

SVM을 이용하여 HMM과 심잡음 점수를 결합한 심음 기반 심장질환 분류기

Heart Sound-Based Cardiac Disorder Classifiers Using an SVM to Combine HMM and Murmur Scores

곽 철*, 권 오 욱*
(Chul Kwak*, Oh-Wook Kwon*)

*충북대학교 전자정보대학 제어로봇공학과

(접수일자: 2010년 12월 9일; 수정일자: 2011년 2월 11일; 채택일자: 2011년 3월 23일)

본 논문은 support vector machine (SVM)을 사용하여 은닉 마코프 모델 (HMM)과 심잡음 존재 정보를 결합한 새로운 심장질환 분류 방법을 제안한다. 캡스트럼 특징과 HMM 비터비 (Viterbi) 알고리즘을 이용하여 입력 신호를 모든 심장질환 모델에 대하여 상태 단위로 분할하여 상태별로 로그우도 (점수)를 계산한다. 심잡음 신호의 시간적 위치 특성을 이용하기 위하여 입력신호를 두 개의 부대역으로 나누고 부대역별로 프레임 단위의 심잡음 점수를 계산한 다음, 비터비 알고리즘으로부터 구한 상태 분할 정보를 이용하여 상태단위의 심잡음 점수를 구한다. SVM은 모든 심장질환 종류에 대한 상태 단위의 HMM과 심잡음 점수를 입력으로 하여 최종적으로 심장질환을 판정한다. 심장질환 분류 실험결과, 제안한 방법은 기존의 캡스트럼 특징과 HMM 분류기를 이용한 방법에 비하여 20.4 %의 상대적 개선율을 보여준다.

핵심용어: 심장질환 분류, 심잡음 확률, 상태단위의 HMM 로그우도, 심잡음 로그우도

투고분야: 생체 및 의학 음향 분야 (15.4)

In this paper, we propose a new cardiac disorder classification method using an support vector machine (SVM) to combine hidden Markov model (HMM) and murmur existence information. Using cepstral features and the HMM Viterbi algorithm, we segment input heart sound signals into HMM states for each cardiac disorder model and compute log-likelihood (score) for every state in the model. To exploit the temporal position characteristics of murmur signals, we divide the input signals into two subbands and compute murmur probability of every subband of each frame, and obtain the murmur score for each state by using the state segmentation information obtained from the Viterbi algorithm. With an input vector containing the HMM state scores and the murmur scores for all cardiac disorder models, SVM finally decides the cardiac disorder category. In cardiac disorder classification experimental results, the proposed method shows the relatively improvement rate of 20.4 % compared to the HMM-based classifier with the conventional cepstral features.

Keywords: Cardiac disorder classification, HMM state score, Murmur score

ASK subject classification: Biological and Medical Acoustics (15,4)

I. 서론

현재 심장질환은 선진국뿐만 아니라 우리나라에서도 가장 중요한 사망 원인이다. 전 세계적으로는 물론 국내에서도 급격한 경제적 성장에 의한 사회생활 변화, 생활 습관 서구화, 평균수명 증가로 인하여 고령화 사회로의

변화와 심장질환의 증가를 가져왔다. 심장질환은 대부분 치명적이고 심한 후유증을 남기는 질병이기 때문에, 휴대용 및 가정용의 간단한 진단 시스템은 심장질환의 조기 발견에 유용하다.

심장질환 진단 방법으로는 심전도 검사와 심초음파 검사가 있다. 심전도 검사는 비교적 정확하나 시간과 비용이 많이 소요되며, 심초음파 검사는 비만환자나 폐질환자에게는 좋은 영상을 얻을 수 없다 [1]. 따라서 전자청진기로 획득한 심음신호를 이용한 심장질환 검사가 개

발된다면, 환자에게는 예방과 조기발견으로 시간과 비용을 줄여 주고, 내과 의사에게는 의심 환자에 보다 더 집중하게 함으로서 정신적 육체적 부담을 경감해 줄 수 있다.

기존의 심장질환 분류기는 크게 인공 신경회로망 (artificial neural network; ANN)을 이용한 방법 [2-4] 과 은닉 마코프 모델 (hidden Markov model; HMM)을 이용한 방법 [5-8]으로 나누어진다. ANN을 이용한 방법으로, 이산 웨이블릿 변환 (discrete wavelet transform; DTW)를 이용하여 웨이블릿 계수를 추출하고 grow-and-learn (GAL)과 다층 퍼셉트론 역전파 (multilayer perceptron-backpropagation; MLP-BP) ANN을 이용하거나 [2], 4차 웨이블릿 커널을 이용한 특징과 역전파 신경회로망을 이용하였으며 [3], 또한 고속 푸리에 변환 (fast Fourier transform; FFT)과 ANN을 이용한 심장질환 분류시스템을 제안하였다 [4].

HMM을 이용한 심장질환 분류 기술로는 심음신호로부터 스펙트럼 특징들을 추출하고 HMM으로 심장질환을 분류하거나 [5], 심음신호의 시간적 특징을 검출하고 complexity-based estimator와 HMM을 이용하거나 [6], 심음신호 포락선의 평균과 분산에서의 상호간의 변화를 이용하였다 [7].

심장질환을 분류하는데 있어서 심잡음의 위치와 주파수 특성이 중요하다. 기존 연구 [2-5]에서는 스펙트럼 (spectrum) 또는 캡스트럼 (cepstrum) 기반 특징을 이용하였으나, 이는 심장질환 분류에 중요한 심잡음 (murmur)을 평활하게 하므로 분류 정확도를 떨어뜨린다. 한편 기존 연구 [6-7]는 시간적 특징들을 이용하였으나, 심잡음의 시간적 위치가 동일한 심음신호에 대해서는 오분류가 발생하기 쉽다. 따라서 본 논문에서는 캡스트럼 특징과 심잡음의 시간적 위치 특성을 결합하고자 한다.

본 논문에서는 한 주기의 심음신호로부터 멜주파수 캡스트럼 계수 (MFCC)를 추출하고, 두 개의 부대역으로부터 심잡음 확률을 추가한다. 각 심장질환에 대하여 MFCC 특징과 HMM을 이용하여 각 심장질환에 대한 상태단위의 HMM 로그우도 (점수)를 계산하고 상태 분할 결과를 획득한다. 각 심장질환에 대한 심잡음의 시간적 위치 특성을 이용하기 위하여, 상태 분할 결과로부터 상태단위의 심잡음 점수를 획득한다. SVM의 변별적 성능을 적용하기 위하여, 상태단위의 HMM 점수와 심잡음 점수는 support vector machine (SVM) [12-13]에 입력되어 최종적인 심장질환이 결정된다.

2절에서는 MFCC와 HMM을 이용한 기본 알고리즘을 설명하고, 3절에서는 본 논문에서 제안한 심잡음 확률을

추가하고 상태단위의 HMM 점수와 심잡음 점수를 이용한 심장질환 분류 알고리즘 기법을 설명한다. 4절에서는 다양한 파라미터 설정에 의한 심장질환 분류정확도를 비교하고, 상태단위의 HMM 점수와 심잡음 점수를 이용한 심장질환 분류기를 평가한다. 5절에서 결론을 맺는다.

II. 기본 알고리즘

2.1. 전체 구조

HMM을 이용한 기본 심장질환 분류 알고리즘은 그림 1 (a)와 같이 구성되고 본 논문에서 제안한 심장질환 분류 알고리즘은 그림 1 (b)와 같이 구성된다. 입력신호로부터 한 주기의 심음신호를 추출하는 것은 이전 연구 [9-10]에서 제안한 방법을 사용하였다.

2.2. MFCC

심음신호는 1 kHz 이하의 주파수 영역에 에너지가 크게 분포하므로 2 kHz로 다운샘플링 하였다. 윈도우 크기 (window size)는 N ms, 이동 크기 (shift size)는 M ms를 사용한다. 전체 주파수 범위를 멜 척도 (mel-scale)에 따라서 분할하여 필터뱅크 계수를 계산한다. 필터뱅크 출력값에 log값을 취한 후 이산 코사인 변환 (discrete cosine transform; DCT)을 하여 K 차 MFCC와 로그에너지를 얻는다 [15]. 심음의 동적 특성을 고려하여 MFCC의 1차, 2차 미분 계수를 추가한다. 본 논문에서는 윈도우 크기, 이동 크기, MFCC 차수 (order)는 컴퓨터 실험을 통해 결정된다.

2.3. HMM

각 심장질환에 대한 상태단위의 점수를 계산하고 상태 분할 결과를 획득하기 위하여 HMM 패턴분류기를 사용

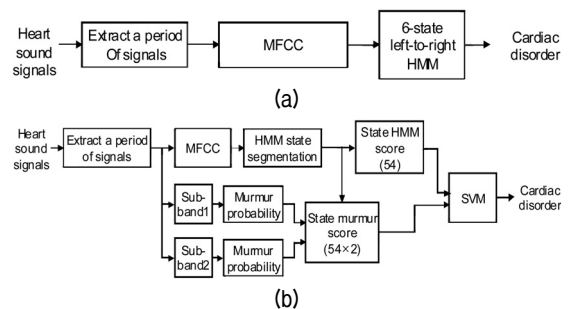


그림 1. 심음 분류 알고리즘 (a) 기본 알고리즘 (b) 제안한 알고리즘
 Fig. 1. Heart sound classification algorithms (a) Baseline algorithm (b) Proposed algorithm.




그림 2. 6개의 상태를 갖는 좌우 HMM 구조
Fig. 2. Structure of 6-state left-to-right HMM.

한다. 심잡음은 수축초기잡음 (early systolic murmur), 수축후기잡음 (late systolic murmur), 확장초기잡음 (early diastolic murmur), 확장후기잡음 (late systolic murmur)으로 나누어진다 [16]. 따라서 심음신호의 제1음 (S1)과 제2음 (S2)은 한 개의 상태로 표현되고 심장수축기 (systole)와 심장확장기 (diastole)는 두 개의 상태로 표현되므로, 한 주기 심음신호는 6개의 상태 천이 (state transition)로 이루어진다. 단일 주기 심음신호는 규칙적인 파형을 가지므로 심음 모델은 시간 천이 특성을 잘 모델링할 수 있는 좌우 HMM으로 모델링된다. 본 논문에서는 그림 2와 같이 시작과 끝 상태가 더미 상태 (dummy state)를 가지는 6 상태 좌우 HMM (6-state left-to-right HMM)을 사용한다. 심음신호의 음향 모델을 학습하기 위하여 균일 분할의 초기 조건으로부터 시작하여 5회의 전향-후향 (forward-backward) 알고리즘을 수행한다 [15]. HMM의 상태 개수, 가우시안 분포 개수는 컴퓨터 실험을 통해 결정된다.

III. 제안한 알고리즘

3.1. 상태단위의 HMM 점수

상태단위의 HMM 점수는 각 상태에서의 로그우도 (log-likelihood)를 의미한다. 심장질환은 심잡음과 클릭음의 위치에 의해 판단되므로 각 상태들 간의 캡스트럼 특징을 반영하여야 한다. 모델단위의 HMM 점수는 각 상태들 간의 캡스트럼 특징을 나타낼 수 없으므로 심잡음의 위치 특성을 반영할 수 없으나, 상태단위의 HMM 점수는 각 상태들 간의 캡스트럼 특징을 나타낼 수 있으므로 심잡음의 위치정보를 포함할 수 있다. 따라서 본 논문에서는 심장질환 모델에 따른 각 상태들 간의 캡스트럼 특징을 분석하기 위하여 각 심장질환에 대한 상태단위의 HMM 점수를 계산한다.

Viterbi 분할 알고리즘 [15]은 상태 분할 결과와 각 모델 A_i 에서의 상태단위의 HMM 점수를 얻기 위하여 사용된다. 9가지 심장질환에 대한 6 개의 상태별 점수와 상태 분할 결과를 획득한다. 각 모델 A_i 에서의 상태단위의





그림 3. 심음신호의 특성

(a) 시간 영역: S1 (500-650 샘플), S2 (1,100-1,200 샘플), 심잡음 (1,200-1,900 샘플) (b) 스펙트럼 영역: 제1음/제2음 (20-200 Hz), 심잡음 (200-700 Hz)

Fig. 3. Characteristic of heart sound signals.

(a) Time domain: S1 (500-600 samples), S2 (1,100-1,200 samples), murmur (1,200-1,900 samples) (b) Spectral domain: S1/S2 (20-200 Hz), murmur (200-700 Hz)

HMM 점수 $L_{HMM}(i, j)$ 는 아래와 같다.

$$L_{HMM}(i, j) = \sum_{t=1}^T \log p(x_t | s_t^i = j, A_i), \quad i = 1 \dots 9, j = 1 \dots 6 \quad (1)$$

s_t^i 는 i 번째 심장질환 모델에서 HMM 분류기로부터 획득한 상태 분할 결과에 따른 시간 t 에서의 상태 인덱스 (index)이다. i 는 심장질환의 인덱스를 표시하고 j 는 HMM 상태의 인덱스를 표시한다. 본 논문에서는 총 54개의 상태단위의 HMM 점수를 획득한다.

3.2. 상태단위의 심잡음 점수

이전 연구 [11]에서는 시간영역 특징을 분석하기 위하여 심음 포락선, 심잡음 확률벡터, 심잡음 진폭값 변동을 계산하였으나, 입력신호의 심잡음 위치만을 검출하므로 각 심장질환에 따른 심잡음 위치 특성을 반영할 수 없었다. 따라서 본 논문에서는 심잡음의 위치와 존재를 포함하기 위하여 심잡음 확률을 계산하고 각 심장질환에 따른 심잡음 위치 특성을 반영하기 위하여 상태단위의 심잡음 점수를 계산한다.

비정상적인 심음신호는 심장수축기 또는 심장확장기

에서 심잡음 (또는 클릭음)의 존재에 따라 심장질환의 종류가 달라진다. 심음신호의 스펙트럼 또는 캡스트럼 영역의 특징은 심잡음의 포락선을 평활하게 하기 때문에 심잡음의 시간적 위치 특성이 약해진다. 따라서 심장질환을 분류하기 위해서는 심잡음의 위치정보와 각 심장질환 모델에서의 상태단위의 심잡음 점수를 검출을 해야 한다.

그림 3은 비정상 심음 신호의 시간 및 주파수 영역의 특성을 보여준다. 그림 3 (a)와 같이 약 500~650 샘플 사이에 존재하는 제1음과 약 1,100~1,200 샘플 사이에 존재하는 제2음은 그림 3 (b)와 같이 20~200 Hz에 주성분이 분포하고, 그림 3 (a)와 같이 약 1,200~1,900 샘플 사이에 존재하는 심잡음 신호는 그림 3 (b)와 같이 200~700 Hz에 주성분이 분포한다 [16]. 심음신호와 심잡음은 감마분포 (gamma distribution) 형태를 가진다.

본 논문에서는 심장질환 종류에 중요한 심잡음의 위치를 검출하기 위하여 각 프레임에서의 심잡음 확률을 계산한다. 한 주기 심음신호로부터 제1음과 제2음의 정상심음 대역과 심잡음 대역을 가지도록 두 개의 부대역으로 나누고 부대역 신호의 각 프레임에서의 평균 절대값 x 를 계산한다.

$$x = \frac{1}{T} \sum_{t=1}^T |s(t)| \quad (2)$$

$s(t)$ 는 부대역 신호의 t 번째 샘플값이고 T 는 프레임 크기이다.

감마 확률분포 함수는 가우시안 확률분포 함수보다 샘플 값이 0 또는 양수를 갖는 평균 절대값을 더 잘 모델링하기 때문에, 평균 절대값의 분포로서 감마 함수를 사용한다. 정상심음 클래스 (ω_1)와 심잡음 클래스 (ω_2)는 각각 감마 확률분포로 모델링된다. 감마 확률분포 함수의 파라미터를 구하기 위하여 비교사학습 클러스터링 (unsupervised clustering) 방법 [14]을 이용한다. 각 프레임에서의 심잡음 사후확률 $p(\omega_2|x)$ 은 다음과 같이 계산된다.

$$p(x|\omega_i) = x^{k_{\omega_i}-1} \frac{e^{-x/\theta_{\omega_i}}}{\theta_{\omega_i}^{k_{\omega_i}} (k_{\omega_i}-1)!}, \quad i = 1, 2 \quad (3)$$

$$p(\omega_2|x) = \frac{p(x|\omega_2)}{p(x|\omega_1) + p(x|\omega_2)} \quad (4)$$

k 는 정수값을 가지는 감마 함수의 형상 (shape) 파라미터이고 θ 는 척도 (scale) 파라미터이다. $p(x|\omega_i)$ 는 i 번

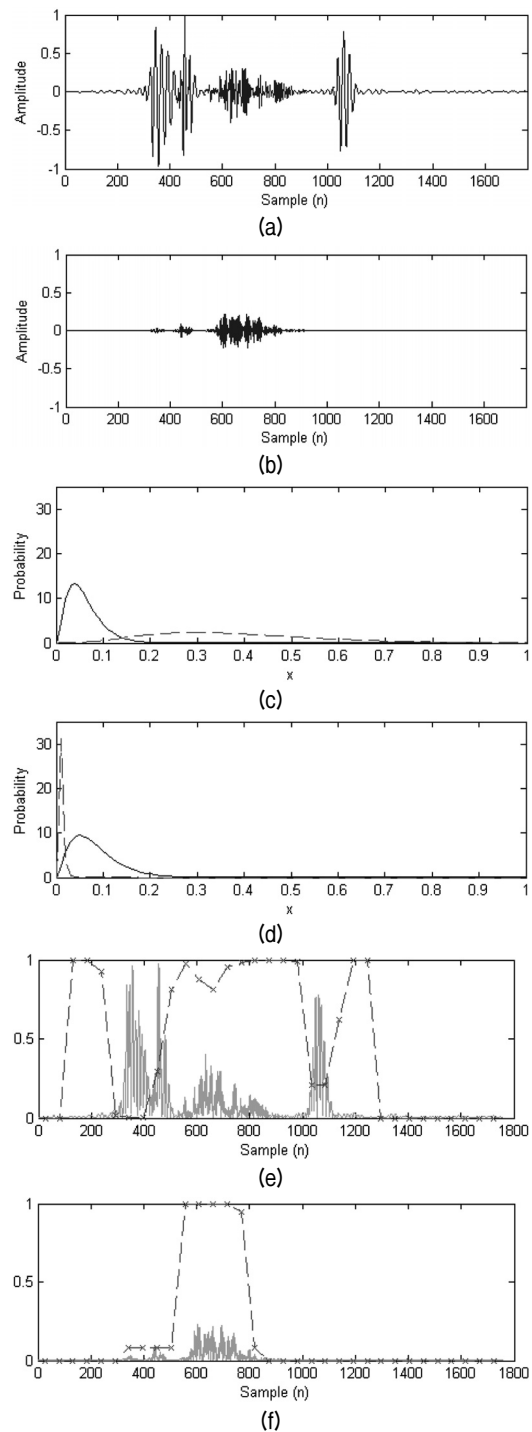


그림 4. 심잡음 확률 계산 예제 (a) 부대역 필터 1의 출력 신호 (b) 부대역 필터 2의 출력 신호 (c) 부대역 1 출력 신호의 감마 확률분포 (d) 부대역 2 출력 신호의 감마 확률분포 (e) 부대역 1의 절대값 (실선)에 겹쳐진 심잡음 확률 (점선) (f) 부대역 2의 절대값 (실선)에 겹쳐진 심잡음 확률 (점선)

Fig. 4. An example of murmur probability computation. (a) output signal of sub-band filter 1 (b) output signal of sub-band filter 2 (c) gamma distributions of sub-band 1 output signal (d) gamma distributions of sub-band 2 output signal (e) murmur probabilities (dotted line) and mean absolute values (solid line) of sub-band 1 (f) murmur probabilities (dotted line) and mean absolute values (solid line) of sub-band 2

째 클래스의 감마확률 분포이다. 그림 4는 실제 심음 신호에 대하여 부대역의 심잡음 확률 계산의 예를 나타낸 것이다. 그림 4 (a)와 4 (b)는 20~200 Hz의 부대역 1과 200~700 Hz의 부대역 2로 필터링 된 심음신호이다. 그림 4 (c)와 4 (d)는 두 부대역의 감마 확률분포를 나타내었다. 심음 클래스는 점선으로 표시하고 심잡음 클래스는 실선으로 표시하였다. 그림 4 (e)와 4 (f)는 두 부대역의 심잡음 확률을 나타내었다. 심잡음 확률은 점선으로 표시하고 필터링된 심음신호의 절대값은 실선으로 표시하였다.

본 논문에서는 심장질환 분류정확도를 향상시키기 위하여 심잡음 구간에서의 각 심장질환에 대한 통계적 특성을 계산한다. 상태단위의 심잡음 점수 $L_{MP_k}(i, j)$ 는 HMM을 이용하여 획득한 상태 분할 결과를 통해 프레임 단위의 심잡음 점수를 누적함으로써, 9가지 심장질환에 대한 두 개의 부대역별로 6개의 상태 단위의 심잡음 점수를 획득한다.

$$L_{MP_k}(i, j) = \sum_{t=1}^T \log p(\omega_2 | x_t, s_t^i = j | A_i), \quad k=1 \dots 2 \quad (5)$$

$$i=1 \dots 9, j=1 \dots 6$$

k 는 부대역의 인덱스이다. 본 논문에서는 총 108개의 상태단위의 심잡음 점수를 획득한다.

3.3. SVM

HMM-SVM 결합을 이용한 다른 응용분야의 이전 연구 [12-13]에서는 SVM 분류기의 입력벡터로서 모델단위의 HMM 점수를 사용하였으나, 본 연구에서는 모델단위의 HMM 점수 대신에 각 모델의 상태단위의 HMM 점수를 사용하고, 심장질환 분류에 적합한 상태단위의 심잡음 점수를 추가하였다. SVM 패턴분류기는 상태단위의 HMM 점수와 상태단위의 심잡음 점수를 이용하여 심장질환을 분류한다.

SVM [14]은 고차원 특징 공간으로 입력 패턴을 사상시킬 수 있고 적은 양의 학습데이터만으로도 신속하게 분리 학습을 수행할 수 있다. 네트워크의 가중치는 선형 부등 조건을 가진 이차식 계획법 (quadratic programming; QP) 문제의 해로서 얻어진다. 학습 모델로는 알려지지 않은 확률분포를 갖는 데이터에 대해 오분류 확률을 최소화하는 구조적 위험 최소화 (structural risk minimization; SRM) 방법을 이용하였다. SVM의 입력 벡터는 상태단위의 HMM 점수와 심잡음 점수이고, 출력노드는 9가지 심장질환을 나타낸다. SVM의 커널 함수로는 방사기저 함

수 네트워크 (radial-basis function network; RBFN) 커널을 사용하고, trade-off 가중치 C 는 실험을 통해 500으로 설정하고, one-against-all 전략을 사용하여 멀티 클래스로 확장하였다.

IV. 실험 결과

4.1. 심음 데이터

외부에서 입수한 교육용 오디오 시디 (CD) [16], 워싱턴 의과대학의 공개 데이터베이스 [17], 텍사스 심장협회의 공개 데이터베이스 [18]로부터 정상 및 비정상 심음 신호를 추출하고, 추가적으로 자체적으로 수집한 심음 신호를 추가하여 본 연구에서 사용된 심음 데이터베이스를 구축하였다. 외부에서 입수한 데이터베이스에는 내과의사에 의해 판정된 심장질환 종류가 제공되어 있으며, 자체적으로 수집한 심음 신호에는 심장질환 환자가 한명도 없었다.

정상적인 심음 신호에서는 심장수축기 (systole)와 심장확장기 (diastole)에서 거의 소리가 들리지 않지만, 비정상적인 심음 신호에서는 심잡음 (murmur)과 클릭음 (click sound)이 들린다. 비정상적인 심음 신호는 심잡음의 위치에 따라서 여러 질환으로 구분할 수 있다. 심장수축기에 심잡음이 존재하는 심장질환에는 대동맥판 협착 (aortic stenosis; AS), 승모판 역류 (mitral regurgitation; MR), 심실강모 결손 (ventricular septal defect; VSD)의 질환들이 있고 심장확장기에 심잡음이 존재하는 심장질환에는 대동맥판 역류 (aortic regurgitation; AR), 승모판 협착 (mitral stenosis; MS)의 질환들이 있다. 심장수축기에 클릭음이 존재하는 심장질환에는 승모판 탈출 (mitral valve prolapse; MVP)의 질환이 있다 [16].

실험에 사용된 심음 데이터베이스는 다수의 주기를 포함하는 연속 심음 신호로 구성된다. 연속 심음 신호는 각 주기별로 시간 및 주파수 특성의 변동이 적으므로, 본 논문에서는 연속 심음 신호로부터 추출한 단일 주기 심음을 사용하였다. 실험에 사용된 정상 및 심장질환별로 나누어진 심음 데이터의 개수는 표 1과 같다.

비정상적인 심음 데이터의 개수가 적으므로 전체 160개의 심음 데이터에서 159개의 심음 데이터는 학습용 데이터로 사용하고 1개의 심음 데이터만 인식용 데이터로 사용하였다. 적은 데이터를 이용하여도 신뢰성 있는 인식 결과를 얻을 수 있는 교차검증 (cross-validation) 방식을 이용하여 인식용 데이터를 바꾸어 가면서 이러한 과정을 반복함으로써, 모든 데이터가 반드시 한 번씩 인

표 1. 심장질환 종류와 데이터 수

Table 1. Heart disorder categories and the number of heart sound data.

심장질환 종류		심음 데이터 개수
정상 (N)		80
비정상	대동맥판 역류 (AR)	6
	대동맥판 협착 (AS)	9
	대동맥판 합성 (AR+AS)	12
	승모판 역류 (MR)	9
	승모판 협착 (MS)	12
	승모판 합성 (MR+MS)	5
	승모판 탈출 (MVP)	14
	심실강모 결손 (VSD)	13
	소계	80

식용 데이터로 사용되도록 하였다.

SVM의 입력벡터는 54개 상태단위의 HMM 점수와 108개의 상태단위 심잡음 점수와 1의 값을 가지는 바이어스 (bias)를 포함하여 163차원이다.

4.2. 심장질환 분류

본 논문에서는 아래와 같이 분류 정확도 (classification accuracy)를 정의하였다.

$$Acc = \frac{N_T - N_E}{N_T} \times 100 \quad (6)$$

N_T 는 입력 데이터의 개수이고 N_E 는 오분류 개수이다.

표 2는 다양한 윈도우와 이동 크기에 따른 9가지 심장질환 종류에 대한 분류 정확도이다. 본 논문에서는 39차 MFCC를 가지고 다양한 윈도우 크기에 따른 심장질환 분류 성능을 비교한 결과 표 2와 같이, 75 ms 윈도우 크기와 25 ms 이동 크기를 사용하였을 경우에 가장 높은 정확도를 보였다. 이는 심음신호의 제1음과 제2음은 20~200 Hz 사이에 많은 에너지가 분포하고 약 25 ms의 길이를 가지므로 음성신호 처리에서 자주 사용하는 윈도우 크기 25 ms와 이동 크기 10 ms보다 길어야 한다는 것을 의미한다.

표 3은 MFCC 차수에 따른 9가지 심장질환 분류 정확도를 나타내었다. 다양한 MFCC 특징차원에 따른 심장질환 분류성능을 비교한 결과, 표 3과 같이, 39차 MFCC를 사용하였을 경우에 가장 높은 정확도를 보였다.

표 4는 HMM의 상태 개수에 따른 9가지 심장질환 분류 정확도이다. 39차 MFCC, 75 ms 윈도우 크기, 25 ms 이동 크기를 가지고 HMM의 상태 개수에 따른 심장질환 분류

표 2. 다양한 윈도우/이동 크기에 따른 분류 정확도

Table 2. Classification accuracy with different window/shift sizes.

Window size (N) (ms)	Shift size (M) (ms)	Accuracy (%)
25	10	78.2
75	25	81.9
150	50	80.1

표 3. 다양한 MFCC 차수에 따른 분류 정확도

Table 3. Classification accuracy with varying MFCC orders.

MFCC 차수	Accuracy (%)
24	80.2
39	81.9
54	78.8

표 4. 상태 개수에 따른 분류 정확도

Table 4. Classification accuracy with varying number of states.

HMM 상태 개수	Accuracy (%)
3	80.4
4	81.1
6	81.9
8	81.5

표 5. GMM 개수에 따른 분류 정확도

Table 5. Classification accuracy with varying number of Gaussian distributions for each state.

가우시안 분포 개수	Accuracy (%)
2	81.4
3	81.9
5	81.2
8	80.7

성능을 비교한 결과, 표 4와 같이 HMM의 상태 개수가 6개일 경우에 가장 높은 정확도를 보였다. 이는 제1음과 제2음은 한 개의 상태로 표현되고 심장수축기와 심장확장기에 존재하는 심잡음은 초기잡음, 후기잡음으로 나누어 각 한 개의 상태로 표현되므로 음성인식에서 사용하는 3 상태 보다는 많아야 한다는 것을 의미한다.

표 5는 각 상태의 가우시안 분포의 개수에 따른 9가지 심장질환 분류 정확도를 보여준다. 연속 HMM의 가우시안 분포의 개수 변화에 따른 성능을 조사한 결과, 표 5와 같이 3개를 사용하는 것이 가장 우수한 성능을 나타냈으며 81.9 %의 분류 정확도를 보였다.

표 6은 심음신호의 주기 개수에 따른 9가지 심장질환 종류에 대한 분류 정확도이다. 단일 주기 심음신호를 가지고 HMM 로그우도의 최대값을 가지는 모델을 심장질환

표 6. 심음신호의 주기 개수에 따른 분류 정확도
Table 6. Classification accuracy with varying number of periods of heart sound signals.

심음신호	Accuracy (%)
한 주기 심음신호	81.9
연속 심음신호	82.5

표 7. 다양한 알고리즘을 이용한 분류 정확도
Table 7. Classification accuracy with various algorithms.

심음	정확도 (%)		
	알고리즘 A	알고리즘 B	알고리즘 C
N	96.3	97.5	98.8
AR	50.0	66.6	66.6
AS	55.6	55.6	66.7
AR+AS	66.8	58.3	66.8
MR	66.7	55.6	66.7
MS	75.0	83.4	83.4
MR+MS	80.0	80.0	80.0
MVP	71.5	78.6	71.5
VSD	69.2	76.9	76.9
평균	81.9	83.8	85.6

환으로 분류한 결과, 표 6과 같이 81.9 %의 분류 정확도를 보였다. 연속 심음신호의 시작/끝 부분의 한 주기를 가지는 심음신호를 제외하고 단일 주기 심음신호로 분할한 후, HMM 평균 로그우도를 계산하여 최대값을 가지는 모델을 심장질환으로 분류한 결과 82.5 %의 분류 정확도를 보였다. 한 주기 심음신호는 연속 심음신호와 비교하여 0.6 %의 오분류를 보임으로써, 주기별 심장질환 종류의 변동이 적다는 것을 의미한다.

표 7은 다양한 알고리즘을 이용하여 9가지 심장질환 분류 정확도를 나타내었다. 다양한 알고리즘을 이용한 심장질환 분류 정확도를 비교평가하기 위하여 본 논문에서는 3가지 심장질환 분류 알고리즘을 사용하였다. 알고리즘 A는 MFCC와 HMM을 이용하여 심장질환을 분류하는 방법인 기본 알고리즘이고 알고리즘 B는 HMM으로부터 상태단위의 HMM 점수를 계산한 후 SVM을 이용하여 심장질환을 분류하는 방법이다. 알고리즘 C는 제안한 알고리즘인 상태단위의 HMM 점수와 심잡음 점수를 결합한 방법이다.

알고리즘 A는 심잡음의 위치정보를 반영할 수 없으므로 심잡음의 위치가 다른 AR과 AS의 분류정확도를 떨어뜨린다. 기본 알고리즘은 심장질환을 분류한 결과, 표 7과 같이 81.9 %의 분류정확도를 보였다.

알고리즘 B는 상태단위의 HMM 점수를 이용하여 심장질환을 분류한 결과, 83.8 %의 분류정확도를 나타내었다.

표 8. 제안한 알고리즘 이용한 심장질환 분류 혼합행렬
Table 8. Confusion matrix of cardiac disorder classification with proposed algorithm.

심음	분류 정확도 (%)								
	a	b	c	d	e	f	g	h	i
a) N	98.8	0.0	0.0	0.0	0.0	0.0	0.0	1.2	0.0
b) AR	0.0	66.6	16.7	16.7	0.0	0.0	0.0	0.0	0.0
c) AS	11.1	0.0	66.7	0.0	11.1	0.0	0.0	0.0	11.1
d) AR+AS	0.0	0.0	8.3	66.8	0.0	8.3	8.3	0.0	8.3
e) MR	0.0	0.0	11.1	0.0	66.7	0.0	11.1	0.0	11.1
f) MS	0.0	8.3	0.0	0.0	8.3	83.4	0.0	0.0	0.0
g) MR+MS	0.0	0.0	0.0	0.0	0.0	20.0	80.0	0.0	0.0
h) MVP	7.1	0.0	7.1	0.0	14.3	0.0	0.0	71.5	0.0
i) VSD	0.0	0.0	0.0	0.0	15.4	0.0	7.7	0.0	76.9

표 9. 제안한 알고리즘을 이용한 심장질환 검출 정확도
Table 9. Detection accuracy of cardiac disorder with proposed algorithm.

입력	인식결과	정상(%)	비정상(%)
	정상		98.8
비정상		2.5	97.5

상태단위의 HMM 점수는 심잡음의 위치정보를 포함하므로 심잡음의 위치가 다른 심장질환에 대한 오분류를 감소시킬 수 있다. 그 결과 알고리즘 A와 비교하여 AR, MS를 각각 34.0 %, 32.0 %의 상대적 개선율을 나타내었다.

알고리즘 C는 상태단위의 심잡음 점수를 추가하여 심장질환을 분류한 결과, 85.6 %의 분류 정확도를 보였다. 제안한 알고리즘은 알고리즘 A와 비교하여 AR, AS, MS를 각각 34.0 %, 25.0 %, 32.0 %의 상대적 개선율을 나타내었다. 상태단위의 HMM 점수와 심잡음 점수의 결합은 심잡음의 위치와 지속시간 (duration)이 다른 AR, AS, MS의 분류정확도를 향상시키므로 기본 알고리즘보다 정확한 심잡음의 위치와 특성을 반영한다는 것을 알 수 있다.

4.3. 심장질환 검출

표 8은 제안한 알고리즘을 이용하여 9가지 심장질환 분류 실험 결과를 혼합행렬 (confusion matrix)로 나타낸 것이다. 앞 절의 9개 심장질환 분류 실험에서 나온 결과를 정상/비정상으로 변환하여 심장질환 유무를 판단하는 심장질환 검출 성능을 측정하였다. 이전 연구 [11]에서 시간영역 특징을 추가한 심장질환 검출 알고리즘은 ELM 심장질환 분류기의 결과를 존재유무로 변환하여 심장질환을 검출한 결과 4.4 %의 오경보율과 0.6 %의 오거부율을 나타내었다.

표 9는 제안한 알고리즘을 이용한 심장질환 검출 성능

을 보여준다. 제안한 알고리즘을 이용하여 상태단위의 HMM 점수 및 심잡음 점수를 이용한 제안한 알고리즘은 표 9와 같이 2.5%의 오경보율과 1.2%의 오거부율을 나타내었다. 이러한 결과는 제안한 알고리즘이 전자 청진기 또는 건강시스템에 효과적으로 활용될 수 있음을 나타낸다.

V. 결론

본 논문에서는 심잡음이 심장질환 종류를 결정하는데 중요함을 고려하여 상태단위의 HMM 점수와 심잡음 점수를 이용한 심장질환 분류 알고리즘을 제안하였다. MFCC와 HMM을 이용하는 기본 알고리즘의 MFCC 차수, 윈도우 크기, 이동 크기, 상태 개수, 가우시안 분포 개수를 실험을 통하여 최적화함으로써, 81.9%의 분류 정확도를 얻었다. 기본 알고리즘과 함께 상태단위의 HMM 점수와 심잡음 점수를 결합하는 SVM을 적용한 제안한 알고리즘은 20.4%의 상대적 개선율을 보임으로써 85.6%의 분류 정확도를 나타내었다. SVM을 이용하여 상태단위의 HMM 점수와 심잡음 점수를 결합함으로써 심장질환 분류 정확도를 개선하였다. 상태단위의 HMM 점수와 심잡음 점수의 결합은 보다 정확한 심잡음의 위치와 특성을 포함하므로 MFCC와 비교하여 대동맥관 역류, 대동맥관 협착, 승모판 협착의 오류를 각각 34.0%, 25.0%, 32.0%를 감소하였다.

제안한 알고리즘은 상태단위의 HMM 점수와 심잡음 점수를 계산함으로써 보다 많은 단계의 처리과정을 수행하게 되면서 계산량과 계산시간이 증가하였으나, 제안한 알고리즘은 심장질환별 심잡음 점수를 추가하여 보다 효과적인 심장질환 분류 정확도를 나타내었다.

심장질환 분류 결과를 유무 판정 결과로 변환하여 계산한 결과 심음 포락선, 심잡음 확률벡터, 심잡음 진폭값 변동의 시간적 특징을 추가한 기존 알고리즘은 2.5%의 평균 오류율을 나타내었고, 상태단위의 심잡음 점수의 시간적 특징을 추가한 제안한 알고리즘은 1.9%의 평균 오류율을 나타내었다. 제안한 알고리즘은 기존 알고리즘과 비교하여 24.0%의 상대적 개선율을 보임으로써, 제안 알고리즘은 전자청진기를 이용한 심장질환 초기진단 시스템에 사용될 수 있는 가능성을 보여 주었다.

감사의 글

이 논문은 2010년도 정부 (교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (No. 2010-0009205).

참고 문헌

1. S.M. Arcasoy, J.D. Christie, V.A. Ferrari, M.S. Sutton, D.A. Zisman, N.P. Blumenthal, A. Pochettino and R.M. Kotloff, "Echocardiographic assessment of pulmonary hypertension in patients with advanced lung disease," *American journal of respiratory and critical care medicine*, vol. 167, pp. 735-740, 2003.
2. C.N. Gupta, R. Palaniappan, S. Swaminathan and S.M. Krishnan, "Neural network classification of homomorphic segmented heart sounds," *Applied Soft Computing*, vol. 7, pp. 286-297, 2007.
3. R.K. Sinha, Y. Aggarwal and B.N. Das, "Backpropagation artificial neural network classifier to detect changes in heart sound due to mitral valve regurgitation," *Journal of Medical Systems*, vol. 31, pp. 205-209, 2007.
4. R.A. Azra' ai, M.N. bin Taib and N.M. Tahir, "Artificial neural network for identification of heart problem," in *Proc. Signal Processing and Communication Systems 2008*, Gold Coast, Australia, pp. 1-6, Dec. 2008.
5. A. Ricke, R. Provinelli and M. Johnson, "Automatic segmentation of heart sound signals using hidden Markov models," *Proc. Computers in Cardiology 2005*, Lyon, France, pp. 953-956, Sep. 2005.
6. M. Obayya and F. Abou-Chadi, "Classifying some cardiac abnormalities using heart rate variability signals," in *Proc. 25th National Radio Science Conference 2008*, Tanta Univ., Egypt, pp. 1-8, Mar. 2008.
7. S.E. Schmidt, E. Toft, C. Holst-Hansen, C. Graff and J.J. Struijk, "Segmentation of heart sound recordings from an electronic stethoscope by a duration dependent hidden-Markov model," in *Proc. Computers in Cardiology 2008*, Bologna, Italy, pp. 345-348, Sep. 2008.
8. 김희근, 정용주, "Ergodic hidden Markov model을 이용한 연속심음분류에 관한 연구," *대한의료정보학회지*, 13권, 1호, 35-41쪽, 2007.
9. C. Kwak and O.-W. Kwon, "Cardiac disorder classification based on extreme learning machine," in *Proc. World Academy of Science, Engineering and Technology 2008*, Bangkok, Thailand, vol. 36, pp. 1260-1263, Dec. 2008.
10. 곽철, 권오욱, "자동 분할과 ELM을 이용한 심장질환 분류 성능 개선," *한국음향학회지*, 28권, 1호, 32-43쪽, 2009.
11. 곽철, 권오욱, "심음 기반의 심장질환 분류를 위한 새로운 시간영역 특징," *한국음향학회지*, 29권, 2호, 133-140쪽, 2010.
12. C. Donghui and L. Zhijing, "A new text categorization method based on HMM and SVM," in *Proc. 2010 2nd International Conference on Computer Engineering and Technology*, Chengdu, China, pp. 383-386, Apr. 2010.
13. J.D. Cai and R.W. Yan, "Application of FCM-HMM-SVM based mixed method for fault diagnosis of power electronic circuit," in *Proc. International Conference on Mechanic Automation and Control Engineering*, Wuhan, China, pp. 3982-3985, Jun. 2010.
14. S. Haykin, *Neural Networks: A comprehensive foundation*, 2nd ed., Prentice Hall, 1999.
15. S. Young, G. Evermann, M. Gales, T. Hain, D. Kershaw, X. Liu, G. Moore, J. Odell, D. Ollason, D. Povey, V. Valtchev and P. Woodland, *Hidden Markov Model Toolkit v3.4*, Cambridge University, 2006.
16. D. Mason, *Listening to the Heart: A Comprehensive Collection of Heart Sounds and Murmurs*, F.A. Davis Company, Philadelphia, 2000.

17. University of Washington department of medicine, *Technique: Heart Sounds & Murmurs*, <http://depts.washington.edu/physdx/heart/tech.html>
18. Texas heart institute as St. Luke's episcopal hospital, *Heart Sound and Murmur Recordings*, http://www.texasheart.org/Education/CME/explore/events/eventdetail_5469.cfm

저자 약력

•곽 철 (Chul Kwak)



2007년 2월: 배재대학교 전자공학과 (공학사)
 2009년 2월: 충북대학교 제어계측공학과 (공학석사)
 2009년 3월 ~ 현재: 충북대학교 제어로봇공학과 (박사과정)
 ※ 주관심 분야: 음성 인식, 심음 인식, 음원 분리, 음성 및 오디오 처리

•권 오 욱 (Oh-Wook Kwon)



1986년 2월: 서울대학교 전자공학과 졸업
 1988년 2월: 한국과학기술원 전기및전자공학과 (공학석사)
 1997년 2월: 한국과학기술원 전기및전자공학과 (공학박사)
 1986년 3월 ~ 2000년 4월: 한국전자통신연구원 책임연구원
 1999년 4월 ~ 1999년 12월: Karlsruhe University 방문연구원
 2000년 5월 ~ 2001년 3월: 한국과학기술원 연구교수
 2001년 3월 ~ 2003년 8월: Research Associate, University of California, San Diego
 2003년 9월 ~ 현재: 충북대학교 전자공학부 부교수
 ※ 주관심 분야: 음성 인식, 음성 및 오디오 처리, 심음 인식