

Hidden Markov Model을 이용한 심음분류에 관한 연구

A Study on Classification of Heart Sounds Using Hidden Markov Models

김희근*, 정용주*
(Kim Hee-Keun*, Chung Young-Joo*)

*계명대학교 전자공학과

(접수일자: 2006년 1월 27일; 수정일자: 2006년 3월 16일; 채택일자: 2006년 3월 20일)

심장병이 있는 환자들을 진료할 때 의사들은 청진기를 이용하여 심음 (heart sound)을 듣고 이를 기준으로 환자의 병의 유무나 질환의 종류에 대한 기초적인 판단을 하게 된다. 하지만, 심음은 환자의 상태나 외부 잡음의 영향에 따라서 신호의 특성이 변하고 또한 정상적인 심음과 질병을 나타내는 심음과의 차이가 비교적 구분하기 어려울 정도로 작기 때문에 숙달된 전문의가 아니면, 진단의 정확도가 떨어질 가능성이 있다. 따라서 신호처리 기법을 이용하여 심음을 분석해서 심음이 정상적인지의 유무를 자동으로 판단할 수 있다면, 진단을 하는 의사들에게 유용한 정보가 될 것이라 생각된다. 본 연구에서는 심음의 질병유무와 질병종류를 자동으로 판단하기 위해서 기존에 많이 사용되었던 artificial neural network (ANN) 대신에 hidden Markov model (HMM)을 사용하는 방법을 제안하였으며, 기초적인 실험결과 상당히 우수한 성능을 보임을 알 수 있었다.

핵심용어: HMM, 심음인식, 신호처리, 심장병

투고분야: 생체 및 의학음향 분야 (15)

Clinicians usually use stethoscopic auscultation for the diagnosis of heart diseases. However, the heart sound signal has varying characteristics due to the noise and/or the conditions of the patients. Also, it is not easy for junior clinicians to find the acoustical differences between different kinds of heart sound signals, which may result in errors in the diagnosis. Thus it will be quite useful for the clinicians to make use of an automatic classification system using signal processing techniques.

In this paper, we propose to use hidden Markov models in stead of artificial neural networks which have been conventionally used for the automatic classification of heart sounds. In the experiments classifying heart sound signals, we could see that the proposed methods were quite successful in the classification accuracy.

Keywords: Heart Diseases, Heart Sounds, Diagnosis, Hidden Markov Models, Neural Networks

ASK subject classification: Biological and Medical Acoustics (15)

I. 서론

심음은 심장이 혈액을 순환시키는 과정에서 나는 소리로, 심장병을 진단하는데 중요한 역할을 한다. 그래서 의사들은 청진기로 심음에 나타나는 심잡음 (heart murmur)과 click을 듣고 병의 유무나 종류를 진단하게

된다[1]. 그러나, 정상적인 심음과 심장병이 있는 심음의 차이를 숙달된 전문의가 아니면 구분하기가 어려운 경우가 가끔 발생하는데, 심음에 능숙하지 못한 의사들을 위해서 진찰을 도와주는 자동심음진단 시스템이 있다면 오진의 가능성도 줄일 수 있고 심음을 공부하는데 있어서도 많은 도움이 될 것이다[2]. 본 연구에서는 심음진단을 위한 기초 연구로서 HMM을 이용한 심음 모델링에 대해서 논의하고자 한다. 2장에서는 심음신호의 개요에 대해서 소개하고 3장에서는 HMM을 이용한 심음의 모델링

책임저자: 정용주 (yjjung@kmu.ac.kr)
704-701 대구시 달서구 신당동 1000 계명대학교 전자공학과
(전화: 053-580-5925)

방법에 대해서 설명하며 4장에서는 심음인식 실험결과를 나타내며 끝으로 5장에서는 결론을 맺는다.

II. 심음신호의 개요

인간의 심장은 2개의 심실 (ventricle)과 2개의 심방 (atrium)을 가지고 있다. 그리고 내부에는 4개의 판막 (승모판: mitral valve, 삼첨판: tricuspid valve, 대동맥판: aortic valve, 폐동맥판: pulmonary valve)이 심장내 혈액의 역류를 막고 있으며, 대동맥과 폐동맥 등의 여러 주요 혈관과 연결되어 있다 (그림 1). 그리고 심장은 수축 (systole)과 이완 (diastole)을 통해서 혈류를 발생시키는데, 이완기에서는 심방과 심실사이에 존재하는 방실판 (atrioventricular valve, 그림 1에서 A)은 개방되고 반월판은 폐쇄되며, 수축기에서는 주요 혈관들과 연결된 반월판 (semilunar valve, 그림 1에서 B)은 개방되고 방실판은 폐쇄된다. 이 때 혈액은 방실판이 개방되면서 심방에서 심실로 흐르고 반월판이 개방되면서 심실에서 주요 혈관으로 사출된다.

심음의 한 사이클은 그림 2에서 보는 바와 같이 S1-systole-S2-diastole의 순서로 이루어지는데, 일상에서 많이 들을 수 있는 심장의 박동소리는 S1과 S2에서 들리는 소리이다. S1과 S2는 판막의 폐쇄에 의해서 발생

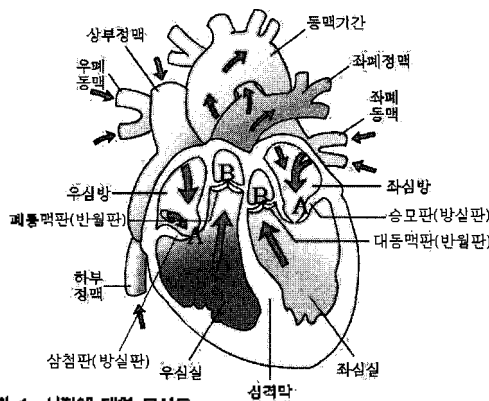


그림 1. 심장에 대한 묘사도
Fig. 1. A sketch of the heart.




그림 2. 심음에 대한 파형의 예
Fig. 2. An example of the waveform of the heart sound.

하는데, S1은 방실판에 의해서, S2는 반월판에 의해서 발생된다. 한편, Systole과 diastole에서는 정상적인 심음에서 거의 소리가 들리지 않지만, 심장병을 가진 심음에서는 심잡음과 click이 들린다. 심잡음과 click은 심장 구조의 결함 및 판막이상 등에 의해서 발생하는 경우가 많기 때문에, 심장병의 유무나 종류를 진단하는데 있어서 중요한 역할을 한다[4]. 한편, 청진기를 이용한 진단에서 심잡음과 click은 신체부위에 따라 소리의 선명함이 달라서, 의사들은 미리 정해진 몇몇의 신체부위를 진단한다.

III. 심음의 모델링

3.1. Hidden Markov Model

본 연구에서는 심음을 모델링하기 위해서 연속밀도 HMM의 left-to-right 형태를 사용하였고 상태 (state) 개수를 심음의 구조에 따라서 결정하였다.

HMM은 음성인식분야에서 널리 이용되고 있는 통계적 모델로써, Markov chain 구조의 여러 개의 상태 (state) 들로 구성되어 있다 (그림 3)[10]. 각 상태는 관측열을 발생시킨다는 가정을 하며, 발생관측벡터에 대한 고유한 확률분포를 가진다. 상태 j 에서 관측벡터 O_t 에 대한 확률분포 $b_j(O_t)$ 는 가우시안 분포의 혼합형태로 규정되어지며, 다음식과 같다.

$$b_j(O_t) = \sum_{m=1}^M c_{jm} \mathcal{N}(O_t, \mu_{jm}, \Sigma_{jm}) \quad (1)$$

여기서 M 은 혼합성분의 개수를 나타내며, c_{jm} 은 각 혼합성분에 대한 가중치이고, $\mathcal{N}(O_t, \mu_{jm}, \Sigma_{jm})$ 은 평균값이 μ_{jm} 이고 공분산값이 Σ_{jm} 인 가우시안 확률밀도 함수 (Gaussian probability density function)이다. 상




그림 3. Left-to-Right형의 HMM
Fig. 3. The left-to-right HMM.

태간의 천이는 천이확률값으로 규정되며 상태 i 에서 상태 j 로의 천이확률값은 a_{ij} 로 표시된다.

HMM 파라미터의 훈련을 위해서는 주어진 훈련용 관측열 (여기서는 심음으로부터 얻어진 특징벡터), $O = (O_1, O_2, \dots, O_T)$ 에 대해서 likelihood $P(O|\lambda)$ 가 최대가 되도록 λ 값을 추정하여야한다. 여기서 λ 는 앞에서 언급된 상태별 관측 확률분포 함수의 파라미터값들과 상태 천이확률값 등을 의미한다. 대표적인 HMM 파라미터 추정 방법으로는 EM (Expectation-Maximization) 방식에 기반을 둔 Baum-Welch 알고리즘이 있으며[14], 본 연구에서는 구현의 복잡성 때문에 Baum-Welch 알고리즘을 간소화시킨 segmental K-means 훈련방식을 이용하였다[5]. 그림 4는 segmental K-means 알고리즘에 기반한 훈련과정에 대한 흐름도를 보여주고 있다. 먼저, 심음데이터가 주어지면, 이를 이용하여 HMM 모델링에 적합한 특징벡터를 추출하게 된다. 이러한 특징벡터를 이용하여 HMM 파라미터를 추정하기 위해서는 파라미터 값에 대한 초기치를 먼저 설정해 주게 된다. 초기값을 설정해주기위해서는 전체 훈련데이터를 각 상태별로 균등 분할하여 각 상태별 확률분포에 대한 평균값과 분산 값을 정해 주게 된다[5]. 이러한 초기값이 설정되면, EM 방식에 따른 파라미터 재추정과정이 이루어

지게 된다. 한편, 재추정된 HMM 파라미터 값은 저장된 후 추후 인식과정에서 사용되게 된다.

인식과정은 주어진 입력 특징벡터열 O 에 대해서 최대의 $P(O|\lambda)$ 값을 나타내는 HMM이 어느 클래스에 해당하는지를 찾아내는 것이다. $P(O|\lambda)$ 를 계산하기 위해서는 forward-backward 알고리즘을 이용해야 하지만 [10], 이 방식은 연산량이 많기 때문에 $P(O|\lambda)$ 의 로그값에 대한 근사치를 간편하게 얻을 수 있는 Viterbi 알고리즘을 그 대신에 사용한다[10].

심음의 구조는 S1-systole-S2-diastole의 순서로 4가지 요소를 구성하고 있으며, 각 요소마다 1개의 상태를 가지도록 하였다. 하지만, 보유한 심음데이터는 그림 2와 같이 처음과 마지막에 2개의 diastole을 가지고 있는데, 훈련과정의 편의를 위해서 이 2개는 서로 다른 요소로 보았다. 따라서 심음은 전체 5개의 요소로 구성되었다고 가정을 하고 HMM 모델의 상태 개수를 5개로 하였다 (그림 5). 그리고 각 상태별 확률분포함수의 혼합 성분 (mixture component) 개수는 실험을 통하여 선정하였는데 그 개수가 10 개일 때 최대의 인식성능을 보임을 알 수 있었다.

IV. 심음인식에 관한 실험

4.1. 데이터 수집

실험을 위한 데이터는 심음 분류 능력을 기르기 위해서 발행된 교육용 오디오 CD에서 수집하였다[11]. 주어진 오디오 CD에 심음은 44.1 KHz 샘플링율과 16bit의 분해도로 저장되어 있었으며 이것을 다시 다운 샘플링하여 16 KHz, 16bit RAW 데이터 파일로 변환하였다. 총 10종류의 심장병에 대한 심음데이터를 수집하였으며 데이터 개수는 표 1과 같다. 한 개의 심음 데이터당 심음의

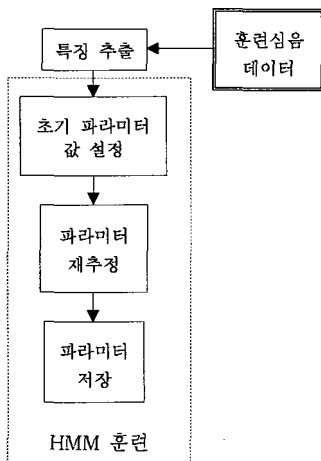


그림 4. 심음신호를 이용한 HMM 훈련 과정.
Fig. 4. Training procedure of HMMs using heart sound signals.




그림 5. HMM과 심음파형과의 관계
Fig. 5. Relationship between the HMM and the heart sound waveform.

표 1. 심음의 종류와 해당 데이터의 수
Table 1. The kinds of heart sound signals and the number of data

심음	데이터 개수
normal sound	15
innocent murmur	14
Aortic Regurgitation(AR)	14
Aortic Stenosis(AS)	18
Coarctation of the Aorta(CA)	20
Mitral Regurgitation(MR)	21
Mitral Stenosis(MS)	14
Mitral Valve Prolapse(MVP)	13
Tricuspid Regurgitation(TR)	20
Ventricular Septal Defect(VSD)	10

길이는 수백 밀리 초 정도가 되며, 특징분석을 위해서 프레임 간격을 2.5ms로 정하였다.

4.2. 특징추출

본 연구에서 사용한 특징 (feature)으로는 FFT (fast Fourier transform) 결과로부터 얻은 필터뱅크 (filterbank) 특징과 MFCC (mel-frequency cepstrum coefficients) 특징이 있다. 특징을 얻는 구체적인 과정은 다음과 같다.

먼저, 심음신호 $s(n)$ 을 길이가 N 인 Hamming 윈도우 함수 $w(n)$ 에 곱하여 신호 $x(n)$ 을 얻는다.


$$x(n) = s(n) w(n) \tag{2}$$

$$w(n) = \begin{cases} 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right), & 0 \leq n \leq N-1 \\ 0, & \text{otherwise} \end{cases} \tag{3}$$


그리고, $x(n)$ 에 대해서 N -포인트 FFT (Fast Fourier Transform)을 취하여 X_k 값을 얻는다.

$$X_k = \sum_{n=0}^{N-1} x(n) e^{-j\frac{2\pi}{N}nk}, \quad 0 \leq k \leq N-1 \tag{4}$$


이때, 필터뱅크출력 $b_j, j=1, \dots, B$ 를 얻기 위해서 전체 주파수 범위($k=1, \dots, N$)을 mel-scale[13]에 맞추어 B개로 비균등 분할한 후, j 번째 영역에 해당하는 $X(k)$ 값들을 더해 주게 된다. 이와 같이 얻은 $b_j, j=1, \dots, B$ 값들은 필터뱅크 출력으로 사용하게 되며, 필터뱅크 출력의 로그 (log)값을 DCT (Discrete Cosine Transformation)변환하여 아래와 같이 MFCC $c_j, j=1, \dots, C$ 값을 얻게 된다. 여기서, B 와 C는 각각 필터뱅크 특징벡터와 MFCC 특징벡터의 차원을 나타내며 본 논문에서는 18 과 13 으로 정하였다[13].



(a) 혼합성분의 개수가 1개인 경우.



(b) 혼합성분의 개수가 5개인 경우.



(c) 혼합성분의 개수가 10개인 경우.

그림 6. 혼합성분의 개수의 변화에 따른 분할정보의 변화
Fig. 6. Segmentation results in the Viterbi decoding as the number of mixture components increases.

$$c_j = \sqrt{\frac{2}{B}} \sum_{i=1}^B \log(b_i) \cos\left(\frac{j\pi}{B}(i-0.5)\right) \tag{5}$$

이러한 MFCC는 음성인식분야에서 자주 사용되는 특징이며, 본 연구에서도 심음신호의 인식을 위해서 필터뱅크 출력과 함께 사용해 보았다.

4.3. 심음의 분할정보

심음이 HMM에 의해서 적절히 모델링 되는지 알기 위한 하나의 근거로서 Viterbi 알고리즘을 통해 구해지는 상태 시퀀스 정보가 있다. 본 연구에서 사용한 segmental K-means 훈련방식은 훈련하는 동안 Viterbi 알고리즘을 실행하고 있다. 따라서 훈련과정동안 구해진 상태 시퀀스 정보를 통해 모델의 각 상태가 심음의 요소를 잘 나타내는지 알아보았다. 또한 상태별 혼합성분의 개수가 상태 시퀀스 정보에 미치는 영향을 알아보기 위해서, 혼합성분의 개수를 변화시키며 훈련을 수행하였다. 그림 6에서는 혼합성분의 개수에 따라 변화하는 상태 시퀀스와 심음 파형과의 일대일 매칭 관계를 보여주고 있다. 그림 6을 보면 혼합성분이 증가함에 따라서 상태 시퀀스가 심음의 요소들을 더 정확하게 분류해 주고 있으며, 혼합성분의 개수가 10일 때 심음의 요소들을 가장 잘 분류해 주고 있음을 알 수 있다.

4.4. Artificial neural network (ANN)

현재 심음분류의 많은 연구는 인공지능분야에서 이루어지고 있으며, ANN이 가장 대표적으로 이용되고 있다 [6-7-8]. ANN은 여러 개의 퍼셉트론 (perceptron)으로 이루어진 층(layer)들이 feed forward 망을 형성한 것이다. 층의 종류로는 입력층 (input layer), 출력층 (output layer), 은닉층 (hidden layer)이 있으며, 주로 1개의 은닉층을 사용한 형태 (입력층-은닉층-출력층)의 ANN을 사용한다[9]. 본 연구에서는 기존의 연구를 참고하여 입력층, 은닉층, 출력층의 퍼셉트론 수가 210개, 20개, 10개로 구성된 ANN을 인식실험에 사용하였으며 [6], 실험의 결과를 HMM의 결과와 비교하였다.

4.5. 심음신호의 주파수 특성

심음신호의 주파수 특성을 알아보기 위해서 FFT를 이용하여 각 심음에 대한 에너지 스펙트럼을 구하였다. 조사한 에너지 스펙트럼에는 심음의 전체 사이클을 FFT한 것과 매 프레임별로 FFT한 것이 있는데, 두 가지의 에너

지 스펙트럼을 동시에 고려한 이유는 ANN과 HMM의 입력으로 이용되는 특징벡터와 밀접한 관련이 있다. ANN의 경우에는 일반적으로 심음의 전체 사이클에 대한 에너지 스펙트럼을 입력으로 이용하는데, 그림 7에는 주파수에 따른 전체 사이클 에너지 스펙트럼의 변화가 도시되어 있다.

그림 7에서 보는 것과 같이 각 심음에서 에너지가 대부분 0~300Hz 사이에 집중되어 있는 것을 볼 수 있지만, 간혹 질병에 따라 약 600Hz 부근 까지 에너지가 존재하는 것을 볼 수 있다. 한편, ANN과는 달리 HMM의 입력에는 매 프레임별로 구한 에너지 스펙트럼을 이용하고 있는데 그림 8에서 이를 나타내고 있다.

그림 8은 매 20 프레임마다 평균한 에너지 스펙트럼값을 시간에 따라 나타낸 것이다. 그림 8(a)는 정상심음에 대한 평균 에너지 스펙트럼을 나타내고 있으며 약 200과

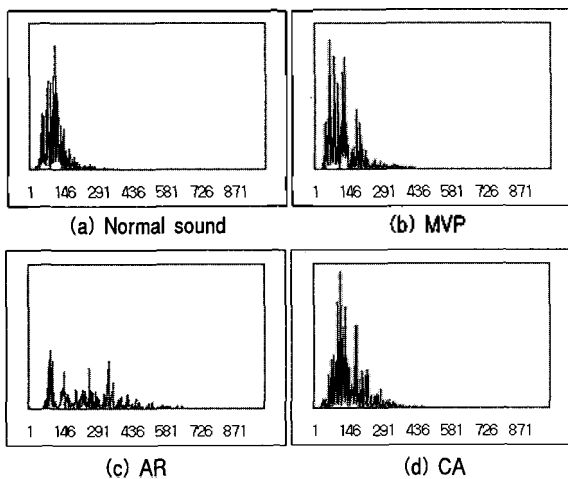


그림 7. 한 사이클 심음의 에너지 스펙트럼
Fig. 7. Energy spectrum corresponding to a cycle of the heart sound signal.

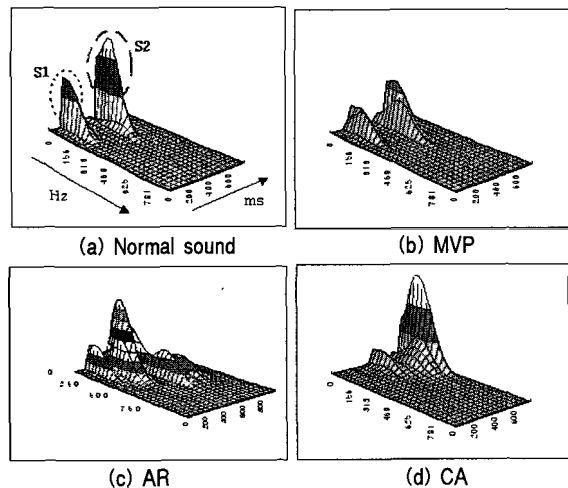


그림 8. 심음신호의 프레임별 스펙트럼의 변화
Fig. 8. Energy spectrum variation with the time frame.

600ms에서 스펙트럼의 에너지값이 비교적 눈에 띄게 큰 것을 볼 수 있다. 이는 S1과 S2를 나타내고 있는 것이며 S1과 S2는 약 300Hz까지의 주파수 범위를 가짐을 알 수 있다. 앞의 정상심음과는 달리 질병이 있는 심음에서는 systole과 diastole에 심잡음이 존재한다. 그래서 그림 8(c)와 8(d)를 보면 S1과 S2이외의 구간에서 심잡음의 에너지가 상당히 있는 것을 볼 수 있으며, 약 600Hz 부근까지 에너지가 존재하고 있음을 확연히 알 수 있다.

4.6. 인식실험

심장병이 있는 심음들과 정상인 심음 그리고 심장병처럼 의심되는 심음으로 구성된 데이터를 이용하여 인식 실험을 하였다. 심음의 종류는 총 10가지로 비교적 다양하지만 각 종류별로의 데이터 수가 적어서, 적은 데이터에도 신뢰성 있는 결과를 얻을 수 있는 Jack-knife 방식을 이용하여 인식실험을 하였다. Jack-knife 방식에서는 전체 심음 데이터 중에서 1개만 인식용 데이터로 사용하고 나머지는 훈련용 데이터로 사용하는데, 이러한 과정을 반복하여 모든 데이터가 반드시 한번 씩 인식용 데이터로 사용되게 함으로서 실험데이터가 작은 경우보다 신뢰성 있는 인식결과를 얻을 수 있게 해준다. 예를 들어, 전체 20개의 심음데이터가 있는 경우, 이중에 19개는 훈련용으로 사용하고 나머지 1개는 인식용으로 사용된다. 이러한 과정이 20번 반복되어 인식결과의 신뢰도를 높게 된다. 실험은 먼저 제안된 HMM 기반의 인식기에서 MFCC를 입력 특징벡터로 한 경우와 필터뱅크 출력을 입력 특징벡터로 한 경우를 서로 비교하였으며, 사용된 에너지 스펙트럼의 주파수 범위는 가능한 넓게 잡아서 200~6400(Hz)의 범위로 하였다. 이 실험에 대한 결과는 표 2에 나타나있다.

표2의 비교란에서 분모의 숫자는 인식실험에 사용된 각 심음별 데이터의 전체개수이고 분자의 숫자는 이 중에서 정확인 인식된 심음데이터의 개수를 말한다. 표 2에 의하면 두 가지 특징을 각각 사용한 인식결과가 서로 비슷하지만 필터뱅크 특징의 경우가 특정한 한 질병에서 인식이 더 좋은 것을 볼 수 있다. 이러한 결과를 통하여 보았을 때, MFCC 특징은 필터뱅크 특징에 비해서 심음의 특성을 나타내는데 있어서 특별히 유리하다고 판단되지 않으므로, 향후 실험에서는 필터뱅크 출력을 기본 특징벡터로 사용하였다.

심음의 에너지 스펙트럼을 보면 거의 대부분의 에너지가 약 600Hz 내에서 존재하고 있으며, 비록 적은 양이

표 2. 심음신호 인식에서 HMM의 특징벡터의 종류에 따른 인식결과
Table 2. The classification results depending on the feature vectors.

심음	MFCC		필터뱅크	
	인식률(%)	비교	인식률(%)	비교
normal sound	100	15/15	100	15/15
innocent murmur	92.86	13/14	92.86	13/14
AR	100	14/14	100	14/14
AS	100	18/18	100	18/18
CA	100	20/20	95	19/20
MR	100	21/21	100	21/21
MS	100	14/14	100	14/14
MVP	76.92	10/13	92.31	12/13
TR	100	20/20	100	20/20
VSD	100	10/10	100	10/10
전체 평균	97.48	155/159	98.11	156/159

표 3. 필터뱅크 출력에서 주파수 범위를 다르게 한 경우의 인식 결과
Table 3. The classification results depending on the frequency ranges in the construction of the filter bank outputs.

범위(Hz)	전체평균(%)	비교
0~900	99.37	158/159
0~210	98.74	157/159
0~420	98.11	156/159
200~900	99.37	158/159
200~300	98.11	156/159
30~900	98.74	157/159

표 4. ANN을 이용한 경우의 인식 결과
Table 4. The classification results of the ANN.

범위(Hz)	전체평균(%)	비교
0~210	93.08	148/159
0~420	90.56	144/159

지만 900Hz 부근까지도 에너지가 존재하는 것을 알 수 있었다. 따라서 비교적 다양한 주파수 범위에 대해서 특징을 추출하여 인식실험을 행하였다. 실험에 이용된 주파수 범위로는 0~900(Hz), 0~210(Hz), 0~420(Hz), 200~900(Hz), 200~300(Hz), 30~900(Hz) 가 있으며 각 범위에 따른 실험 결과는 표 3에 나타난다.

표 3의 결과를 보면 0~900(Hz)와 200~900(Hz)의 범위에서 99.37%로 가장 좋은 인식률을 보이고 있지만, 나머지 주파수 범위의 결과들과도 큰 차이를 보이고 있지는 않다. 결과가 전체적으로 매우 좋은 인식률을 보이고 있는데, 이는 HMM이 심음분류에 있어서 기본적으로 우수한 성능을 가지고 있다는 것을 말한다고 생각된다. 본 연구에서는 HMM의 성능과 비교하기 위해서 ANN을 이용한 인식실험도 하였다. 기존의 연구에서 0~210(Hz)의 주파수 범위를 이용할 것을 권고하고 있기 때문에[6], 본 연구에서는 확인하는 의미에서 0~210(Hz),

0~420(Hz) 두 가지 범위로 인식 실험을 하였다.

표 4의 결과에 따르면 ANN의 결과는 0~210Hz의 주파수 범위를 이용할 때 더 좋은 결과를 보였다. 이를 표3의 HMM의 결과와 비교한다면 HMM은 전체적으로 약 98% 정도의 인식율을 나타낸 반면 ANN의 경우에는 약 93% 인식율을 보임으로서 HMM에 비해서는 상당히 저조한 성능을 보임을 알 수 있다. 이러한 결과는 음성과 같은 동적인 패턴의 인식에서 우수한 성능을 보이는 HMM의 효율성이 심음신호에 대해서도 그대로 성립함을 보여주는 것이라 생각된다.

V. 결론

본 연구에서는 HMM을 이용한 심음모델링과 심음분류에 대해서 제안하였다. 이는 기존의 연구에서 사용되던 ANN이 심음과 같은 동적인 패턴에 대한 인식에 다소 부적합하다는 생각에 기반 하였다. 인식실험 결과, 제안한 HMM을 이용하였을 경우, ANN을 이용한 기존의 방식에 비해서 월등한 인식성능을 보임을 알 수 있었다. 이러한 결과는 심음이 시간적으로 매우 변화가 심한데 그 원인이 있으며, HMM이 이러한 변화를 모델링하는 우수한 성능을 보임을 확인할 수 있었다.

감사의 글

“본 연구는 산업자원부 지역연구개발클러스터구축사업 중 경북대학교 첨단 진단/예측 의료기술 클러스터 사업단의 연구비 지원을 받아 수행되었음.”

참고 문헌

1. T.S. Leung, P.R. White, W.B. Collis, E. Brown, A.P. Salmon, "Classification of heart conditions based on heart sounds," Proceedings of the 12th International Congress on Condition Monitoring and Diagnostic Engineering Management, Sunderland, UK, .335-342, 1999.
2. Todd R. Reed, Nancy E. Reed and Peter Fritzson, "The analysis of heart sounds for symptom detection and machine-aided diagnosis", Proceeding of Eurosım2001, ISBN: 90-806441-1-0, 2001.
3. T.S.Leung, P.R.White, J.Cook, W.B.Collis, E.Brown, A.P.Salmon, "Analysis of the second heart sound for

diagnosis of paediatric heart disease," IEE Proceedings - Science, measurement and technology, 145(6), 285-290, 1998.

4. T.S.Leung, P.R.White, W.B.Collis, E.Brown, A.P.Salmon, "Acoustic diagnosis of heart diseases," Proceedings of the 3rd international conference on acoustical and vibratory surveillance methods and diagnostic techniques, Senlis, France, 389-398, 1998.
5. L. R. Rabiner, J. G. Wilpon, and B. H. Juang, "A segmental k-means training procedure for speech recognition," IEEE Trans. ASSP, 2033-2045, Dec. 1990.
6. DeGroff C, Bhatikar S, Hertzberg J, Shandas R, Valdes-Cruz L, Mahajan R, "Artificial neural network-based method of screening heart murmur in children," Circulation 103, 2711-6, 2001.
7. Bhatikar S, DeGroff C, Mahajan R, "A classifier based on the artificial neural network approach for cardiology auscultation in pediatrics," Artificial Intelligence in medicine, 34, Issue 1, 65-76, May 2005.
8. Cather I, "Neural network assisted cardiac auscultation", Artificial Intelligence in medicine, 7, 53-66, 1995.
9. Richard P. Lippmann, "An introduction to computing with neural nets", ACM SIGARCH Computer Architecture News, 16, issue 1, 7-25, 1988.
10. L. R. Rabiner, "A tutorial on hidden Markov model and selected applications in speech recognition," IEEE Proc., 77, 257-286, Feb. 1989.
11. Daniel Mason, *Listening to the heart: A Comprehensive Collection of Heart Sounds and Murmurs*, (F. A. Davis Company, Philadelphia, 2000)
12. 김희근, 정용주, 남재철, 김윤년, "Hidden Markov Model을 이용한 심음분류에 관한 연구", 한국음향학회 학술발표대회 논문집 22(1), 51-54, 2005.
13. Davis S. B. and Mermelstein P. "Comparison of parametric representation for monosyllabic word recognition in continuously spoken sentences", IEEE Trans. Acoust., Speech, Signal Processing, 28, 357-366, 1980.
14. L. E. Baum, G. S. T. Petrie and N. Weiss, "A maximization technique occurring in the statistical analysis of probabilistic functions of Markov chains", Ann. Math. Statist., 41, 164-171, Jan. 1970.

● 정용주 (Yong-Joo Chung)

1988년 2월: 서울대학교 전자공학과 (공학사)
 1990년 2월: 한국과학기술원 전기및전자공학과 (공학석사)
 1995년 8월: 한국과학기술원 전기및전자공학과 (공학박사)
 1992.9~1999.2: LG전자 연구원
 1999.3~현재: 계명대학교 전자공학과 교수
 *주관심분야: 음성인식, 패턴인식, 통계적신호처리

저자 약력

● 김희근 (Hee-Keun Kim)



2005년 2월: 계명대학교 전자공학과(공학사)
 2005년 3월~현재: 계명대학교 전자공학과 석사과정
 *주관심분야: 음성신호처리, 생체신호처리