

복부 근전도 분석을 통한 복부 비만 측정시스템 개발

김정호[†] · 권장우

Development of the measurement system of abdominal obesity based on analysis of abdominal electromyogram

Jung-Ho Kim[†] and Jang-Woo Kwon

Abstract

Recently, obesity that is increasingly becoming a major cause of various diseases is emerging as a serious social problem. In order to solve this problem, the necessity of measurement systems for overweight management has increased. This paper is a study on the measurement system for obesity management that can offer right medical services everywhere and allways by analyzing EMG (electromyograph) of the abdomen and then checking one's health state. For analyzing EMG signals of the abdomen, algorithms for energy detection, signal feature extraction, classification and recognition are presented. This paper proposes a system that provides an appropriate an estimation on the health status by evaluating the obesity degree and muscular strength of the abdomen through the system applying these algorithms.

Key Words : EMG, MFCC, HMM, pattern recognition, abdominal obesity

1. 서 론

생체 신호 내부에는 질병과 관련된 직-간접적인 정보를 담고 있다. 특히, 표면 근전도(Surface Electromyogram)는 피부표면에 전극을 부착하는 무통증, 비침습적인 방식이다. 하지만 실제 복부에 대한 근전신호의 내부에는 측정기기의 기계적 잡음, 근육수축시 표면 전극에서 입력되는 외부잡음, 주위환경에서 발생한 잡음 등이 존재한다^[1]. 또한, 각 개인의 근전신호 형태가 매우 다양하고, 동일인이라도 근의 분포상태, 전극의 부착 위치에 따라서 근전신호가 다양하게 출력된다. 따라서 정확한 패턴 분류에도 상당한 악영향을 미친다.

기존의 근전도 패턴 인식을 위한 특징 추출 과정에서는 주로 LPCC(Linear Predictive Cepstral Coefficients), 영교차음(Zero-Crossing), 절대적분치(Integral of Absolute Value, IAV), AR(Autoregressive), 극파(Spike), 근육의 피로도 등이 다양하게 적용되고 있으며, 이들 비선형 시스템의 시간영역에서 근전신호를 주

로 분석하기 때문에 잡음이 포함될 경우 인식률의 저하를 초래한다^[2].

이러한 문제 때문에 주파수 영역에서 특징을 검출하는 방법과 관련해서 본 논문은 복부 근전도 분석시 시간영역의 특징 추출 기법보다 상대적으로 잡음에 강한 MFCC(Mel-Frequency Cepstral Coefficients) 특징 추출 기법을 제안하며, 이 기법은 음성 특징 추출에 주로 적용되기 때문에 근전도 특징 추출을 위해 재구성한다.

확률모델(Stochastic Model)은 시변적 신호의 패턴 인식에 있어 효율적이며, 이러한 확률 모델들 중 대표적인 예는 마르코프 상태 천이 함수(Markov Transition Function)에 그 수학적 기초를 두고 있는 Markov model과 HMM(Hidden Markov Model)이다. 통계적 확률 분포에 기인하는 HMM(Hidden Markov Models) 등을 단일 또는 혼합(hybrid)하여 패턴 인식 시스템을 구성한다.

일반적으로 HMM은 음성 연구 분야에서 활발한 연구가 진행되어오고 있으며^[3], 신경회로망과의 결합을 통하여 상호간의 장점을 증대시키기 위한 시도가 이루어져 오고 있다^[4]. 그러나 생체 신호가 가지고 있는 특성이 다른 분야에서 제안하고 있는 합성 시스템에 적

동명대학교 컴퓨터공학과 인공지능연구실(Dept. of Computer Engineering, Tongmyong Univ.)

[†]Corresponding author: kjhzorro@nate.com

(Received : May 11, 2007, Accepted : August 16, 2007)

합하지 못하므로, 생체신호의 특성을 잘 반영하는 시스템 구성이 필요하다.

따라서 본 논문에서는 복부 비만과 관련한 생체 신호 중 복부 근전도 신호를 획득한다. 그리고 복부 부위별 근전도의 신호가 상이하므로 정확한 평가를 위해서 복부 부위별 평가가 요구되었다. 그리고 기존의 특징 추출 기법을 재구성한 MFCC를 이용해서 복부 근전도 신호의 특징을 추출하여 HMM-GMM으로 학습된 근전도 측정 시스템을 제안한다.

실험 및 결과에서는 실험을 위해 16명의 피실험자에 대한 각각의 비만도를 분석하였으며, 이들을 비만도별로 분류하였다. 그리고 복부 6부위와 재구성한 MFCC의 8타입에 대한 평가를 수행하였으며, 측정 시스템에 대한 성능을 평가한다.

2. 본 론

2.1. EMG 특징 추출

각 프레임 별로 IAV 또는 Zero-Crossing을 통해 얻어진 근전신호의 에너지 값을 사전에 정의한 적절한 임계치를 적용하여 연속신호 내의 근전신호를 검출한다^[5,6].

근전신호의 특징 추출을 위해서 MFCC를 적용한다. 이 기법은 인간의 청각 특성을 모델링한 것으로 주파수 별로 필터 बैं크를 구성해서 인식하는 방법이다^[7,8]. 일반적인 MFCC 추출 방법은 먼저 윈도우를 씌워서 블록 단위의 프레임으로 나눈 뒤에 이후부터의 처리는 모두 프레임 단위로 이루어진다.

$$x[n], n=0,1,\dots,N-1 \quad (1)$$

x 는 한 프레임의 이산 EMG 신호이며, N 은 프레임 길이이다. 이를 FFT를 이용하여 주파수 영역으로 변환된다.

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-j\frac{2\pi nk}{N}} \quad (2)$$

magnitude 스펙트럼인 $|X[k]|$ 와 Mel 필터 बैं크인 $H_m[k]$ 를 다음과 같이 로그를 취한다.

$$S[m] = \ln \left[\sum_{k=0}^{N-1} |X[k]|^2 H_m[k] \right] \quad (3)$$

$m=1,2,\dots,M$ 은 필터 बैं크수를 나타내며, 주파수 대역을 여러개의 필터 बैं크로 나누고 각 बैं크에서의 에너지를 구한다. Mel 필터 बैं크는 식 (4)와 같다.

$$H_m[k] = \begin{cases} 0 & \text{for } k < f(m-1) \\ \frac{2(k-f(m-1))}{(f[m+1]-f[m-1])(f[m]-f[m-1])} & \text{for } f(m-1) \leq k < f(m) \\ \frac{2(f[m+1]-k)}{(f[m+1]-f[m-1])(f[m+1]-f[m])} & \text{for } f(m) \leq k < f(m+1) \\ 0 & \text{for } k \geq f(m+1) \end{cases} \quad (4)$$

$S[m]$ 에 대한 이산 코사인 변환(Discrete Cosine Transform, DCT) 과정을 식 (5)와 같이 수행한다.

$$c[n] = \sum_{m=0}^{M-1} S[m] \cos(\pi m(m-1/2)/M) \quad (5)$$

여기서, $n=1,2,\dots,M$ 은 MFCC의 차수이며, 식 (6)과 식 (7)처럼 최종적으로 MFCC를 획득한다.

$$\Delta c[n] = c[n+1] - c[n] \quad (6)$$

$$\Delta\Delta c[n] = \Delta c[n+1] - \Delta c[n] \quad (7)$$

여기서 기존의 MFCC 필터 बैं크 타입을 직접적으로 적용하기에는 적절하지 못하다. 근전도는 상대적으로 낮은 주파수 대역(10 Hz~500 Hz)을 지니고 있다. 따라서 기존의 MFCC와는 다른 다양한 타입의 필터 बैं크로 재구성이 요구되며, 채널수 또한 다양하게 변경하면서 근전도 인식에 가장 적합한 구성을 취할 필요가 있다.

그림 1과 그림 2는 재구성된 필터 बैं크 타입과 적절한 채널수를 적용하여 구성한 필터 बैं크이다. 그림 1은 삼각 필터 बैं크이며, Type 1은 고주파 대역으로 갈수록 필터 बैं크의 크기가 증가되는 형태이며, 필터들마다 오버랩(overlap)형태를 유지하고 있다. Type 2는 Type 1과 비슷하며, 단지 오버랩형태가 아니다. Type 3은 주파수 대역이 일정한 필터 बैं크이며, 오버랩(overlap) 형태이다. Type 4는 Type 3과 비슷하지만 오버랩 형태가 아니다. 그리고 필터는 점점 증가하다가 다시 감소하는

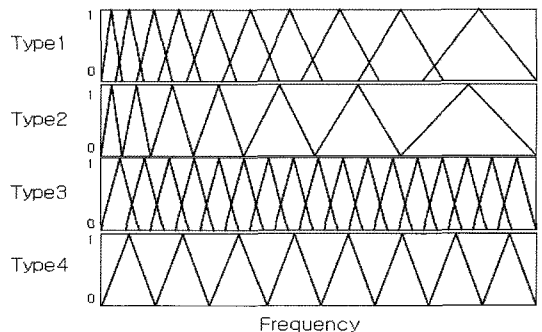


그림 1. 삼각 필터 बैं크
Fig. 1. Triangular filter bank.




그림 2. 해닝 필터뱅크
Fig. 2. Hanning filter bank.

형태를 유지하면서 최고일 때 가중치는 1, 최저일 때 가중치는 0으로 설정한다.

그림 2의 해닝 필터뱅크는 삼각 필터뱅크와 거의 모든 구성이 흡사하지만, 단지 필터모양이 삼각형이 아닌 종형을 나타내고 있다. 이는 삼각 필터뱅크보다 좀 더 유연하게 가중치를 할당한다.

MFCC에서 추출된 특징 벡터들은 K-means와 LBG 벡터 양자화를 적용해서 클러스터로 구성된다.

MFCC 특징벡터 집합 $\{x_1, \dots, x_N\}$ 으로부터 K개의 중심집합 $\{y_1, \dots, y_N\}$ 을 만들어서 x_n 이 y_n 에 가까울 경우 클러스터 X_k 에 라벨링하고, 전체 집합에 대한 K개의 클러스터 $\{X_1, \dots, X_K\}$ 로 구성한다.

새로운 클러스터들의 각각의 중심을 다음처럼 갱신한다.

$$y_i = c(X_i), i=1, \dots, K \quad (8)$$

다시 데이터와 가장 거리가 가까운 클러스터 중심과의 총 왜곡(distortion)을 구한다.

$$D = \sum_{n=1}^N d(x_n, y_{i(n)}), i(n) = k, \dots, \text{if } x_n \in X_k \quad (9)$$

왜곡이 안정적인지를 확인하기 위해서는 다음과 같은 상대적인 감소치를 체크하면 된다.

$$\Delta D = \frac{D_{prev} - D_{curr}}{D_{prev}} < 10^{-4} \quad (10)$$

2.2. EMG 패턴인식 시스템 구성

다음은 패턴에 대한 각 HMM 모델을 구성하는 과정이다^[9]. 모델 파라미터 λ 가 주어졌을 때 관측 심볼열에 대한 확률, O 는 전향 알고리즘을 이용한다.

$$P(O|\lambda) = \sum_{i=1}^N \alpha_i(t) \quad (11)$$

여기서,

$$\alpha_i(t) = \pi_i b_i(o_t) \quad 1 \leq i \leq N$$

$$\alpha_i(i) = P(o_1, o_2, \dots, o_i; i_i = q_i | \lambda)$$

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^N \alpha_i(t) a_{ij} \right] b_j(o_{t+1})$$

$$t = 1, 2, \dots, T-1, 1 \leq j \leq N$$

N개의 모델 각각에 대한 $P(O|\lambda_N)$ 는 다음과 같이 나타낼 수 있다.

$$B \triangleq [P(O|\lambda_1), P(O|\lambda_2), \dots, P(O|\lambda_N)] \quad (12)$$

HMM의 각 모델은 좌우진행형(left-to right) 모델을 사용하고 근전도 신호에 의한 근육의 수축이 발화 상태(firing state)-수축의 과도기 상태(contraction transition state)-수축의 과도기 유지 상태(contraction transition maintenance state)-수축의 정상 상태(contraction steady state)유지의 4단계를 갖는다고 가정하고 각 모델에 3개의 상태를 할당하였다. GMM 기법을 기반으로 하여 각 상태(state)를 마다 다양한 특징 벡터수를 구성해서 테스트 한다^[10,11].

j번째 영역에서, 상태별 T_j 개의 학습 벡터를 $Y_j = \{Y_{T_j=1}, \dots, Y_{T_j=T_j}\}$ 라 하면, 가우시안 성분 밀도는 M_j 성분밀도의 가중된 합으로 표현할 수 있다.

$$p(y_j|\lambda) = \sum_{i=1}^{M_j} p_{j,i} \frac{1}{(2\pi)^{\frac{1}{2}} \left| \sum_{j=1}^{M_j} \right|} \exp \left\{ -\frac{1}{2} (y_j - \mu_{j,i})^T \sum_{j=1}^{M_j} (y_j - \mu_{j,i}) \right\} \quad (13)$$

여기에서, $\mu_{j,i}$ 는 평균벡터이고, $\sum_{j=1}^{M_j}$ 는 분산행렬이다. 혼합 성분들의 가중치는 $\sum_{j=1}^{M_j} p_{j,i} = 1$ 를 만족한다.

$Y = \{Y_1, \dots, Y_K\}$ 가 주어지면, 모델을 위한 가우시안 성분 밀도 함수는 성분의 평균벡터, 공분산 행렬, 가중치로 나타낼 수 있다.

$$\lambda = \{p_{j,i}, \mu_{j,i}, \Sigma_{j,i}\} \quad i=1, \dots, M \text{ and } j=1, \dots, K \quad (14)$$

여기에서, j번째 영역의 i번째 클래스의 사후확률(A posterior probability)은 식 (15)이다.

$$p(j, i | y_i, \lambda) = \frac{p_{j,i} b_i(y_j)}{\sum_{i=1}^{M_j} p_{j,i} b_i(y_j)} \quad (15)$$

근전도 패턴 식별을 위하여, 저체중, 정상체중, 과체중, 비만의 분류는 GMM의 $\theta_1, \theta_2, \dots, \theta_8$ 로 나타내고, 패턴의 주성분 벡터를 이용하여 GMM의 최대 사후확률 값을 갖는 패턴 모델 l 을 찾을 수 있다^[12].

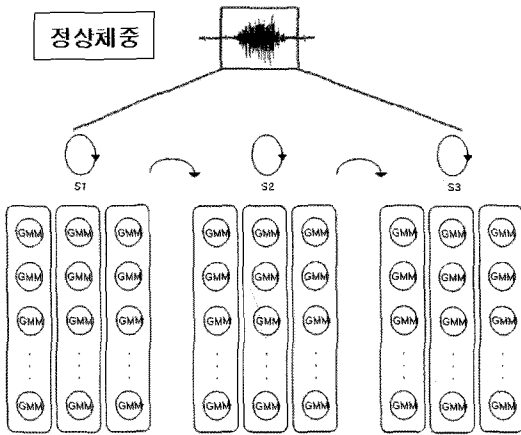


그림 3. HMM-GMM 구조(정상체중 모델)
Fig. 3. HMM-GMM composition.

$$\hat{s} = \max_{\theta} \sum_{j=1}^T \log p(y_j | \theta) \quad (22)$$

최적으로 구성된 HMM은 GMM과 함께 구성되며, 그 모델 형태는 그림 3과 같다. 저체중, 정상체중, 과체중, 비만에 대한 체중별 4개의 모델을 각각 구성한다. 그림 3은 정상체중에 대한 HMM-GMM 모델이다.

각 HMM-GMM은 좌우진행형(left-to right) 모델이며, 상태 수는 3, 특징 차수는 10~15으로 구성한다.

3. 실험 및 결과

3.1. 데이터 획득

그림 4은 복부 근전도 검출시 전극의 위치를 나타내

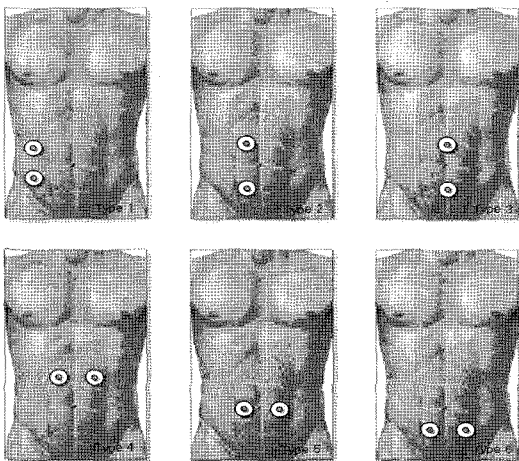


그림 4. 복부 부위별 전극위치(6가지)
Fig. 4. Electrode location for each abdominal part.




그림 5. 복부 부위별 파형(6가지)
Fig. 5. Waveform for each abdominal part.

고 있으며, 모두 6가지의 전극 위치타입으로 구성하였다. Type 1, 2, 3은 세로 방향으로 허리부터 복부의 중앙으로 이동시키면서 전극을 부착했으며, Type 4, 5, 6은 가로 방향으로 복부 위에서부터 아래로 이동시키면서 전극을 부착하였다.

이러한 설정은 다양한 복부 부위에서 얻어지는 복부 근전도 신호의 파형과 근전도 신호의 특성이 모두 상이하다는 가정 하에서 신호 분석 기법을 통해 정확한 비만도를 판별하고자 하는 것이다^[13-15].

그림 5의 경우는 각 부위별 근전도 파형이며, 표 1에서 피험자(번호 1)에 대한 여러 데이터 중 부위별 일부 파형이다. 복부 근전도 측정시 서있는 상태를 유지하면서 부위별 측정하였다. 4초 동안 복부에 힘을 준 상태와 힘을 안준 상태를 반복하면서 5번씩 측정하여 약 20초 동안 복부의 연속 EMG 신호를 획득하였다. 근전도 계측 장비 설치시 입력 채널수는 1채널로 하였으며, 전극은 Ag-Cl 일회용 전극을 사용하였다. 근전도 신호가 최대 500 Hz임을 감안해서 샘플링율은 2000 samples/s로 충분히 설정하여 데이터 획득을 수행하였다.

본 연구의 임상실험을 위해 20-30대 남성 16명의 피실험자를 대상으로 비만 정도를 조사하였다. 표 1의 각 피실험자의 개인 신체정보를 근거로 하여 표 2에서 표준체중 비만도, 체질량 지수(BMI), 복부 비만도(WHR)의 비만 측정법으로 비만 정도를 평가하였다.

각 피실험자의 검출된 복부 근전도 신호들은 3가지

표 1. 피실험자 비만도 분석 자료
Table 1. Obesity Degree Analysis Data for Testees

번호	구분	성별	나이 (세)	몸무게 (kg)	신장 (m)	허리 둘레 (cm)	엉덩이 둘레 (cm)	표준체중 (%)	비만도 (BMI)	복부 비만도 (WHR)
1	남	28	63	1.81	77	90	-13.58 (저체중)	19.23 (저체중)	0.86 (정상체중)	
2	남	30	65	1.69	83	94	4.67 (정상체중)	22.76 (정상체중)	0.88 (정상체중)	
3	남	27	67	1.78	79	95	-4.56 (정상체중)	21.15 (정상체중)	0.83 (정상체중)	
4	남	30	73	1.72	87	95	12.65 (과체중)	24.68 (과체중)	0.92 (복부비만)	
5	남	29	63	1.76	78	92	-7.89 (정상체중)	20.34 (정상체중)	0.85 (정상체중)	
6*	남	28	89	1.84	92	104	17.72 (과체중)	26.29 (비만)	0.88 (정상체중)	
7*	남	28	76	1.80	85	102	5.56 (정상체중)	23.46 (과체중)	0.83 (정상체중)	
8*	남	28	79	1.85	90	106	3.26 (정상체중)	23.08 (과체중)	0.85 (정상체중)	
9	남	27	65	1.73	80	98	-1.07 (정상체중)	21.72 (정상체중)	0.81 (정상체중)	
10*	남	29	78	1.71	89	105	22.07 (과체중)	26.67 (비만)	0.85 (정상체중)	
11*	남	27	77	1.75	79	101	14.07 (과체중)	25.14 (비만)	0.78 (사지비만)	
12*	남	26	80	1.77	92	103	15.44 (과체중)	25.54 (비만)	0.89 (정상체중)	
13*	남	29	75	1.70	83	100	19.05 (과체중)	26.00 (비만)	0.83 (정상체중)	
14	남	25	87	1.69	97	111	40.10 (비만)	30.46 (비만)	0.87 (정상체중)	
15	남	25	95	1.80	97	114	31.94 (비만)	29.32 (비만)	0.85 (정상체중)	
16*	남	28	72	1.75	89	99	6.67 (정상체중)	23.51 (과체중)	0.90 (정상체중)	

비만 측정법과 비만정도(저체중, 정상체중, 과체중, 비만)에 따라 분류하였다. 이는 각 측정법에 따른 비만도 정도가 개인마다 동일하게 측정되지 않을 수 있다.

표 1에서 1, 2, 3, 4, 5, 9, 14, 15는 표준체중 비만도와 BMI가 동일한 피험자이며, 6, 7, 8, 10, 11, 12, 13, 16은 비만도가 동일하지 않은 피험자(*)이다. WHR의 경우는 체중별 분류가 다소 어려운 관계로 본 실험에서는 비교 및 참고 데이터로 활용한다.

3.2. 실험결과

본 논문은 다음 사항을 고려하여 복부 비만도 분류 성능을 최적화하는데 적절한 설정에 대한 평가를 수행

한다.

- LPCC를 적용하여 전극위치에 따른 인식을 비교
 - 제안한 MFCC 필터 타입들에 대한 인식을 비교
- 이러한 인식을 평가를 위해 학습 데이터와 평가 데이터를 나누어서 실험에 적용하였다.
- 학습 데이터는 각 피실험자에 대해서 표준체중법과 비만도(BMI)가 동일한 피실험자(1, 2, 3, 4, 5, 9, 14, 15) 총 8명만으로 구성하였다.

평가 데이터는 다음과 같이 두 분류로 나누었다.

- 표준체중법과 비만도(BMI)가 동일한 8명 데이터
 - 전체 16명 데이터
- 학습 데이터 수는 저체중, 정상체중, 과체중, 비만에

표 2. 비만도 측정법

Table 2. Measurement methods of obesity degree

측정법	산출법	체중별 분류
표준체중 비만도	$\text{표준체중} = (\text{신장} - 100) \times 0.9$ $\text{비만도} = \frac{\text{현재체중} - \text{표준체중}}{\text{표준체중}} \times 100$	저체중: < -10 % 정상체중: -10 ~ 10 % 과체중: 10 ~ 20 % 비만: > 20 %
체질량 지수 (BMI)	$\text{체중}(\text{kg}) / \text{신장}(\text{m})^2$	저체중: < 18.5 정상체중: 18.6 ~ 22.9 과체중: 23 ~ 24.9 비만: 25 ~ 29.9
복부 비만도 (WHR)	*허리둘레/엉덩이	정상: < 0.9 과체중: > 0.9 (남성 기준)

표 3. 표준체중 비만도와 BMI가 동일한 피험자 실험

Table 3. Experiments for testees whose standard weight and BMI are the same

전극위치 체중	Type1 (%)	Type2 (%)	Type3 (%)	Type4 (%)	Type5 (%)	Type6 (%)
저체중	90	80	90	70	80	80
정상체중	70	80	80	80	80	90
과체중	80	70	70	70	80	70
비만	80	70	70	80	80	70
전체	80.00	75.00	77.50	75.00	80.00	77.50

표 4. 전체 피험자 실험

Table 4. Experiments for total testees

전극위치 체중	Type1 (%)	Type2 (%)	Type3 (%)	Type4 (%)	Type5 (%)	Type6 (%)
저체중	60	60	70	50	60	70
정상체중	60	50	60	60	70	60
과체중	60	60	60	60	50	60
비만	70	60	60	50	70	70
전체	62.50	57.50	62.50	55.00	62.50	65.00

표 5. 표준체중 비만도와 BMI가 동일한 피험자 실험

Table 5. Experiments for testees whose standard weight and BMI are the same

필터 체중	Triangular Type(%)				Hamming Type(%)			
	1	2	3	4	1	2	3	4
저체중	90	80	90	80	90	90	90	80
정상체중	80	80	80	80	80	80	80	70
과체중	90	90	80	70	80	70	80	80
비만	90	80	90	80	90	80	80	70
전체	87.50	82.50	85.00	77.50	85.00	80.00	82.50	75.00

대해 각 15개로 구성하였고, 평가 데이터는 저체중, 정상체중, 과체중, 비만에 대해 각 10개의 데이터를 할당

해서 인식률을 평가하였다.

3.2.1. LPCC 적용한 전극위치에 따른 인식을 평가

표 3과 표 4는 각 전극위치(6타입)에서 복부 EMG 신호를 검출한 후, 이들 각 신호에서 추출한 LPCC 특징벡터를 각 체중별로 분류하여 체중별 HMM-GMM 모델로 구성해서 실험한 인식결과이다. 표 3은 표준체중 비만도와 BMI가 동일한 피험자 8명에 대한 결과이며, 표 4는 전체 피험자에 대한 결과이다. 표 4의 실험의 경우 표준체중 비만도와 BMI가 동일하지 않은 피험자(8명)이 포함되어 있다. 인식결과를 산출하기 위해서 이들에 대한 비만도 기준이 요구된다. 여기서, BMI에서 평가된 비만도를 적용하였다.

표 3에서 전극위치에 따른 인식률이 상대적 높은 전극 위치는 Type 1, 3 및 5 였으며, Type 1의 경우가 가장 높은 결과를 보여준다. 표 3의 경우는 체중별 분류가 명확한 피험자를 대상으로 실험하여서 표 4와 비교하였을 경우 전체적인 인식률이 높게 나타나지만, 표 3과 표 4의 전극 타입별 비교 분석시 비슷한 결과를 확인할 수 있다.

다양한 피험자를 대상으로 표본 데이터를 수집해서 인식률 차이는 개선이 가능할 것으로 판단되며, 전체 인식률 증가에도 영향을 줄 것으로 사료된다.

3.2.2. 제안한 MFCC 필터타입에 대한 인식을 평가

LPCC 특징벡터를 적용한 실험에서 전극위치에 따른 인식을 평가를 통해서 전극 위치 Type 1, 3 및 5가 상대적으로 인식률이 높게 나타났으며, 그 중 Type 1이 가장 높은 인식결과를 보여주었다.

제안한 MFCC 필터타입 8개에 대한 인식률을 평가하기 위해서는 모든 전극위치(6타입)에 대해서 실험하지 않고 이들 전극위치 중 가장 높은 인식률이 나타난 Type 1에 대한 EMG 신호만을 적용하여 실험하였다.

전극위치 Type 1의 EMG 신호에서 8가지 필터타입을 적용한 후, MFCC 특징벡터를 추출하여 각 체중별로 분류하여 체중별 HMM-GMM 모델로 구성해서 실험한 결과는 다음 표 5와 표 6이다.

표 5의 경우는 표준체중 비만도와 BMI가 동일한 피험자를 대상으로 체중별 분류가 명확한 피험자를 대상으로 실험하였기 때문에 전체 피험자를 대상으로 한 표 6의 경우보다 인식률이 높게 평가되었다.

표 5의 인식 결과를 통하여 Triangular Types이 Hamming Types보다 인식률이 높게 평가됨을 확인할 수 있다. 특히 Triangular Types 중 Type 1과 Hamming Types 중 Type 1이 동일 타입 내에서 가장 높게 평가되었다. 즉 고주파 대역으로 갈수록 필터 뱅크의 크기가 증가하고, 필터마다 오버랩 되도록 설정한 MFCC

표 6. 전체 피험자 실험
Table 6. Experiments for total testees

필터	Triangular Type(%)				Hamming Type(%)			
	1	2	3	4	1	2	3	4
체중								
저체중	80	80	80	70	80	70	80	80
정상체중	70	60	70	70	70	70	80	60
과체중	80	70	80	60	70	60	60	70
비만	80	70	70	80	70	80	70	70
전체	77.50	70.00	75.00	70.00	72.50	70.00	72.50	70.00

의 표준 필터타입인 Type 1이 가장 인식률이 높게 나타났다. 가장 인식률이 낮은 필터타입인 Type 4의 경우 일정한 간격의 필터뱅크와 오버랩 없는 형태라는 점이다. 따라서 Type 1과 Type 4의 필터특징을 통해 복부 EMG 신호의 특징을 판단할 수 있다.

복부 EMG 신호의 주요 주파수 대역이 저주파에 주로 분포하며, 고유한 특징벡터를 검출하기 위해서는 필터뱅크 크기 규정이 무엇보다 중요하다. 그리고 고주파 대역 일수록 고유한 특징을 포함하지 못한다고 판단할 수 있다.

표 3과 표 5의 비교를 통해서 LPCC 특징벡터로 구성된 HMM-GMM보다 제한한 MFCC로 구성된 HMM-GMM이 상대적으로 인식률이 높게 평가됨을 확인할 수 있다. 따라서 MFCC 적용시 보다 적절한 필터 수와 대역폭을 설정한다면 인식률 개선에 영향을 줄 수 있을 것으로 판단된다.

4. 결 론

본 연구에서는 최근 문제시 되고 있는 비만에 대한 관심이 높아지면서 복부의 근전도 신호 분석으로 복부 근력 상태를 평가하여 비만 및 건강 상태를 관리하기 위한 측정 시스템을 제안하였다.

비만 정도를 분류시 개인의 복부 중 여러 부위마다 근력의 상태 차이 때문에 근전도 신호의 차이가 있었고, 동일한 비만 정도를 나타내는 부류일 경우라도 복부 근력의 차이로 인해 근전도 차이가 있었다.


본 연구에서 개선한 MFCC 특징 추출 알고리즘과 HMM-GMM 분류 알고리즘을 적용함으로써 복부 근전도 신호 분석만으로 비만 정도의 분류가 가능하였다. 전극위치에 따른 인식률 평가를 통해서 전극 위치 Type 1, 3 및 5가 상대적으로 인식률이 높게 나타났으며, MFCC 타입 중에서 Triangular Types이 Hamming Types보다 다소 인식률이 증가하였음을 볼 수 있었다. 그리고 LPCC보다 개선한 MFCC가 상대적으로 인식

률이 높게 평가되었다. 하지만 인식 성능을 개선하기 위해서는 더욱 정밀한 비만도 측정법과 피험자의 생활 습관 및 음식 습관 등 체계적이고 정확한 분류를 통한 실험이 요구된다.

참고 문헌


- [1] M. Solomonow, R. Baratta, BH Zhou, H. Shoji, and D'Ambrosia Robert D., "The EMG-force model of electrically stimulated muscle: dependence on control strategy and predominant fiber composition", *IEEE Trans. Biomed. Eng.*, vol. 34, no. 9, pp. 692-703, 1987.
- [2] Willis J. Tonpkins, "Biomedical digital signal processing", *Prentice Hall International Editions*, pp. 43-44, 1993.
- [3] G. Zavaliagos, Y. Zhao, R. Schwartz, and J. Makhoul, "A hybrid segmental neural net/hidden markov model system for continuous speech recognition", *IEEE Trans. Speech and Audio Processing*, vol. 2, no. 1, part II, pp. 151-152, 1994.
- [4] Lalit R. Bahl, Peter F. Brown, Peter V. de Souza, and Robert L. Mercer, "Estimating hidden markov model parameters so as to maximize speech recognition accuracy", *IEEE Trans. Speech and Audio Processing*, vol. 1, no. 1, pp. 77-78, 1993.
- [5] J. W. Kwon, Y. G. Jang, B. S. Kim, H. K. Min, and S. H. Hong, "Probabilistic-neural pattern classifier and muscle force estimation", *Proceedings of the 15th annual international Conference of the IEEE EMBS*, Sandiego, U.S.A., pp. 1145-1146, 1993.
- [6] J. W. Kwon and S. H. Hong, "The application of counterpropagation neural networks for EMG pattern classification", *'94 World Congress on Medical Physics and Biomedical Engineering*, Rio-dejaneiro, Brasil, pp. 919, 1994.
- [7] L. R. Rabiner and R. W. Schafer, "Digital processing of speech signals", *Prentice-Hall, Inc.*, pp. 359-362, 1978.
- [8] L. Rabiner and R-H Juang, "Fundamentals of speech recognition", *Prentice-Hall International, Inc.*, pp. 333-357, 1993.
- [9] K-F Lee and H-W Hon, "Speaker-independent phone recognition using hidden markov models", *IEEE Trans on Acoustics, Signal Rrocessing*. vol. 37. no. 11, November 1989.
- [10] M. Fujimoto and Y. Ariki, "Robust speech recognition in additive and channel noise environments using GMM and EM algorithm", (ICASSP '04). *IEEE International Conference on Acoustics,*

- Speech, and Signal Processing, 2004. Proceedings.*, I-941-4 vol. 1, 2004.
- [11] S. Nakagawa, W. Zhang, and M. Takahashi, "Text-independent speaker recognition by combining speaker-specific GMM with speaker adapted syllable-based HMM", (ICASSP '04). *IEEE International Conference on Acoustics, Speech, and Signal Processing*, 2004. Proceedings., I-81-4 vol. 1, May 2004.
- [12] M-T Gan, M. Hanmandlu, and A. H. Tan, "From a gaussian mixture model to additive fuzzy systems", *IEEE Transactions on Fuzzy Systems*, 303-316 vol. 13, June 2005.
- [13] J. Garcia-Casado, J. L. Martinez-de-Juan, and J. L. Ponce, "Effect of abdominal layers on surface electroenterogram spectrum", *Proceedings of the 25th Annual International Conference of the IEEE EMBS 2003*, vol. 3, pp. 2543-2546, Sept 2003.
- [14] L. M. Hinkelman, T. D. Mast, M. J. Orr, and R. C. Waag, "Effects of abdominal wall morphology on ultrasonic pulse distortion", *1997 IEEE Ultrasonics Symposium*, vol. 2, pp. 1493-1496, Oct. 1997.
- [15] H. Scharfetter, P. Brunner, M. Mayer, B. Brandstatter, and H. Hinghofer-Szalkay, "Fat and hydration monitoring by abdominal bioimpedance analysis: data interpretation by hierarchical electrical modeling", *IEEE Transactions on Biomedical Engineering*, vol. 52, pp. 975-982, June 2005.



김 정 호 (Jung-Ho Kim)

- 2005년 동명정보대학교 컴퓨터공학과 (공학사)
- 2007년 동명대학교 대학원 컴퓨터공학과 (공학석사)
- 주관심분야 : 음성-영상 처리 및 인식



권 장 우 (Jang-Woo Kwon)

- 1990년 인하대학교 전자공학(공학사)
- 1992년 인하대학교 대학원 전자공학 (공학석사)
- 1996년 인하대학교 대학원 전자공학 (공학박사)
- 현재 동명대학교 컴퓨터공학과 부교수
- 주관심분야 : 인공지능, 신호처리