서의 적용이 부자연스러우므로 제안한 인식 시스템은 손 제스처의 3차원 정보, 즉 손 궤적의 3차원 위치 좌표열을 이용해 제스처 인식을 수행한다.

본 논문에서는 제스처 인식을 위해 제스처 자체를

사용하지 않고 제스처의 구성 요소인 스트로크를 기본 인식 단위로 사용하는 것을 제안한다. 실험에 사용되는 제스처는 이러한 스트로크를 결합함으로써 표현할 수 있으며 새로운 제스처의 생성도 미리 정의된 스트로크를 단순히 결합함으로써 가능해진다. 제안된 방법은 제스처 인식 분야에서 널리 사용되는 이산 HMM을 이용해 쉽게 구현할 수 있다.

즉, 미리 정의된 각 스트로크에 대해 HMM이 생성되면 각 제스처는 이들 스트로크 HMM을 연결하여 만든 결합 HMM으로 모델링 할 수 있다. 제스처를 기본 인식 단위로 사용한 기존의 HMM 기반의 제스처 인식 연구<sup>[3,6,8]</sup>에서는 새로운 제스처가 정의되는 경우에는 해당되는 HMM을 생성하기 위해 추가적인 학습 과정을 필요로 하였다. 그러나 제안한 스트로크 기반의 인식 기법은 새로운 제스처에 대해 추가의 학습 과정이 필요하지 않아 시스템의 확장성을 높일 수 있다는 장점을 가진다. 본 논문에서는 실험을 통해 스트로크 기반의 결합 HMM의 인식 성능과 기존의 제스처를 기반으로 한 HMM의 인식 성능을 서로 비교하였다.

본 논문의 구성은 다음과 같다. II장에서는 실험에 사용된 제스처 데이터베이스 특징, 그리고 결합 HMM의 구조 등을 포함한 전체 인식 시스템에 대해 자세히 기술한다. III장에서는 제안한 인식 시스템에 대한 실험 결과 및 고찰을 설명하고 마지막으로 IV장에서 결론을 맺는다.

## II. 스트로크 기반의 손 제스처 인식 시스템

### 1. 인식 시스템의 전체 구성

제안된 제스처 인식 시스템의 전체적인 구조는 그림 1과 같다. 먼저 각 스트로크 별로 HMM을 구성하고 이들 스트로크 HMM을 연결하여 미리 정의된 제스처들에 대한 결합 HMM을 생성하는 학습 과정이 오프라인으로 수행된다. 온라인 인식 단계에서는 어떤 제스처가 입력으로 주어지면 오프라인 학습 단계에서 생성된 각 제스처별 결합 HMM으로부터 주어진 제스처의 관측열에 대한 확률값을 계산한 뒤 최고 확률값을 나타내는 HMM을 선택하여 그에 해당되는 제스처로 인식한다.

진술한 인식 과정을 수행하기 위해서는 먼저 제스처

를 검출하고 획득하는 과정이 선행되어야 한다. 손의 궤적으로 표현되는 제스처에 대한 정보는 Polhemus 센서를 이용해 얻을 수 있는데 이를 위해서는 먼저 발생된 손 궤적으로부터 의미 있는 제스처 구간만을 검출하는 전처리 과정이 필요하다. 그러나, 어떤 제스처의 시작점과 끝점을 검출하는 일은 쉬운 일이 아니다. 본 논문에서는 이 문제를 해결하기 위해 PinchGlove를 사용하였다. Fakespace사의 PinchGlove<sup>[9]</sup>는 두 손가락의 단순한 접촉으로써 제스처의 시작과 끝나는 시점을 알려준다. 따라서 PinchGlove의 손등에 Polhemus 센서를 부착해 사용함으로써 제스처의 검출 및 획득 과정을 동시에 수행할 수 있다. 그림 2는 Polhemus 센서와 PinchGlove를 사용한 제스처 획득 시스템 및 시스템의 블록도를 나타낸다.

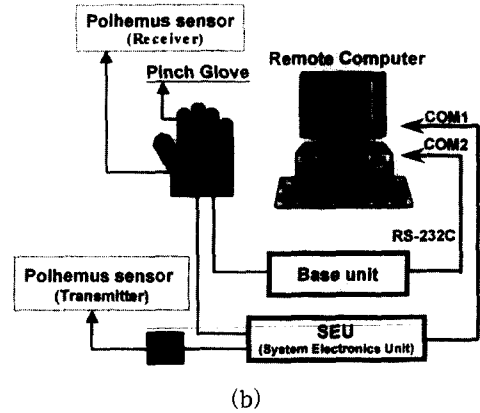


그림 2. (a) 제스처 획득 시스템 및 (b) 시스템 블록도  
Fig. 2. (a) Gesture acquisition system and (b) its system blocks.

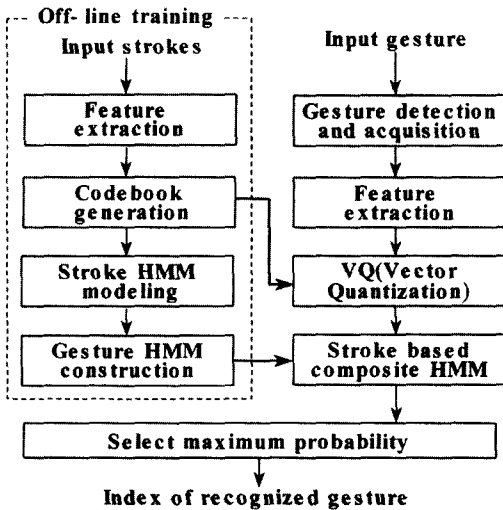



그림 1. 스트로크 기반의 손 제스처 인식 시스템  
Fig. 1. Stroke based hand gesture recognition system.



(a)

2. 손 제스처 데이터베이스

strokes(segments) of gesture	symbol of gesture	type of gesture	word of gesture
←	L	←	Left
→	R	→	Right
↑	U	↑	Up
↓	D	↓	Down
↑ ↓	UD	↑ ↓	Forward
↓ ↑	DU	↓ ↑	Backward
← ↓	LD	← ↓	Catch
↓ ←	DL	↓ ←	Put
← → ↓	LRD	← → ↓	Start
↓ → ←	DRL	↓ → ←	End
↓ ↘ ↓	DS <sub>1</sub> D	↓ ↘ ↓	Repeat
→ ↘ →	RS <sub>3</sub> R	→ ↘ →	Wait
↘ ↑ ↘	S <sub>2</sub> US <sub>3</sub>	↘ ↑ ↘	Danger
↻ ↻ ↻	C <sub>3</sub> C <sub>4</sub>	↻ ↻ ↻	Safe
↘ ↘ ↘	S <sub>1</sub> S <sub>2</sub>	↘ ↘ ↘	Fast
↻ ↻ ↻	C <sub>1</sub> C <sub>2</sub> C <sub>1</sub>	↻ ↻ ↻	Slow

그림 3. 스트로크, 심볼, 그리고 스트로크의 결합으로 표현되는 제스처  
Fig. 3. Strokes, their symbols, and gestures as compositions of strokes.

본 논문에서는 인식 실험을 위해 그림 3에 나타난 16개의 손 제스처를 정의하였다. 정의된 제스처 중에서 11개의 제스처는 로봇의 이동 방향과 원경 작업을 위한 동작을 지시하기 위해 사용된다. 또한 3개의 제스처는 원경 작업장의 상태를 알려주기 위해 사용되며 나머지 2개의 제스처는 로봇의 동작 속도를 제어하기 위해 사용된다. 본 실험에서는 이들 16개의 제스처를

생성하기 위해 총 11개의 스트로크를 기본 단위로 사용한다. 그림 3의 첫번째 열에 나타난 스트로크들은 세 번째 열에 나타난 제스처를 생성하기 위해 필요한 기본 요소들이다. 그림에서 나타난 바와 같이 한 개의 스트로크가 하나의 단순한 손 제스처가 될 수도 있지만 일반적으로 두개 또는 세 개의 제스처가 연결되어 좀더 복잡한 제스처를 생성한다. 부가적으로 그림 3의 두 번째 열에는 각 스트로크를 나타내기 위한 심볼을 문자로써 표기하였다.

3. 특징 추출

본 절에서는 Polhemus 센서와 PinchGlove를 이용하여 획득된 스트로크 및 제스처들로부터 인식 시스템의 입력으로 사용하기 위한 특징을 추출하는 과정에 대해 설명한다. Fels와 Hinton<sup>[4]</sup>은 수화를 해석하여 이를 음성으로 변환하는 시스템을 구현하기 위해 손의 위치 정보와 손 움직임의 속도 및 가속도를 특징으로 사용하였다. 그러나 본 논문에서는 손의 움직임과 관련된 궤적 정보만을 이용해 제스처를 정의하므로 손의 형태와 움직임 모두를 사용한 경우에 비해 좀더 단순한 특징을 사용하더라도 인식 시스템의 구현이 가능하다. 따라서 식 (1)에 나타난 것과 같이 손의 연속된 두 위치를 나타내는 좌표 벡터 사이의 차를 구해 특징으로 사용하였다.

$$v_t = x(t) - x(t-1) = [\Delta x, \Delta y, \Delta z]^T \quad (1)$$

여기서  $v_t$ 는 시간  $t$ 에서의 손의 위치를 나타내는 3차원 좌표 벡터  $x(t)$ 와 그 전 위치를 나타내는  $x(t-1)$  간의 차를 나타내는 벡터이며 그 성분은  $\Delta x$ ,  $\Delta y$ , 그리고  $\Delta z$ 로 표현된다. 제스처는 동일한 실험자라도 매번 실행할 때마다 그 크기 및 묘사되는 속도가 다르게 나타난다. 이러한 문제는 식 (2)와 같이 정규화된  $v_t$ 를 입력 특징으로 사용함으로써 해결할 수 있다.

$$\frac{v_t}{|v_t|} = [\Delta x', \Delta y', \Delta z']^T \quad t=1,2,\dots,N \quad (2)$$

제안된 인식 시스템은 이산 HMM을 인식기로 사용한다. 따라서 제스처로부터 추출한 특징 벡터를 입력으로 적용하기 위해서는 이것을 이산화된 심볼로 변환시키는 벡터 양자화 과정이 필요하다. 벡터 양자화는 미리 정해진 개수의 코드워드로 이루어진 코드북을

이용하여 특징 벡터를 하나의 이산 심볼로 변환한다. 본 논문에서는 LBG 알고리즘을 이용하여 학습용 스트로크 데이터로부터 코드북을 생성하여 벡터 양자화 과정에 적용하였다. 이때 코드북의 크기는 32로 정하였다. 즉, 주어진 특징 벡터를 32개의 이산 심볼 중의 하나로 변환하여 이산 HMM의 입력으로 적용하였다.

4. 스트로크 HMM의 결합

은닉 마르코프 모델(HMM)<sup>[10]</sup>은 제스처 인식 뿐만 아니라 음성 인식과 필기체 문자 인식 분야 등에서도 널리 사용되는 인식 기법으로서 관측이 불가능한 통계적 프로세서와 관측열을 발생시키는 또 다른 통계적 프로세서로 이루어진 이중적인 통계적 프로세서이다.  $N$  개의 상태로 이루어진 HMM은 일반적으로  $\lambda=(A, B, \pi)$ 로 표현된다. 여기서  $A$ 는 상태 천이 확률을 나타내는 행렬이고  $B$ 는 관측 심볼에 대한 출력 확률을 나타내는 행렬이다. 또한  $\pi$ 는 초기 상태 확률을 나타내는 벡터이다. 각 HMM에서의 이러한 파라미터들은 Baum-Welch 재추정 알고리즘을 이용해 추정된다. 또한 입력으로 주어진 관측열에 대한 각 HMM에서의 확률값 계산은 전향-후향(Forward-Backward) 알고리즘 또는 Viterbi 알고리즘을 이용해 이루어지는데 본 논문에서는 Viterbi 알고리즘을 사용하였다.




그림 4. (a) 스트로크 모델 및 (b) 두개의 스트로크 모델의 결합으로 생성된 제스처 모델  
Fig. 4. (a) Stroke model and (b) composite gesture model with two strokes.

그림 4의 (a)는 기본 인식 단위로 사용되는 스트로크를 모델링 하기 위해 사용된 3 상태의 left-to-right HMM을 나타낸다. 학습 과정에서는 먼저 각 스트로크들에 대한 HMM을 생성한 뒤 두개 혹은 3개의 관련된 스트로크 HMM을 연결하여 정의된 각 제스처들에 대한 결합 HMM을 생성한다. 그림 4의 (b)

는 결합 HMM의 한 예를 나타내며 최종적으로 16개의 결합 HMM이 생성된다.

### III. 인식 실험

#### 1. 제스처 발생

본 논문에서 제안한 제스처 인식 시스템은 3차원 공간에서 발생한 손 궤적의 위치 정보를 이용하여 제스처 인식을 수행한다. 제스처의 발생을 2차원 평면 상으로 제한하는 것은 실제 환경에서 적용하기가 부자연스러우므로 본 논문에서는 인식 시스템이 3차원 왜곡에 대한 적응성을 가지도록 하여 3차원 공간에서 자연스럽게 발생한 제스처를 인식에 그대로 적용하고자 한다. 즉, 인간이 자연스럽게 제스처를 실행할 수 있는 범위를 3차원 공간에서 정한 뒤 이 범위를 잘 반영할 수 있는 스트로크 데이터를 구하여 HMM의 학습에 사용함으로써 인식 시스템이 3차원적인 왜곡에 대하여 적응성을 가지도록 한다. 본 절에서는  $C_1$  stroke를 예로서 사용하여 전술한 개념의 타당성을 검사하였다. 먼저, 그림 5에는 3차원 공간에서 자연스럽게 발생한  $C_1$  스트로크를 나타내었는데 이를 학습용 데이터로 사용하여 HMM을 생성한다. 그리고 그림 6의 (a)에 나타난 것과 같이  $C_1$  스트로크에 대한 검사용 데이터 집합을 인위적으로 발생시켜  $C_1$  HMM에서의 인식 여부를 검사한다. 실험 결과에서  $C_1$  HMM은  $\pm 50^\circ$  범위 내에서 발생한 스트로크에 대해서는 제대로 인식을 할 수 있음을 확인하였다. 실제로 실험자가 의도적으로 제스처를 왜곡시켜 발생시키지 않고 자연스럽게 발생시키는 경우에는 그 발생 범위가 위의 실험 결과로부터 나타난 HMM의 인식 범위를 벗어나지 않는다. 따라서 전술한 방식으로 구현된 인식 시스템은 3차원 공간에서 자연스럽게 발생한 제스처에 대한 인식을 제대로 수행할 수 있음을 알 수 있다.





그림 5. 학습에 사용된  $C_1$  스트로크의 궤적  
Fig. 5. Trajectories of  $C_1$  stroke used in training.





그림 6. (a) 인위적으로 발생된 검사용  $C_1$  스트로크 및 (b) 인식 범위

Fig. 6. (a) Testing strokes artificially generated for  $C_1$  stroke and (b) range of acceptance.

#### 2. 실험 결과

실험에서는 각 스트로크에 대한 HMM을 생성하기 위해 4명의 실험자가 11개의 스트로크를 각각 5번씩 실행하여 얻은 총 220개의 스트로크 데이터를 학습용 데이터베이스로 사용하였다. 또한 스트로크 HMM을

연결하여 생성된 각 제스처별 결합 HMM에 대한 인식 성능을 알아보기 위하여 학습에 참여하지 않은 또 다른 6명의 실험자가 16개의 제스처를 각각 10번씩 실행하여 얻은 총 960개의 제스처 데이터를 검사용 데이터베이스로 사용하였다. 표 1에는 결합 HMM을 구성하는 스트로크 HMM의 상태 수를 달리하여 실험한 결과를 나타내었는데 스트로크 HMM의 상태 수가 7일 경우에 가장 높은 인식률인 96.56%를 얻을 수 있었다.

표 1. 검사용 데이터베이스에 대한 스트로크 기반의 결합 HMM에서의 인식률

Table 1. Recognition rates of stroke based composite HMM against a testing database.

HMM models	Error no.	Recognition rate(%)
5-10-15 states	45	95.31
6-12-18 states	40	95.83
7-14-21 states	33	96.56
8-16-24 states	45	95.31
9-18-27 states	45	95.31

또한 본 논문에서는 제스처를 기본 인식 단위로 사용한 두 종류의 HMM, 즉 가변 크기 HMM과 고정 크기 HMM으로 인식 실험을 수행하여 스트로크를 기본 단위로 사용한 결합 HMM의 경우와 그 결과를 비교하였다. 가변 크기 HMM은 대응되는 제스처의 복잡성에 따라 세가지 종류의 각기 다른 상태 수를 가지도록 하였다. 즉, 제스처의 형태가 단순하고 쉬운 경우에는 적은 수의 상태를 가지는 HMM으로 모델링 하고 복잡한 제스처의 경우에는 모델링 되는 HMM의 상태 수가 상대적으로 많도록 하였다. 결과적으로, 주어진 제스처에 대해 제스처 기반의 가변 크기 HMM과 스트로크 기반의 결합 HMM은 동일한 수의 상태를 가진다. 한편 고정 크기 HMM은 제스처의 형태에 관계없이 일정한 수의 상태를 가진다. 전술한 두 종류의 제스처 기반의 HMM은 4명의 실험자가 각 제스처를 5번씩 실행하여 얻은 제스처 데이터를 학습용 데이터베이스로 사용하여 구현되었다. 검사 과정에서는 스트로크 기반의 결합 HMM에 대한 인식 성능을 검사하기 위해 사용된 검사용 데이터베이스를 똑같이 제스처 기반의 HMM에 적용함으로써 그 인식 성능을 서로 비교할 수 있도록 하였다. 표 2에서는 전술한 두 종류의 제스처 기반의 HMM에 대한 인식 실험 결과

를 나타내었는데 7-14-21 가변 크기 HMM과 10 상태의 고정 크기 HMM에서 각기 최고 인식률인 96.15%와 92.19%를 얻을 수 있었다.

표 2. 검사용 데이터베이스에 대한 제스처 기반의 HMM에서의 인식률

Table 2. Recognition rates of two gesture based HMMs against a testing database.

HMM models	Structure	Error no.	Recognition rate(%)
고정 크기HMM	8 states	108	89.27
	9 states	112	88.33
	10 states	75	92.19
	11 states	78	91.88
	12 states	90	90.63
가변 크기HMM	5-10-15 states	58	93.96
	6-12-18 states	45	95.31
	7-14-21 states	37	96.15
	8-16-24 states	63	93.44
	9-18-27 states	71	92.60

본 실험에서는 표 1과 표 2에 나타난 결과로부터 스트로크 기반의 결합 HMM이 두 종류의 제스처 기반의 HMM에 비해 더 좋은 인식 성능을 가지며 상태 수의 변화에 따른 인식 성능의 변화도 상대적으로 적게 나타남을 확인 할 수 있었다.

#### IV. 결 론

본 논문에서는 글로브 센서를 기반으로 한 3차원 손 제스처 인식 시스템을 구현하였다. 실험에 사용된 각 제스처는 손의 움직임에 대한 3차원 궤적으로 정의되며 제스처 인식은 PinchGlove와 Polhemus 센서로부터 획득한 손 궤적의 3차원 위치 좌표열을 입력으로 사용하여 수행된다. 인식 시스템은 스트로크를 기본 인식 단위로 사용한 결합 HMM으로 구현하였다. 즉, 제스처를 구성하는 각 스트로크에 대해 이산 HMM을 구현한 뒤 이들 스트로크 HMM을 연결하여 각 제스처에 대한 결합 HMM을 생성한다. 제스처를 기본 인식 단위로 사용한 기존의 HMM 기반의 인식 연구에서는 새로운 제스처가 정의되면 이를 모델링 하기 위해 추가의 학습 과정을 필요로 한다. 그러나 제안된 스트로크 기반의 인식 기법은 추가의 학습 과정 없이 이미 생성된 스트로크 HMM의 단순한 결합만으로 새

로운 제스처에 대한 HMM 생성이 가능해 인식 시스템의 확장이 용이해진다는 장점을 가진다. 또한 본 논문에서는 인식 시스템이 3차원적 왜곡에 대한 적응성을 가지도록 하여 3차원 공간에서 자연스럽게 발생된 제스처에 대해 인식을 수행할 수 있도록 하였다.

실험에서는 제안된 스트로크 기반의 결합 HMM에 대한 인식 성능을 알아보기 위해 16개의 제스처를 정의하여 인식 실험을 수행하였다. 또한 제스처를 기본 인식 단위로 사용한 두 종류의 HMM, 즉 가변 크기 HMM과 고정 크기 HMM에 대해서도 인식 실험을 수행하여 그 결과를 서로 비교하였다. 실험 결과, 스트로크 기반의 결합 HMM이 제스처 기반의 HMM에 비해 더 좋은 인식 성능을 나타냄을 확인할 수 있었다.

#### 참 고 문 헌

- [1] T. S. Huang and V. I. Pavlovic, "Hand Gesture Modeling, Analysis, and Synthesis," *International Workshop on Automatic Face-and Gesture-recognition*, pp. 73-79, 1995.
- [2] J. M. Rehg and T. Kanade, "DigitEyes: vision-based human hand tracking," *Technical Report, CMU-CS-93-220*, School of Computer Science, Carnegie Mellon University, Dec. 1993.
- [3] T. Starner and A. Pentland, "Visual recognition of American Sign Language using hidden Markov models," *International Workshop on Automatic Face-and Gesture-recognition*, Zurich, pp. 189-194, 1995.
- [4] S. S. Fels and G. E. Hinton, "Glove-Talk : a neural network interface between a Data-Glove and a speech synthesizer," *IEEE Trans. Neural Networks*, vol. 4, no. 1, pp. 2-8, Jan. 1993.
- [5] S. S. Fels and G. E. Hinton, "Glove-TalkII a neural-network interface which maps gestures to parallel formant speech synthesizer controls," *IEEE Trans. Neural Networks*, vol. 8, no. 5, pp. 977-984, Sep. 1997.
- [6] C. Lee and Y. Xu, "Online, interactive learning of gestures for human/robot interfaces," *Proc. 1996 IEEE Int. Conf. on Robotics and Automation*, Minneapolis, MN, vol. 4, pp. 2982-2987, 1996.
- [7] D. J. Sturman and D. Zeltzer, "A survey of glove-based input," *IEEE Computer Graphics and Applications*, vol. 14, pp. 30-39, Jan. 1994.
- [8] J. Yang, Y. Xu, and C. S. Chen, "Human action learning via hidden Markov model," *IEEE Trans. Syst., Man, and Cybern.*, vol. 27, no. 1, pp. 34-44, Jan. 1997.
- [9] Fakespace PinchGlove Systems, *Installation Guide and User Handbook*, 1995.
- [10] L. R. Rabiner and B. H. Juang, "An introduction to hidden Markov models," *IEEE ASSP Magazine*, vol. 3, no. 1, pp. 4-16, Jan. 1986.

저 자 소 개



金 麟 哲(正會員)

1966년 11월 15일생. 1989년 2월 경북대학교 전자공학과 졸업(공학사). 1991년 2월 경북대학교 대학원 전자공학과 졸업(공학석사). 1991년 ~ 1996년 (주) 카스 기술개발실 선임연구원. 1996년 9월 ~ 현재 경북

대학교 대학원 전자공학과 박사과정 재학중. 주관심분야는 형태 인식, 신경회로망, 컴퓨터비전



李 容 範(正會員)

1962년 1월 10일생. 1985년 2월 경북대학교 전자공학과(학사). 1987년 2월 경북대학교 대학원 전자공학과(공학석사). 1999년 8월 경북대학교 대학원 전자공학과(공학박사). 1987년 ~ 현재 한국원자력연구소 로봇

핵심기술개발실 실장. 주관심분야는 입체영상시스템, 가상현실, 로봇비전

李 南 昊(正會員)

1963년 4월 28일생. 1991년 2월 경북대학교 전자공학과(학사). 1993년 2월 경북대학교 대학원 전자공학과(석사). 1993년 ~ 현재 한국원자력연구소 근무. 주관심분야는 가상현실, 방사선 센서

秦 成 一(正會員) 第 32卷 S編 第 9號 參照

경북대학교 전자전기공학부 교수