

HMM-GMM 방식을 이용한 복부 근전도 분석에 관한 연구

A study on analysis of abdominal EMG using HMM-Gmm algorithm

*권장우, *김정호, *김현성, **윤동업, ***최홍호

*동명대학교 컴퓨터공학과

**부경대학교 전기공학과

***인제대학교 의용공학과

요약 : 최근 각종 질환의 원인이 되고 있는 비만은 심각한 사회문제로 대두되고 있으며, 이를 해결하기 위해 비만 관리를 위한 측정 시스템의 필요성이 증가하고 있다. 본 논문은 비만관리를 위해 복부의 근전도 신호를 분석해서 언제 어디서든 본인의 건강상태를 체크하여 적절한 의료 서비스를 받을 수 있는 측정 시스템에 관한 연구이다. 복부 근전도 신호 분석을 위해서 에너지 검출, 신호 특정 추출, 상태 분류 및 인식 등을 위한 알고리즘을 제안한다. 이 신호 분석 알고리즘을 측정 시스템에 적용하여 복부의 비만도 및 복부의 근력을 평가하여 건강상태에 대한 적절한 평가를 제공하는 시스템을 제안한다.

Key words : EMG(Electromyogram), HMM(Hidden Markov Models), GMM(Gaussian Mixture Models), Pattern Recognition, Abdominal Obesity

서 론

생체신호내부에는 질병과 관련된 적-간접적인 정보를 담고 있다. 특히, 표면 근전도(Surface Electromyogram)는 피부표면에 전극을 부착하는 무통증, 비침습적인 방식이다. 하지만 실제 복부에 대한 근전 신호의 내부에는 측정기기의 기계적 잡음, 근육수축 시 표면전극에서 입력되는 외부잡음, 주위환경에서 발생된 잡음을 등이 존재한다.[1] 그러한 잡음을 실시간으로 예측하여 제거하기가 어렵다는 문제점이 있고, 만약 제거를 수행하여도 원 신호를 손상시켜서 근전신호의 고유성을 훼손 할 수 있다. 따라서 고유한 특징을 검출함에 있어 상당한 어려움이 따른다. 이는 오차율 증가의 주요 원인이 된다. 또한, 각 개인의 근전신호 형태가 매우 다양하고, 동일인이라도 근의 분포상태, 전극의 부착 위치에 따라서 근전신호가 다양하게 출력된다. 따라서 정확한 패턴 분류에도 상당한 영향을 미친다.

기존의 근전도 패턴 인식을 위한 특징 추출 과정에서는 주로 LPCC(Linear Predictive Cepstral Coefficients), 영교차율(Zero-Crossing), 절대적분치(Integral of Absolute, IAV), AR(Autoregressive), Spike(극파), 근육의 피로도 등이 다양하게 적용되고 있으며 이들 비선형 시스템의 시간영역에서 근전 신호를 주로 분석하기 때문에 잡음이 내포될 경우 인식률의 저하를 초래한다.[2]

이러한 근전신호의 특징을 분류하기 위한 분류기로 인공신경회로망인 MLP(Multilayer Perceptron), SOFM(Self-Organizing Feature Map) 있다. 이들 분류기는 정적인 신호의 인식에는 뛰어나지만 동적인 신호의 처리에는 적합하지 못하다는 단점을 가지고 있다. 근전도 신호는 시변성이 강한 일종의 불규칙 신호라 볼 수 있으므로 확률 모델의 적용이 적합하다. 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 확률분포에 기반하는 HMM(Hidden Markov Models) 등을 단일 또는 혼합(Hybrid)하여 패턴 인식 시스템을 구성한다.

일반적으로 HMM은 음성 연구 분야에서 활발한 연구가 진행되어오고 있었으며,[3] 신경회로망과의 결합을 통하여 상호간의 장점을 중대시키기 위한 시도가 이루어져 오고 있다.[4] 그러나 생체 신호가 가지고 있는 특성이 다른 분야에서 제안하고 있는 합성 시스템에 적합하지 못하므로, 생체 신호의 특성을 잘 반영하는 시스템의 구성이 필요하다.

따라서 본 논문에서는 복부 비만과 관련한 생체 신호 중 복부 근전도 신호를 획득한다. 그리고 LPCC 특징 추출 기법을 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 비만도 별로 분류하였다.

본 론

1. EMG 패턴인식 시스템 구성

다음은 패턴에 대한 각 HMM 모델을 구성하는 과정이다.[5] 모델 파라미터 λ 가 주어졌을 때 관측 심볼열 O 에 대한 확률, $P(O | \lambda)$ 는 전향 알고리즘을 이용한다.

$$P(O|\lambda) = \sum_{i=1}^N a_i P_i \quad (1)$$

여기서

$$\begin{aligned} a_1(i) &= \pi b_i(o_1) \quad 1 \leq i \leq N \\ a_i(i) &= R(o_1, o_2, \dots, o_i; i = q_i | \lambda) \\ a_{i+1}(j) &= [\sum_{i=1}^N a_i(i) a_{ij}] b_j(o_{i+1}) \\ i &= 1, 2, \dots, T-1, \quad 1 \leq j \leq N \end{aligned}$$

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

$$B \triangleq [P(O|\lambda_1), P(O|\lambda_2), \dots, P(O|\lambda_N)] \quad (2)$$

그림 1은 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 steady state)-수축의 정상 상태(contraction steady state) 유지의 4단계를 갖는

다고 가정하고 각 모델에 3개의 상태를 할당하였다. GMM 기법을 기반으로 하여 각 상태(State)들마다 다양한 특징 벡터수를 구성해서 테스트 한다. [6] [7]

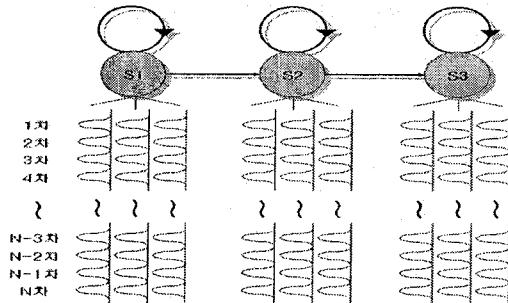


그림 1. HMM-GMM 구성

j 번째 영역에서, 상태 열 T_j 개의 학습 벡터를 $Y_j = \{Y_{t_j-1}, \dots, Y_T Y_{t_j-T}\}$ 라 하면, 가우시안 성분 밀도는 M_j 성분 밀도의 가중된 합으로 표현할 수 있다.

$$p(y_{t_j} | \lambda) = \sum_{i=1}^M p_{j,i} \frac{1}{(2\pi)^{\frac{D}{2}} |\Sigma_{j,i}|^{\frac{1}{2}}} \exp\left(-\frac{1}{2} (y_{t_j} - \mu_{j,i})^T \Sigma_{j,i}^{-1} (y_{t_j} - \mu_{j,i})\right) \quad (3)$$

여기에서, $\mu_{j,i}$ 는 평균 벡터이고 $\Sigma_{j,i}$ 는 분산 행렬이다. 혼합 성분의 가중치는 $\sum_i p_{j,i} = 1$ 를 만족한다.

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

$$\lambda = \{p_{j,i}, \mu_{j,i}, \Sigma_{j,i}\} \quad i=1, \dots, M \text{ and } j=1, \dots, K \quad (4)$$

여기에서, j 번째 영역의 i 번째 클래스의 사후 확률 (A posterior probability)은 식 (5)이다.

$$p(j, i | y, \lambda) = \frac{p_{j,i} b_i(y_{t_j})}{\sum_i p_{j,i} b_i(y_{t_j})} \quad (5)$$

근전도 패턴 식별을 위하여, 저체중, 정상체중, 과체중, 비만의 분류는 GMM의 $\theta_1, \theta_2, \dots, \theta_c$ 나타내고, 패턴의 주성분 벡터를 이용하여 GMM의 최대 사후 확률 값을 갖는 패턴 모델을 찾을 수 있다.

$$\hat{s} = \max \sum_{i=1}^T \log(p(j, i | y, \lambda)) \quad (6)$$

최적으로 구성된 HMM은 GMM과 함께 구성되며. 그 모델 형태는 그림 2와 같다. 저체중, 정상체중, 과체중, 비만에 대한 체중별 4개의 모델을 각각 구성한다. 각 HMM-GMM은 좌우진행형(left-to right) 모델이며, 상태 수는 3, 특징 차수는 10~15으로 구성한다.

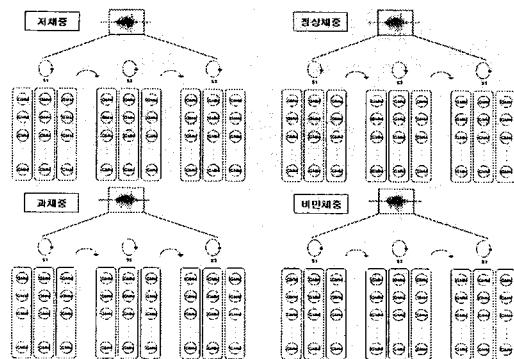


그림 2. 체중별 HMM 형

실험 및 결과

1. 데이터 획득

그림 3은 복부 근전도 검출시 전극의 위치를 나타내고 있으며, 모두 6가지의 전극 위치 타입으로 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.

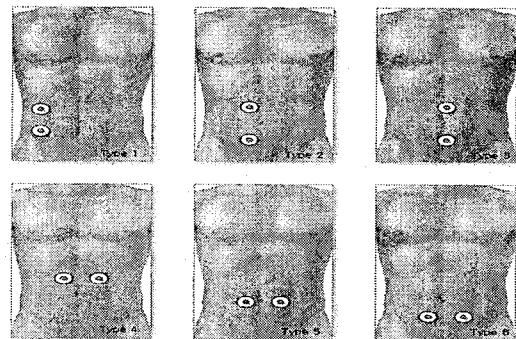


그림 3. 복부 부위별 전극 위치(6가지)

복부 근전도 측정시 서있는 상태를 유지하면서 부위마다 자발적으로 복부에 힘을 준 상태와 힘을 안준 상태를 4초 간격으로 주기적 측정하여 약 20초 동안 복부의 연속 EMG 신호를 획득하였다. 근전도 계측 장비 설정시 입력 채널수는 1채널로 하였으며, 전극은 Ag-Cl 일회용 전극을 사용하였다. 근전도 신호가 최대 500Hz임을 감안해서 샘플링율은 2000samples/s으로 설정하여 데이터 획득을 수행하였다.

본 연구의 임상실험을 위해 20~30대 남성 16명의 피실험자를 대상으로 비만 정도를 조사하였다. 각 피실험자의 개인 신체 정보를 근거로 하여 표준체중법, BMI, WHR의 비만 측정법으로 비만 정도를 평가하였다.

각 피실험자의 검출된 복부 근전도 신호들은 3가지 비만 측정법과 비만 정도(저체중, 정상체중, 과체중, 비만)에 따라 분류하였다. 표 1에서 표준체중법과 비만도(BMI) 측정 시 피실험자 번호 6, 7, 8, 10, 11, 12, 13, 16은 비만도가 동일하지 않았다.

WHR의 경우는 대부분이 정상체중으로 평가되어 체중별 분류를 할 수 없는 관계로 인해 본 실험에서 제외하였다.

표 1. 피실험자 비만도 분석 자료

번호	성별	나이(세)	체중(kg)	신장(cm)	체지방률(%)	LPCC	BMI	복부비만도(%)
1	남	28	63	181	77	90	25.53	15.23 (정상체중)
2	남	30	65	169	83	94	25.27	22.76 (정상체중)
3	남	27	67	178	79	95	24.88	21.16 (정상체중)
4	남	30	73	172	87	95	22.66	21.63 (정상체중)
5	남	29	63	176	78	92	27.33	23.34 (정상체중)
6*	남	28	89	184	92	104	27.72	25.25 (정상체중)
7*	남	28	76	180	85	102	25.48	25.48 (정상체중)
8*	남	28	79	185	90	106	25.25	25.25 (정상체중)
9	남	27	65	173	80	98	24.77	21.72 (정상체중)
10*	남	29	78	171	89	105	22.77	22.67 (정상체중)
11*	남	27	77	175	79	101	24.03	25.34 (정상체중)
12*	남	26	80	1.77	92	103	16.44 (과체중)	26.64 (비만) (정상체중)
13*	남	29	75	1.70	83	100	19.05 (과체중)	28.00 (비만) (정상체중)
14	남	25	87	1.69	97	111	40.10 (비만)	50.48 (비만) (정상체중)
15	남	25	95	1.80	97	114	61.84 (비만)	28.62 (비만) (정상체중)
16*	남	28	72	1.75	89	99	6.57 (정상체중)	28.81 (과체중) (정상체중)

2. 실험 결과

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

- LPCC을 적용하여 전극위치에 따른 인식률 비교 이러한 인식률 평가를 위해 학습 데이터와 평가 데이터를 나누어서 실험에 적용하였다. 학습 데이터는 각 피실험자에 대해서 표준체중법과 비만도(BMI)가 동일한 피실험자 번호 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 대해 각 15개로 구성하였고, 평가 데이터는 저체중, 정상체중, 과체중, 비만에 대해 각 10개의 데이터를 할당해서 인식률을 평가하였다.

3. LPCC 적용한 전극위치에 따른 인식률 평가

표 2. 표준체중법과 BMI가 동일한 피실험자 실험 (단위 : %)

전극위치	Type 1	Type 2	Type 3	Type 4	Type 5	Type 6
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 3. 전체 피실험자 실험 (단위 : %)

전극위치	Type 1	Type 2	Type 3	Type 4	Type 5	Type 6
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

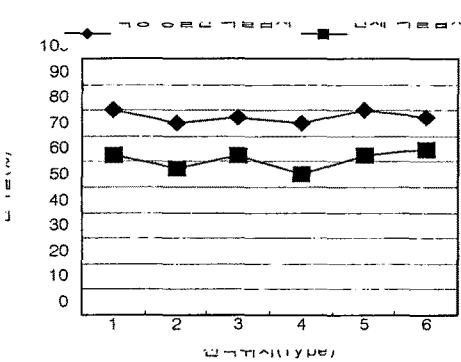


그림 4. 동일한 피실험자와 전체 피실험자 실험 비교 그래프

표준체중법과 BMI가 동일한 피실험자 실험과 전체 피실험자 실험을 비교하였을 경우 전체적인 인식률 차이를 나타내지만, 전극 타입별 비교 분석시 비슷한 결과를 나타냄을 볼 수 있다.

그림 4에서 표준체중법과 BMI가 동일한 피실험자 실험과 전체 피실험자 실험에서 인식률의 차이가 발생함을 관측할 수 있다. 이는 많은 피실험자를 대상으로 표본 데이터를 수집하게 되면 되면 그 인식률 차이는 개선될 것이며, 전체 인식률 증가에도 영향을 줄 것으로 판단된다.

결론

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

비만 정도를 분류시 개인의 복부 중 여러 부위마다 균력의 상태 차이 때문에 균전도 신호의 차이가 있었고, 동일한 비만 정도를 나타내는 부류일 경우라도 복부 균력의 차이로 인해 균전도 차이가 있었다. 본 연구에서 LPCC특정 추출 알고리즘과 HMM-GMM 분류 알고리즘을 적용함으로써 복부 균전도 신호 분석만으로 비만 정도의 분류가 가능하였다. 전극위치에 따른 인식률 평가를 통해서 전극 위치 Type 1, 3, 5이 상대적으로 인식률이 높게 나타났다. 하지만 인식 성능을 개선하기 위해서는 더욱 정밀한 비만도 측정법과 피실험자의 생활 습관 및 음식 습관 등 체계적이고 정확한 분류를 통한 실험이 요구된다.

향후 다양한 생체 신호 모니터링을 위한 신호 계측 기술, 데이터를 효율적으로 전송을 위한 데이터 압축 및 유/무선 네트워크 기술, 의료 기관과 사용자 간의 다양한 의료 서비스 제공 등 다양한 관련 기술들에 대한 연구가 선행되어야 한다.

참 고 문 헌

- [1]Moshe Solomonow et al, "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. Zavaliagkos, et al., "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]Kai-Fu Lee, and Hsiao-Wuen Hon, "Speaker–Independent Phone Recognition Using Hidden Markov Models", IEEE Trans on Acoustics, Signal Rrocessing. vol.37. No.11, November 1989
- [6]Masakiyo Fujimoto, Yasuo 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
- [7]Seiichi Nakagawa, Wei Zhang, Mitsuo 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