

자동 분할과 ELM을 이용한 심장질환 분류 성능 개선

Performance Improvement of Cardiac Disorder Classification Based on Automatic Segmentation and Extreme Learning Machine

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

*충북대학교 제어계측공학과

(접수일자: 2008년 8월 18일; 수정일자: 2008년 10월 27일; 채택일자: 2008년 12월 30일)

본 논문은 자동 분할과 extreme learning machine (ELM)을 이용하여 연속 심음신호에 의한 심장질환 분류의 성능을 개선한다. 자동 분할을 위한 전처리 단계에서 비정상적인 심음신호는 심잡음 (murmur)과 클릭음 (click)을 포함하고 있기 때문에 제1음 (S1)과 제2음 (S2) 시작점 검출 결과가 부정확하거나 누락되어 기존의 심장질환 분류 시스템의 정확도를 저하시키게 된다. 이러한 분할 오류에 의한 성능 저하를 감소하기 위해 S1 및 S2의 위치를 찾고, S1 및 S2의 시간 차이를 이용하여 부정확한 시작점을 교정한 다음 한 주기 심음 신호를 추출한다. 특징벡터로는 단일 주기의 심음 신호로부터 추출된 멜 척도 필터뱅크 로그 에너지 계수와 포락선을 사용한다. 심장질환을 분류하기 위하여 한 개의 은닉층을 가진 ELM 알고리즘을 사용한다. 9가지 심장질환 분류 실험을 수행한 결과, 제안 방법은 81.6%의 분류 정확도를 나타내며, multi-layer perceptron (MLP), support vector machine (SVM), hidden Markov model (HMM) 중에서 가장 높은 분류 정확도를 보여준다.

핵심용어: 심음인식, ELM, HMM

투고분야: 생체 및 의학 음향 분야 (15.4)

In this paper, we improve the performance of cardiac disorder classification by continuous heart sound signals using automatic segmentation and extreme learning machine (ELM). The accuracy of the conventional cardiac disorder classification systems degrades because murmurs and click sounds contained in the abnormal heart sound signals cause incorrect or missing starting points of the first (S1) and the second heart pulses (S2) in the automatic segmentation stage. In order to reduce the performance degradation due to segmentation errors, we find the positions of the S1 and S2 pulses, modify them using the time difference of S1 or S2, and extract a single period of heart sound signals. We then obtain a feature vector consisting of the mel-scaled filter bank energy coefficients and the envelope of uniform-sized sub-segments from the single-period heart sound signals. To classify the heart disorders, we use ELM with a single hidden layer. In cardiac disorder classification experiments with 9 cardiac disorder categories, the proposed method shows the classification accuracy of 81.6% and achieves the highest classification accuracy among ELM, multi-layer perceptron (MLP), support vector machine (SVM), and hidden Markov model (HMM).

Keywords: Heart sound classification, Extreme learning machine, Hidden Markov model

ASK subject classification: Biological and Medical Acoustics (15.4)

I. 서론

심장질환들은 대부분 치명적이거나 심한 후유증을 남기기 때문에, 심장질환의 조기 발견은 매우 중요하다. 심장질환 여부는 심초음파 또는 electro-cardiogram (ECG) 검사를 통하여 정확하게 진단되지만, 이는 진단시

간과 비용이 소요된다. 의사들은 전통적으로 청진기를 사용하여 심장박동 소리 (심음)를 듣고 환자의 심장질환 유무와 종류를 판단하는데 청진음으로부터 심장질환을 찾아내는 것은 많은 경험과 지식을 필요로 한다. 따라서 청진음으로부터 심장 질환의 유무와 종류를 자동적으로 판단할 수 있으면 진단시간 단축과 정밀진단 필요 여부를 판정하는데 도움이 된다. 본 논문은 이를 위하여 청진음으로부터 심장질환을 분류하고 질환 여부를 검출하는 방법을 제안한다.

책임저자: 권 오 욱 (owkwon@cbnu.ac.kr)
361-763 충북 청주시 흥덕구 성봉로 410
충북대학교 전기전자컴퓨터공학부
(전화: 043-261-3374; 팩스: 043-268-2386)

심장질환 분류를 위한 기존 연구는 크게 artificial neural network (ANN)을 이용한 방식과 hidden Markov model (HMM)을 이용한 방식으로 나누어진다. ANN 방식 [1-3]은 심음신호의 단일 주기를 획득하기 위해 전처리 단계에서 자동 분할 알고리즘을 가지고 있어야 한다. 자동 분할 알고리즘으로 인한 분할 오류들은 인식 정확도를 떨어뜨린다. HMM 방식 [4-7]은 연속 심음 신호로부터 심음의 동적 특성과 비정상적인 특성을 고려하여 심장질환 종류를 판단할 수 있으나, 심장질환 분류 정확도가 만족스럽지 않다는 단점이 있다.

본 논문에서는 자동분할 알고리즘으로 인한 분류 오류율을 최소화하기 위해 대역통과필터와 쉐논 에너지 (Shannon energy)를 이용하여 제1음 (S1)과 제2음 (S2)를 강조한 다음 영상 이진화 방법 [8]을 응용하여 S1과 S2구간의 시작점들을 검출하고, 시작점들 간의 거리를 이용하여 비검출 시작점을 추가하고 부정확한 시작점을 교정하는 개선된 자동 분할 알고리즘을 구축한다. 단일 주기의 심음신호를 추축하여 필터뱅크 로그 에너지 값과 심음신호의 포락선 값을 구하여 특징벡터로 사용한다. 심장질환을 분류하기 위하여 다른 학습 알고리즘과 비교하여 계산 시간이 작고 복잡한 문제에서도 우수한 성능을 얻는 extreme learning machine (ELM) [9][10]을 이용한다. 연속 심음 신호를 이용하여 심장질환의 유무를 판단하는 초기진단 시스템에 적용할 수 있는 방법을 제안한다.

제2장에서는 심음신호의 특성을 살펴보고 실험에 사용된 심음 데이터의 세부사항을 기술한다. 제3장에서는 HMM을 이용한 기존의 심장질환 분류 기법을 설명하고, 제4장에서는 본 논문에서 새로이 제안한 ELM을 이용한 심장질환 분류 방법을 설명한다. 제5장에서는 HMM, ELM, multi-layer perceptron (MLP), support vector machine (SVM)을 이용한 심장 질환 분류 성능을 비교하고 그 결과를 토의하며, 제6장에서 결론을 맺는다.

II. 심음 신호 및 데이터베이스

2.1. 심음 신호 [11]

심음 신호의 한 주기는 그림 1에서 보는 바와 같이 S1-systole-S2-diastrale의 순서로 이루어진다. S1은 심실 수축기에 해당하며 저음 (57~70 Hz)이고 둔하며, 소리의 지속이 길다. S2는 심실 확장기에 해당하며 고음 (90~100 Hz)이고 예리하며, 소리의 지속이 짧다. S1은 승모판막, 삼첨판막의 폐쇄음과 대동맥판막, 폐동맥판막의 개방음이 주성분이고, S2는 승모판막, 삼첨판막의 개방음과 대동맥판막, 폐동맥판막의 폐쇄음이 주성분이다.

정상적인 심음에서는 심실 수축기 (systole)와 심실 확장기 (diastole)에서 거의 소리가 들리지 않지만, 심장질환자의 심음에서는 심잡음 (murmur)과 클릭음 (click)이 들린다. 비정상적인 심음신호는 그림 2에서 보는 바와 같이 심




그림 1. 한 주기 심음신호
Fig. 1. One period of heart sound signals.

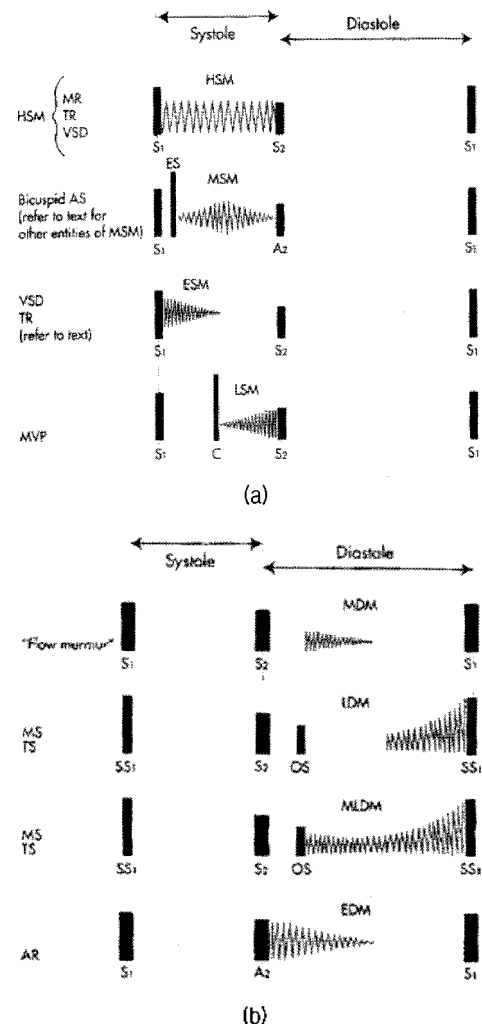


그림 2. 심잡음의 위치에 따른 심장질환
(a) 심실 수축기 심잡음, (b) 심실 확장기 심잡음
Fig. 2. Classification of cardiac disorders according to the position of murmurs.
(a) Systolic murmurs, (b) Diastolic murmurs

잡음의 위치에 따라서 여러 질환으로 구분할 수 있다. 심실 수축기에서 심잡음을 가진 심장질환에는 대동맥판 협착 (aortic stenosis; AS), 승모판 역류 (mitral regurgitation; MR), 심실강모결손 (ventricular septal defect; VSD)의 질환들이 있고 심실 확장기에서 심잡음을 가진 심장질환에는 대동맥판 역류 (aortic regurgitation; AR), 승모판 협착 (mitral stenosis; MS)의 질환들이 있다. 승모판 탈출 (mitral valve prolapse; MVP)은 심실 수축기에서 큰 리듬이 존재하는 질환이다.

대동맥판막의 비정상적인 질환인 AR은 고음이며 희미하게 혹은 부는 듯한 소리 또는 분출하는 듯한 소리가 들리고 AS는 저음이며 거친 소리가 들린다. 승모판막의 비정상적인 질환인 MR은 S1이 심실 수축기 심잡음에 묻히는 경향을 보이고 MS는 저음이며 심실 확장기에서 덜거덕 소리가 들리며 MVP는 심실 수축기에서 클릭음이 들린다. 심실강모결손인 VSD는 MR과 거의 유사하여 분간하기가 힘들다. 좌측 부흉골 3~4번째 사이의 공간에서 잘 들리고 떨리는 소리를 동반한다.

2.2. 심음 데이터베이스

심음신호를 분류하기 위하여 심음분류 능력을 기르기 위해서 발행된 교육용 오디오 시디 (CD) [11]와 여러 기관에서 공개한 심음 데이터베이스로부터 추출한 심음 데이터를 수집하였다. 여기에 본 연구실에서 수집한 실제 정상인의 심음신호를 추가하였다. 심음신호는 8 kHz로 샘플링 되어 16비트 pulse code modulation (PCM)으로 저장되었다.

심음 데이터베이스는 다수의 주기를 포함하는 연속 심음 데이터로 구성된다. 본 논문에서 HMM 기반 심장 질환

분류에서는 연속 심음을 그대로 사용하고, 신경 회로망 기반의 심장 질환 분류에서는 각 연속 심음 데이터로부터 본 논문에서 제안한 방법으로 추출한 각각 두 개의 단일 주기 심음을 사용한다. 실험에 사용된 정상 및 심장질환 별로 나누어진 연속 심음 데이터 및 단일 주기 심음 데이터의 개수는 표 1과 같다.

III. HMM 기반 심장질환 분류

3.1. 특징 추출

심음신호의 주파수 특성은 0~200 Hz 사이에 주로 존재하는 S1, S2의 특성과 1 kHz 이하에 존재하는 심실 수축기와 심실 확장기의 심잡음 특성으로 이루어져 있다. 심음신호의 주파수 주성분은 1 kHz 이하에 분포하므로 8 kHz 샘플링율의 심음신호를 2 kHz 샘플링율의 심음신호로 다운샘플링하여 심음신호의 샘플링율을 낮추어 변환하였다. S1과 S2의 시간적 특성은 100 ms 범위내외에서 변화하나 심잡음과 클릭음의 시간적 특성은 30 ms 범위내외에서 변하므로 S1과 S2의 첫 번째 하모닉 (harmonic) 요소의 3 사이클 (cycle)을 포함하도록 윈도우 크기를 30 ms로 선택하였으며, 심잡음은 짧은 시간 내에 특성이 변하므로 윈도우는 매 10 ms 마다 이동한다. 심음신호의 특징벡터를 추출하기 위해 그림 3에서 보는 바와 같은 과정을 거친다 [12].

필터뱅크 출력을 얻기 위해서 전체 주파수 범위를 mel-scale에 맞추어 30개의 밴드로 분할하여 필터뱅크 계수를 계산하였다. 필터뱅크 출력 값에 log값을 취한 후 discrete cosine transform (DCT)을 하여 mel frequency cepstral coefficients (MFCC) 값을 얻게 된다. MFCC 계수는 12개를 사용하며 프레임 로그 에너지를 추가적으로 사용하여 특징벡터는 13차 벡터가 된다. 심음신호의 동적 특성을 반영하기 위하여 1차 미분 값을 추가하여 특징벡터는 총 26차이다.

표 1. 심장질환 종류와 데이터 수
Table 1. Heart disorder categories and the number of heart sound data.

심장질환 종류		데이터 개수	
		연속	단일 주기
정상		80	160
비정상	대동맥판 역류 (AR)	6	12
	대동맥판 협착 (AS)	9	18
	대동맥판 합성 (AR+AS)	12	24
	승모판 역류 (MR)	9	18
	승모판 협착 (MS)	12	24
	승모판 합성 (MR+MS)	5	10
	승모판 탈출 (MVP)	14	28
	심실강모 결손 (VSD)	13	26
	소계	80	160




그림 3. HMM 기반 심장질환 분류기의 특징추출
Fig. 3. Feature extraction for HMM-based classifiers.

3.2. HMM을 이용한 심장질환 분류

HMM기반 심장질환 분류기의 학습을 위하여 무선 전자청진기를 이용하여 수집한 실제 정상 고립심음 데이터와 추출한 고립심음 데이터를 사용하였다. HMM은 그 구조에 따라서 여러 가지 형태가 존재하는데 신호의 특성이 시간에 따라서 변하는 경우에는 자기 천이와 상태간의 천이가 왼쪽에서 오른쪽으로만 가능한 좌우(left-to-right) HMM이 가장 많이 사용된다 [12]. 고립심음 데이터를 학습하기 위해서 그림 4에서 보는 바와 같이 좌에서 우로 천이하는 형태를 사용하였고 상태 개수는 동일한 질병이라도 심잡음의 위치와 특성이 다르므로 단일 주기의 고립심음을 시작 상태와 끝 상태를 포함한 8개로 설정하였다.

좌우 HMM은 고립심음 신호를 모델링하기에는 적합하지만 수집한 실제 연속심음 신호를 분류하는 경우에는 문제가 발생한다. 실제 연속심음 데이터는 전자청진기를 이용하여 심음신호를 수집하므로 처음으로 들어오는 심음신호의 구간을 알 수 없으므로 첫 번째 상태에서 한 주기 심음신호의 모든 상태간의 천이가 가능하도록 그림 5에서 보는 바와 같이 순환(circular) HMM을 이용하여 연속심음 신호를 모델링한다. 점선 화살표는 첫 번째 상태에서 모든 상태간의 천이 가능을 나타내고 실선 화살표는 좌우 HMM의 상태간의 천이 가능을 나타낸다.





그림 4. 8 상태 left-to-right HMM의 구조
Fig. 4. Structure of 8-state left-to-right HMM.



----- 첫 번째 상태(0)에서 모든 상태(1-6)로의 천이 가능
모든 상태(1-6)에서 마지막 상태(7)로의 천이 가능
————— Left-to-right HMM의 상태(1-6)간의 천이 가능

그림 5. 8 상태 순환 HMM의 구조
Fig. 5. Structure of 8-state circular HMM.

IV. ELM을 이용한 심장질환 분류

신경회로망 기반 심장질환 분류 시스템은 전처리, 특징추출, 패턴분류기로 구성된다. 전처리에서는 연속 심음신호로부터 S1, S2 시작점을 구하여 단일 주기의 심음신호를 뽑아낸다. 특징추출 모듈은 단일 주기 심음신호로부터 필터뱅크 계수 및 포락선 신호를 추출하여 특징벡터로 출력한다. 패턴분류기는 ELM으로 구성된다.

4.1. 전처리

심장질환을 분류하기 위해서 심잡음 또는 클릭음의 위치 정보가 중요하므로 연속 심음신호에서의 S1과 S2의 위치를 검출하여야 한다. 본 논문에서는 단일 주기의 심음신호를 검출하기 위해 그림 6과 같이 S1, S2 시작점을 검출하고 교정한다. S1, S2 시작점을 검출하고 교정하는 방법은 아래에서 자세하게 서술한다.

4.1.1. 시작점 검출

연속 심음신호의 S1과 S2의 주파수 주성분이 50~100




그림 6. ANN 기반 심장질환 분류기의 전처리 단계
Fig. 6. Preprocessing stage of ANN-based cardiac disorder classifiers.

Hz 사이에 존재하므로 정규화 된 심음신호를 대역통과 필터를 통과시켜 심잡음 신호를 감소시킨다.

연속 심음신호의 쉐논 에너지(Shannon energy) [13]는 심음신호의 특성을 고려하여 매 10 ms씩 이동하면서 30 ms 윈도우에 대하여 식 (1)과 같이 계산된다. k 는 30 ms 윈도우의 샘플의 개수를 나타내고, x_{norm} 는 정규화(normalization)된 신호이다. 전자청진기로부터 들어오는 연속 심음신호는 환자과 환경에 따라 진폭값(amplitude)이 다르므로 쉐논 에너지의 입력신호를 정규화해야 한다.

$$E_s = -\frac{1}{K} \sum_{i=1}^K x_{norm}^2(i) \log x_{norm}^2(i) \quad (1)$$

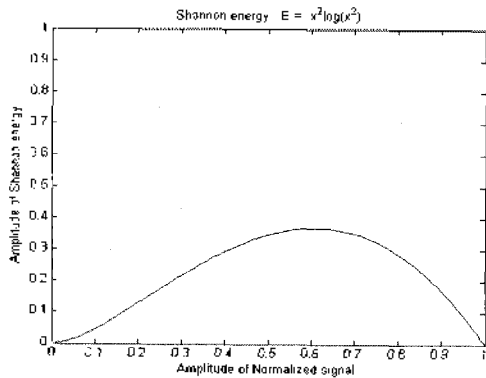


그림 7. 쉐논 에너지
Fig. 7. Shannon energy.

쉐논 에너지는 그림 7에서와 보는 바와 같이 매우 작은 범위와 큰 범위의 진폭값을 감소시켜, 포락선의 피크를 강조한다.

S1, S2 구간과 심잡음 구간을 구별하기 위해 식 (2)~(5)와 같은 처리과정을 거치는 영상 이진화 방법의 자동 문턱값 (automatic threshold) [8]을 응용하였다. 먼저 쉐논 에너지를 0~255사이의 정수값으로 정규화한 이산 랜덤 변수를 X 라고 가정하고, X 의 히스토그램 $N(X=i)$ 를 구한다. 식 (2)로부터 레벨 값이 i 이하인 샘플의 개수 $t(i)$ 를 구하고, 식 (3)을 이용하여 레벨 값이 i 이하인 샘플의 평균값 $m(i)$ 를 구한다. 식 (4)를 이용하여 레벨 i 보다 큰 샘플의 개수 $t(i)$ 와 레벨 i 이하인 샘플의 개수 $t(G) - t(i)$ 의 비율 $A(i)$ 을 구한다. 식 (5)에서와 같이 레벨 i 이하인 샘플의 평균 $m(i)$ 와 전체 평균값 $m(G)$ 의 차이 제곱으로부터 $B(i)$ 를 구한다. 마지막으로 식 (5)와 같이 $A(i)B(i)$ 가 최대가 되는 레벨 값을 구한 다음, 검출된 구간에서의 심잡음 영역의 분포에 따라 문턱값을 적용하기 위해 심음신호의 표준편차 σ_X 의 10배를 곱하여 최종적인 문턱값으로 결정하였다.

$$t(i) = \sum_{k=0}^i N(X=k) \quad (2)$$

$$m(i) = \frac{\sum_{k=0}^i kN(X=k)}{\sum_{k=0}^i N(X=k)} \quad (3)$$

$$A(i) = \frac{t(i)}{t(G) - t(i)}, \quad B(i) = [m(i) - m(G)]^2 \quad (4)$$

$$T = 10 \sigma_X \cdot \arg \max \{A(i)B(i)\} \quad (5)$$

그림 8은 S1, S2 구간과 심잡음 구간을 구별하는 문턱값을 구하는 예를 나타낸다. 그림 8 (a)는 정규화된 이산

쉐논 에너지를 나타내며, 그림 8 (b)는 이산 쉐논 에너지의 히스토그램 $N(X=i)$ 를 나타낸다. 그림 8 (c)와 그림 8 (d)는 각각 $A(i)$ 와 $B(i)$ 를 나타낸다. 그림 8 (e)는 $A(i)B(i)$ 를 나타낸 것이다. 최종적인 문턱값은 $A(i)B(i)$ 가 최대가 되는 레벨값에 심음신호 표준편차 σ_X 의 10배를 곱한 값이다.

그림 9는 연속 심음신호로부터 시작점을 구하는 예를 나타낸다. 그림 9 (a)는 원 심음신호를 정규화 한 심음신호이다. 그림 9 (b)는 대역통과필터 이후의 신호로서 약 38,000~40,000 샘플 사이에 존재하는 심잡음 신호가 감소된 것을 볼 수 있다. 그림 9 (c)는 쉐논 에너지를 나타내며 약 44,000~45,000 샘플 사이에 있는 S1 구간의 진폭값을 증가시키고, 약 46,500~47,500 샘플 사이에 있는 S2 구간의 진폭값을 증가시켜 펄스가 강조된 것을 볼 수 있다. 그림 9 (d)는 문턱값 이상인 구간을 나타낸 것이다. 검출된 S1과 S2 구간의 시작점을 구하기 위해 문턱값 이상인 구간의 시작점을 제외한 검출된 펄스들을 제거하여야 한다. 일반적으로 심음신호의 S1에서 S2까지 시간적 거리가 250 ms 보다 길다는 사전정보를 이용하여 문턱값 이상인 구간의 시작점을 기점으로 시작점을 제외한 쪽 t_d (250 ms) 이하인 펄스를 제거한 후에 최종적으로 각 펄스의 시작점을 검출한 결과가 그림 9 (e)이다.

4.1.2. S1/S2 판별 및 교정

연속 심음신호에서 S1 또는 S2의 진폭값이 심잡음의 진폭값보다 작거나 S1 또는 S2의 구간이 심잡음에 의해 묻히게 되면 t_{S1} 또는 t_{S2} 신호를 검출할 수 없다. 따라서 t_{S1} , t_{S2} 미검출 신호나 부정확한 위치 정보를 가지는 신호를 수정하여야 한다. 그림 10은 t_{S1} 또는 t_{S2} 미검출 신호들과 부정확한 위치 신호들을 수정하기 위한 흐름도이다.

심음신호에서는 $t_{S1} - t_{S2}$ 의 시간적 거리가 $t_{S2} - t_{S1}$ 의 시간적 거리, 미검출 신호로 생기는 거리보다 작다는 사전정보를 이용하여 각 시작점이 S1인지 S2인지를 판별하였다.

검출한 t_{S1} , t_{S2} 의 시간과 t_{S1} , t_{S2} 의 이전시간의 차를 구하고 t_{S1} , t_{S2} 의 시간적 거리를 내림차순으로 정렬한 후, 정렬된 t_{S1} , t_{S2} 의 시간적 거리 값들에서의 작은 값들의 50 백분위수 (percentile)의 평균을 구하였다. 그 평균값을 이용하여 그림 11 (b)에서 보는 바와 같이 t_{S1} 에서 t_{S2} 사이의 거리와 이외의 거리를 구분하고 S1과 S2를 표시하였다. 검출한 t_{S1} 과 t_{S2} 신호를 이용하여 t_{S1} 이전 거리 (D1), t_{S2} 이후 거리 (D2)를 측정하여 D1과 D2의 히스토그

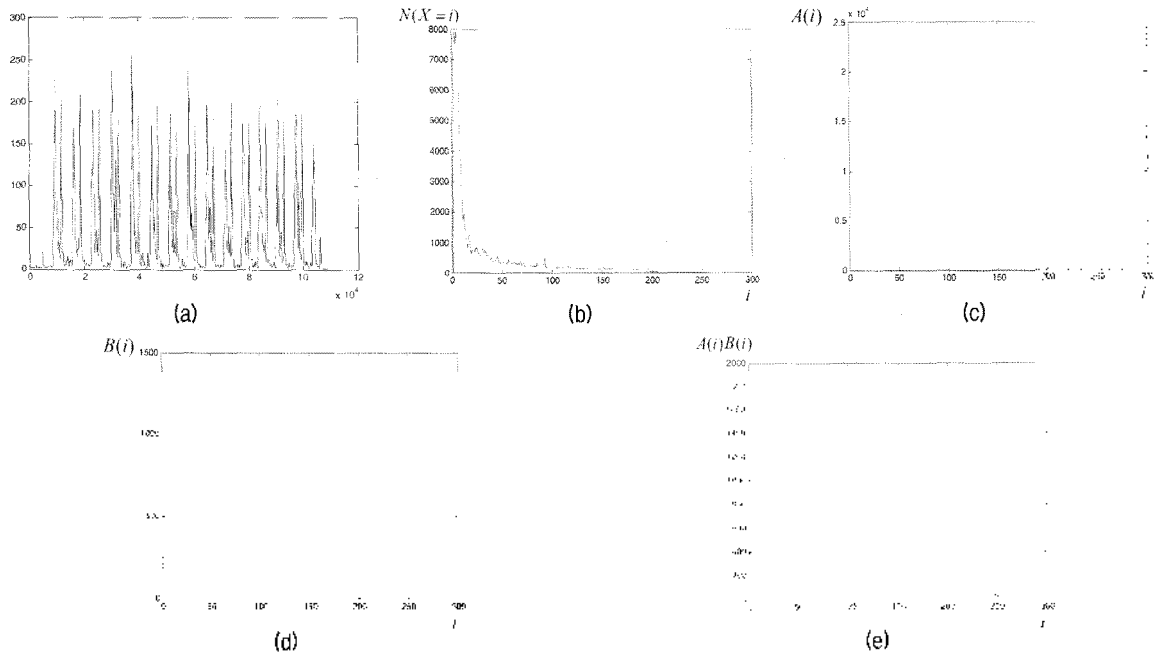


그림 8. 자동 문턱값 결정 예제

(a) 웨논 에너지, (b) 히스토그램 $N(X=i)$, (c) 레벨 i 보다 큰 샘플의 개수와 레벨 i 이하인 샘플의 개수의 비율 $A(i)$, (d) 레벨 i 이하인 샘플의 평균값과 전체 평균값의 차이 제곱 $B(i)$, (e) $A(i)$ 와 $B(i)$ 의 곱

Fig. 8. An example of automatic threshold determination.

(a) Shannon energy, (b) Shannon energy histogram, $N(X=i)$, (c) Ratio of the number of samples larger than level i to the number of samples less than or equal to level i , $A(i)$, (d) Square of difference between average of samples less than or equal to level i and average of all samples, $B(i)$, (e) Multiplication of $A(i)$ and $B(i)$

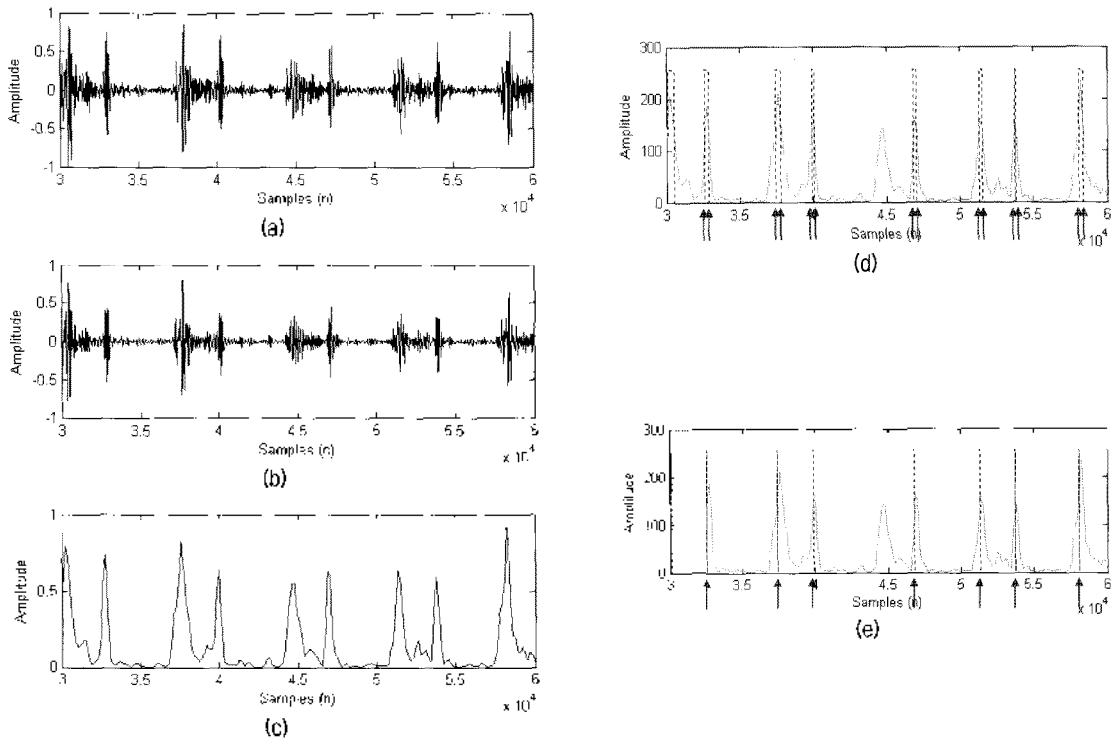


그림 9. S1/S2 시작점 검출 예제

(a) 입력신호, (b) 대역통과필터 신호, (c) 웨논 에너지, (d) S1/S2와 심잡음 구간 결정, (e) 시작점 결정

Fig. 9. An example of S1/S2 starting-point extraction.

(a) The original signal, (b) The band-pass filtered signal, (c) Shannon energy, (d) S1/S2 and murmur segment, (e) The starting-point decision

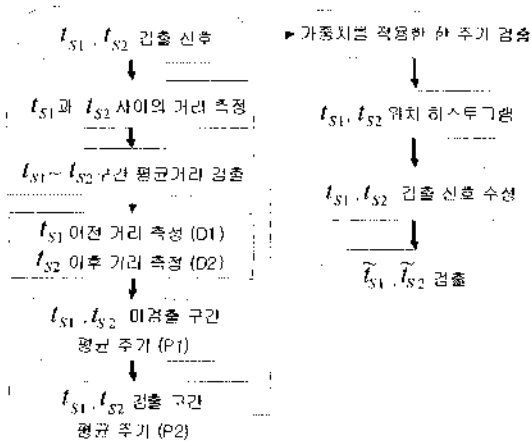


그림 10. S1/S2 시작점 수정 흐름도
Fig. 10. Flowchart of S1/S2 starting-point correction.

램을 이용하여 t_{S1} 또는 t_{S2} 의 미검출 구간 (M)을 표시하였다. 미검출구간의 거리는 대략 한 주기의 값이다. 미검출구간의 평균주기 (P1)와 t_{S1} , t_{S2} 검출구간의 평균주기 (P2)를 구하였다. P1과 P2의 검출된 주기의 수를 계산하여 P1과 P2의 검출된 확률을 구하고 심음신호의 한 주기를 계산하기 위해 P1과 P2의 검출된 확률을 가중치 값으로 적용하여 심음신호의 한 주기 값을 얻었다. $t_{S1} - t_{S2}$ 의 중간지점을 중심으로 한 주기만큼 나누어 t_{S1} , t_{S2} 검출 신호의 위치를 구하였다. t_{S1} , t_{S2} 검출 신호의 위치에 대한 히스토그램을 구한 후, t_{S1} 과 t_{S2} 신호를 구별하는 문턱값을 구하였다. 구별된 t_{S1} 과 t_{S2} 의 평균 위치를 구하여 t_{S1} , t_{S2} 미검출 신호와 부정확한 위치에 존재하는 t_{S1} , t_{S2} 신호에 S1의 시작점 또는 S2의 시작점으로 표시하였다. 그림 11 (c)에서 보는 바와 같이 미검출 구간의 t_{S2} 신호에 S2의 시작점으로 표시하였다. left-to-right scan과 right-to-left scan을 해 가면서 미검출 구간에서의 label된 검출신호에 따라 그림 11 (d)에서 보는 바와 같이 약 44,000~45,000 샘플 사이에 존재하는 미검출 구간에 S1의 시작점 신호를 첨가하고 약 32,000~33,000 샘플 사이에 존재하는 부정확한 시작점을 가지는 신호를 수정하여 개선된 S1, S2 시작점 신호 (\bar{t}_{S1} , \bar{t}_{S2})를 얻었다.

4.2. 특징 추출

S1, S2의 시작점과 한 주기를 알 수 있으므로 연속 심음 신호에서 단일 주기 고립 심음신호를 추출하였다. 특징 벡터를 추출하기 위해 그림 12에서 보는 바와 같이 필터뱅크 로그 에너지 값과 심음신호의 포락선 값을 구하였다. 심음신호의 특징벡터인 필터뱅크 로그 에너지 값과 심음신호의 포락선 값을 구하는 방법은 아래에서 자세히 서술한다.

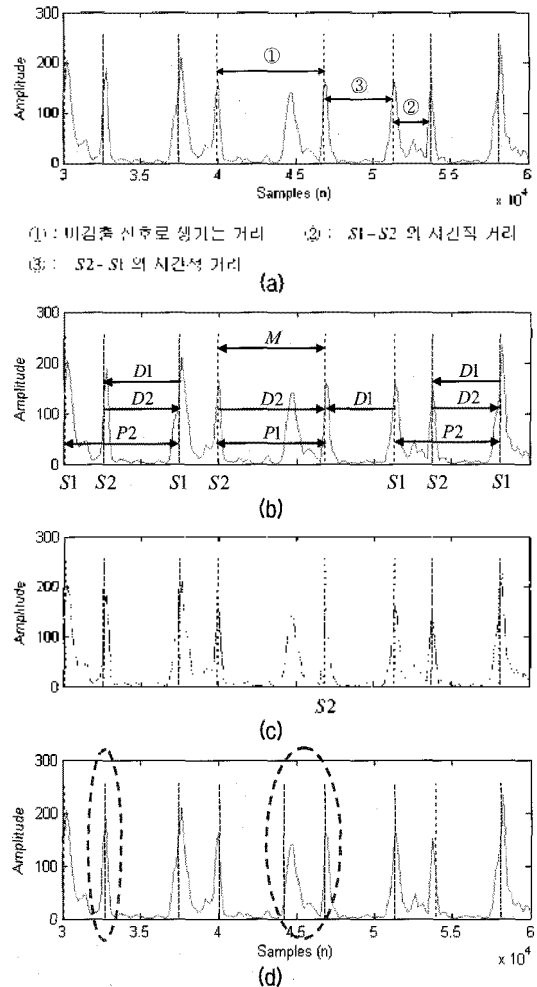


그림 11. 시작점 추가 과정
(a) 심음신호의 시간적 거리의 사전정보, (b) 각종 시간적 거리의 정의, (c) 원래의 S1, S2 시작점, (d) 수정된 S1, S2 시작점
Fig. 11. Procedure of starting-point addition.
(a) The prior information of time distance of heart sound signals, (b) Definitions of various time differences, (c) The original starting points, (d) The corrected S1/S2 starting points




그림 12. ELM 기반 심장질환 분류기의 특징추출
Fig. 12. Feature extraction for ELM-based classifiers.

심음신호는 한 주기보다 짧은 시간에 특성이 많이 변하지 않으므로 프레임 크기는 단일 주기 심음신호를 사용하였다. 심음신호의 주파수 특성들이 1 kHz 이하에 주로 존재하므로 심음신호의 샘플링율을 8 kHz에서 2 kHz로 낮추었다. 전처리에서 추출한 단일 주기 고립 심음신호를 1개의 프레임으로 설정하였다. Hamming 윈도우 함수

가 씌워진 $x(n)$ 에 대해서 2048-points 고속 푸리에 변환 (FFT)을 취하여 X_k 값을 얻는다. 필터뱅크출력을 얻기 위해 전체 주파수 범위를 mel-scale에 맞추어 0~1000 Hz를 100개로 분할하였다. 필터뱅크 출력값의 크기 (magnitude)를 구하고 log 함수를 취하여 100개의 필터뱅크 로그 에너지 값을 얻었다.

단일 주기 심음 신호의 포락선을 알기 위해 병렬적으로 균일한 길이를 가지도록 부세그먼트 (subsegment)로 분할하였다. 균일하게 나누어지지 않는 신호는 심음신호의 마지막 부분에 0으로 채워주고 40개의 균일한 길이를 가지는 부세그먼트로 분할하였다. 각 부세그먼트의 절대값의 평균값을 계산하여 40개의 포락선 값을 구하였다. 앞에서 구한 100개의 필터뱅크 로그 에너지 값과 40개의 포락선 값을 하나의 벡터로 연결하여 최종적으로 140차원의 특징벡터를 얻는다.

4.3. ELM을 이용한 패턴분류

ELM 알고리즘 [9][10]은 고전적 학습 방법들의 단점과 빠른 학습시간을 위하여 입력 가중치와 뉴런들의 바이어스들의 학습을 하지 않고 오직 출력 가중치들을 뉴 최소자승해 (norm least-squares solution)와 모어 페로스의 일반화된 역행렬을 이용하여 구한다. 출력 층에 사용되는 활성화 함수는 선형함수를 사용한다. ELM 알고리즘의 주요 장점은 1) 반복학습을 하지 않기 때문에 다른 학습 방법들에 비해 속도가 매우 빠르다. 2) 정사 기반 학습 방법들은 오직 출력 오차를 최소화 하기 때문에 가중치들의 크기를 고려하지 않지만 ELM 알고리즘은 가장 작은 출력 오차와 뉴 최소자승 방법을 이용하여 가장 작은 가중치들까지 구하기 때문에 일반화 성능이 우수하다. 3) 정사 기반 학습 방법은 오직 미분 가능한 활성화함수를 사용하지만 ELM 알고리즘은 미분가능하지 않은 활성화 함수를 가지는 한 개의 은닉층으로 구성된 신경회로망을 학습할 수 있다. 4) 정사 기반 학습 방법이 국부최소, 부적절한 학습물의 효과, over-fitting과 같은 문제점이 있는 반면 ELM 알고리즘은 한 번의 학습으로 해에 도달하는 경향이 있다 [9][10].

ELM 알고리즘은 입력 가중치와 뉴런들의 바이어스들의 학습을 하지 않고 학습 데이터의 실제 출력 값과 목표 출력 값의 오차가 제로가 되도록 하는 신경망의 은닉층 출력행렬 H 와 목표 출력행렬 T 를 이용하여 극소 뉴 최소자승해 β 를 구하였다. 실제 출력 값과 목표 출력 값의 오차가 제로가 되는 학습 모델링을 얻었다.

N 개의 학습데이터 (x_j, t_j) 에 대하여 N 개의 은닉 뉴

런과 활성화함수 $g(x)$ 를 갖는 신경회로망이 있다고 하자. 여기서 $x_j = [x_{j1}, x_{j2}, \dots, x_{jn}]^T \in R^n$ 이며, n 은 특징벡터의 차원이다. 목표 출력값 $t_j = [t_{j1}, t_{j2}, \dots, t_{jm}]^T \in R^m$ 이고, m 은 출력 뉴런의 개수이다. 이 경우 실제 출력 값 o_j 는 다음과 같다.

$$\sum_{j=1}^N \beta_j g(x_j) = \sum_{j=1}^N \beta_j g(w_i \cdot x_j + b_i) = o_j, \quad (6)$$

$w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ 는 i 번째 은닉 뉴런과 입력 뉴런 사이에 연결된 가중치 벡터이고, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 는 i 번째 은닉 뉴런과 출력 뉴런 사이에 연결된 가중치 벡터이다. b_i 는 i 번째 은닉 뉴런의 바이어스 값을 나타낸다. $w_i \cdot x_j$ 는 w_i 와 x_j 의 벡터 내적을 나타낸다.

N 개의 학습 데이터에 대하여 식 (6)과 같은 실제 출력 값과 식 (7)과 같은 목표 출력 값 t_j 의 오차가 0이 될 경우 $\sum_{j=1}^N \|o_j - t_j\| = 0$ 을 만족하는 β_i, w_i, b_i 가 존재한다.

$$\sum_{j=1}^N \beta_j g(w_i \cdot x_j + b_i) = t_j, \quad j = 1, \dots, N \quad (7)$$

N 개의 방정식을 아래와 같이 간단히 표현하면

$$H\beta = T \quad (8)$$

$$H = (w_1, \dots, w_N, b_1, \dots, b_N, x_1, \dots, x_N) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_N \cdot x_1 + b_N) \\ \vdots & \dots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_N \cdot x_N + b_N) \end{bmatrix}_{N \times N} \quad (9)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{bmatrix}_{N \times m}, \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m} \quad (10)$$

H 는 은닉층 출력 행렬을 나타낸다. H 의 i 번째 열은 입력 x_1, x_2, \dots, x_N 의 각각에 대한 i 번째 은닉 뉴런의 출력이다. 극소 뉴 최소자승해 β 는 아래와 같이 구할 수 있다.

$$\beta = H^+ T \quad (12)$$

H^+ 는 H 에 대한 모어 페로스의 일반화된 역행렬을 의미한다 [9][10].

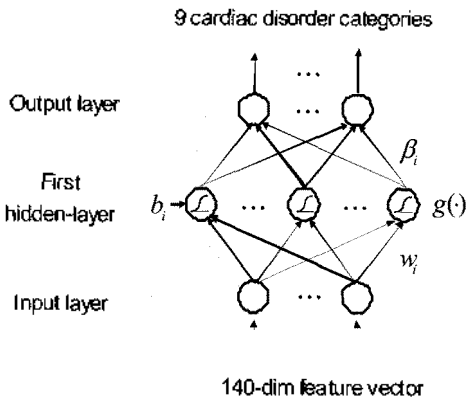


그림 13. ELM 네트워크 구조
Fig. 13. Structure of ELM network.

ELM 신경회로망은 그림 13에서 보는 바와 같이 입력 값은 100차 필터뱅크 로그 에너지 값과 40차 심음신호 포락선으로 구성되어 있고 출력 값은 9가지 심장질환 출력값이다. 미분가능하지 않은 활성화 함수를 가지는 한 개의 은닉층으로 구성된 신경회로망이다.

V. 실험 결과 및 토의

심장질환 분류 실험을 하기 위해 \tilde{f}_{s1} , \tilde{f}_{s2} 신호를 이용하여 한주기 심음신호를 추출하고 1개의 연속심음 신호에서 2개 고립심을 데이터를 구축하였다. 심장질환의 종류에 대한 인식실험은 비정상적인 심장질환에 대한 데이터의 개수가 적어 교차검증 (cross-validation) 방식을 이용하여 독립적인 연속 심음 인식실험을 하였다. 본 논문에서는 전체 심음 데이터 중에서 각 심장질환의 1개의 연속 심음 데이터에서 추출한 2개의 고립 심음 데이터만 인식용 데이터로 사용하고 나머지 데이터는 훈련용 데이터로 사용하였다. 이런 과정을 반복하여 모든 데이터가 반드시 한 번씩 인식용 데이터로 사용하게 되므로 적은 데이터를 이용하여도 신뢰성 있는 인식결과를 얻을 수 있도록 하였다.

5.1. HMM을 이용한 심장질환 분류

HMM 기반의 심음 분류기에서는 학습 데이터를 구축하기 위해 \tilde{f}_{s1} , \tilde{f}_{s2} 신호를 이용하여 한주기 심음신호를 추출하여 학습 데이터를 구축하였다. 단일 주기의 고립 심음신호는 시작 상태와 끝 상태를 포함한 8개로 설정하였다. 4개의 Gaussian mixture model을 이용하여 5번의 반복 학습을 통해 학습 모델링을 얻었다.

표 2. 순환 HMM을 이용한 심장질환 분류 성능
Table 2. Performance of cardiac disorder classification using circular HMM.

심음	맞게 인식한 샘플 수 / 전체 샘플 수	정확도 (%)	
정상	140 / 160	88	
비정상	AR	4 / 12	33
	AS	6 / 18	33
	AR+AS	18 / 24	75
	MR	12 / 18	67
	MS	24 / 24	100
	MR+MS	8 / 10	80
	MVP	18 / 28	64
VSD	12 / 26	46	
평균	242 / 320	75.6	

표 3. 순환 HMM을 이용한 심장질환 검출 성능
Table 3. Performance of cardiac disorder detection using circular HMM.

입력	인식결과	정상 (%)	비정상 (%)
	정상	87.5	12.5
비정상	1.2	98.8	

좌우 HMM을 이용하여 연속심음 인식실험을 한 결과 심장질환 분류 정확도는 72.8%를 보였다.

실제 수집된 연속 심음신호는 시작점이 랜덤하므로 순환 HMM을 이용하여 연속심음 인식실험을 추가하였다. 수집된 실제 심음신호는 그 시작점이 각각 다르므로 순환 HMM을 이용하여 연속심음 인식실험을 한 결과 심장질환 분류 정확도는 표 2에서 보는 바와 같이 평균 75.6%를 보이고 있다. 정상 데이터 80개, 비정상 데이터 80개의 연속 심음 데이터를 이용하여 심장질환의 유무를 분류한 결과 표 3에서 보인 바와 같이 93.2%의 평균 검출률을 보이고 있다.

5.2. ELM을 이용한 심장질환 분류

본 논문에서는 ELM 알고리즘에서 은닉층 뉴런의 개수에 따른 심장질환 분류 실험과 각 실험에 대한 심장질환 검출률을 구하였다. 은닉층 뉴런의 개수에 따른 심장질환 분류 결과 그림 14에서 보는 바와 같이 500개와 1,000개의 은닉층 뉴런의 개수를 가질 때 우수한 성능을 보이고 있다. 500개의 은닉층 뉴런의 개수를 가질 때 심장질환 분류 결과 75.9%를 보이고 1,000개의 은닉층 뉴런의 개수를 가질 때 심장질환 분류 결과 78.1%를 보이고 있다. 상대적 개선률은 9.1%를 보이고 있다. 계산량 증가에 비해 성능 증가가 크지 않다. 상대적으로 증가비율이 낮




그림 14. ELM의 은닉층 뉴런 개수에 따른 심장질환 분류 결과
Fig. 14. Cardiac disorder classification accuracy with the different number of hidden neurons in ELM.




그림 15. 시도 횟수에 따른 ELM의 분류 성능
Fig. 15. Cardiac disorder classification accuracy of ELM with the different number of trials.

으므로 이후의 실험에서는 은닉층 뉴런의 개수를 500개로 고정하였다.

실험 시도 횟수에 대한 심장질환 분류 정확도를 조사한 결과 그림 15에서 보인 바와 같이 평균 80.6%의 정확도를 나타내었다.

본 논문에서는 뉴런의 개수는 500개를 가지고 500번째 실험에서 얻은 학습 모델링을 가지고 연속 심음신호의 심장 질환의 종류를 분류하였다. S1/S2 시작점 검출 신호 t_{S1} , t_{S2} 과 개선된 S1/S2 시작점 교정신호 \tilde{t}_{S1} , \tilde{t}_{S2} 을 이용하여 ELM을 이용한 연속심음 인식실험을 수행하였다. 기존의 분할 방식 t_{S1} , t_{S2} 신호를 이용한 심장질환 분류 정확도는 79.4%를 나타내었고 제안한 자동분할 방식 \tilde{t}_{S1} , \tilde{t}_{S2} 신호를 이용한 심장질환 분류 정확도는 81.6%를 나타내었다. 표 4는 기존의 시작점 검출 알고리즘을 이용한 ELM 심장질환 분류 정확도와 제안된 자동검출 알고리즘을 이용한 ELM 심장질환 분류 정확도를 나타낸다.

표 5는 개선된 자동분할과 ELM 패턴분류를 이용한 심

표 4. 기존의 시작점 검출 알고리즘과 제안된 자동 검출 알고리즘을 이용한 ELM 분류 성능 비교

Table 4. ELM classification performance comparison using the conventional starting-point detection algorithm and the proposed automatic segmentation algorithm.

알고리즘	정확도 (%)
기존의 분할 방법	79.4
제안한 자동 분할 방법	81.6

표 5. ELM을 이용한 심장질환 분류 성능

Table 5. Performance of cardiac disorder classification using ELM.

심음	맞게 인식한 샘플 수 / 전체 샘플 수	정확도 (%)	
정상	155 / 160	97	
비정상	AR	6 / 12	50
	AS	8 / 18	44
	AR+AS	13 / 24	54
	MR	11 / 18	61
	MS	19 / 24	79
	MR+MS	8 / 10	80
	MVP	20 / 28	71
	VSD	21 / 26	81
평균	261 / 320	81.6	

표 6. ELM을 이용한 심장질환 검출 성능

Table 6. Performance of cardiac disorder detection using ELM.

입력	인식결과	정상 (%)	비정상 (%)
	정상	96.9	3.1
비정상	3.1	96.9	

장질환 분류 정확도를 나타낸다. 표 6에서 보인 바와 같이 심장질환 검출 정확도는 96.9%를 나타내었다.

5.3. 다른 신경회로망 기반 심장질환 분류

5.3.1. MLP를 이용한 심장질환 분류

MLP [14] 기반의 심음 분류기는 ELM과 동일한 특징벡터를 사용하며, 2개의 은닉층을 가지고 첫 번째 은닉층의 노드 개수는 100이고 두 번째 은닉층의 노드 개수는 20이다. 최대 epoch의 수는 300이고 목표 에러 값은 0.0001로 설정하였다. 학습률은 0.1이고 모멘텀 상수는 0.5로 설정하였다. 활성화 함수는 사그모이드 (sigmoid) 함수를 사용하였고 학습 함수는 scaled conjugate gradient 알고리즘 [15]을 사용하였다.

MLP를 이용하여 연속심음 인식실험을 한 결과 심장질환 분류 정확도는 73.1%를 보이고 있다. 심장질환의 유무

를 판정한 결과 96.9%의 검출률을 보이고 있다.

5.3.2. SVM을 이용한 심장질환 분류

SVM [16][17]기반의 심장질환 분류기에서는 학습 모델링을 구축하기 위하여 입력층은 ELM과 동일한 140차 특징벡터로 구성되어 있고 출력층은 9가지 심장질환 확률을 가지는 신경회로망으로 구성하였다. Radial-basis function networks (RBFN) 커널을 사용하였고 trade-off 가중치 값 C 는 그림 16에서 보는 바와 같이 계산량 증가에 비해 성능 증가가 크지 않으므로 상대적으로 좋은 성능을 보이는 500으로 설정하였다. One-per-class를 사용하여 멀티 클래스로 확장하여 학습 모델링을 얻었다.

SVM을 이용하여 연속심음 인식실험을 한 결과 심장질환 분류 정확도는 76.6%를 보이고 있다. 심장질환 검출률은 96.6%를 보였다.

5.4. 성능비교 및 토의

표 6에서 보는 바와 같이 HMM, MLP, SVM, ELM 기반의 심장 질환 분류기는 각각 75.6%, 73.1%, 76.6%, 81.6%의 분류 정확도를 나타내었다. 표 7에서 보는 바와 같이 HMM, MLP, SVM, ELM 기반의 심장 질환 검출 정확도는 각각 93.2%, 96.9%, 96.6%, 96.9%의 분류 정확도를 나타내었다. ELM 기반 심음분류기는 HMM 심음분류기 오류율 24.4% (=100-75.6)에 비하여 오류율을 18.4% (=100-81.6)로 낮춤으로써 HMM 오류율의 24.6% (= (24.4-18.4)/24.4)를 개선한 것이며, 이 수치는 비교 대상으로부터의 상대적 개선률을 의미한다. 따라서 ELM 기반의 심음 분류기는 HMM, MLP, SVM에 비교하여 24.6%, 31.6%, 21.4%의 상대적 개선률을 나타내었다.

순환 HMM 기반의 심장질환 분류기에서는 다수의 주기를 포함하는 연속 심음신호를 사용하므로 단일 주기 검출 오류에서 기인하는 정확도 저하를 줄일 수 있으나, 인식과정에서 연속 심음 신호 전체를 이용하여 심음을 분석하고 질환의 종류를 분류하기 때문에 많은 처리시간과 메모리를 요구하게 된다.

ELM 기반의 심장질환 분류기에서는 MLP 또는 SVM 알고리즘과 달리 반복학습을 하지 않기 때문에 학습 속도가 매우 빠르고 가장 작은 출력 오차와 놌 최소화 방법을 이용하여 가장 작은 가중치들까지 구하기 때문에 일반화 성능이 우수한 반면에 단일 주기 심음신호로부터 구한 특징벡터를 요구하므로 본 논문에서 제안한 바와 같은 고성능의 자동분할 알고리즘이 필요하다.




그림 16. Trade-off 가중치 값에 따른 SVM의 심장질환 분류 결과
Fig. 16. Cardiac disorder classification accuracy with the different cost values of trade-off in SVM.

표 6. 패턴분류기 종류에 따른 분류 정확도 비교

Table 6. Comparison of classification accuracy with different pattern classifiers.

심음		정확도 (%)			
		HMM	MLP	SVM	ELM
정상		88	96	98	97
비정상	AR	33	33	33	50
	AS	33	44	39	44
	AR+AS	75	54	58	54
	MR	67	50	61	61
	MS	100	63	63	79
	MR+MS	80	50	70	80
	MVP	64	57	57	71
	VSD	46	38	58	81
평균		75.6	73.1	76.6	81.6

표 7. 패턴분류기 종류에 따른 검출 정확도 비교

Table 7. Comparison of detection accuracy with different pattern classifiers.

심음	정확도 (%)			
	HMM	MLP	SVM	ELM
평균	93.2	96.9	96.6	96.9

VI. 결론

본 논문에서는 자동분할을 이용한 ELM 기반의 심장질환 분류기를 제안하였다. 연속심음 데이터를 인식하기 위하여 제1음과 제2음의 시작점들을 검출하고 이를 개선하는 알고리즘을 제안하였다. 패턴 분류기로는 ELM을 사용하였는데, 다른 학습 방법들에 비해 속도가 매우 빠르고 일반화 성능이 우수하며, 한 개의 은닉층을 가진 단순한 신경회로망으로 구성할 수 있다는 장점이 있다. 연속심음 데이터를 이용하여 실험한 결과 ELM 기반 심장질환

환 분류 정확도는 81.6%로서 HMM, MLP, SVM 기반 심장 질환 분류기에 비하여 21~32%의 상대적 개선률을 나타내었다. 특히 심장질환 여부를 판정하는 실험에서 제안 방법은 96.9%의 검출 정확도를 나타내어, 실용화 가능성을 볼 수 있었다.

감사의 글

이 논문은 2007년도 충북대학교 학술연구지원사업의 연구비지원에 의하여 연구되었음.

참고 문헌

1. D. Barschdorff, S. Ester, T. Dorsel, and E. Most, "Neural network based multi-sensor heart sound analysis," Proc. Computers in Cardiology 1990, Chicago, IL, USA, 303-306, Sep. 1990.
2. O. Abdel-Alim, N. Hamdy, and M. A. El-Hanjouri, "Heart diseases diagnosis using heart sounds," Proc. 19th NRSC, Alexandria Univ., Egypt, 634-640, Mar. 2002.
3. D. Barschdorff, U. Femmer, and E. Trowitzsch, "Automatic phonocardiogram signal analysis in infants based on wavelet transforms and artificial neural networks," Proc. Computers in Cardiology 1995, Vienna, Austria, 753-756, Sep. 1995.
4. M. El-Hanjouri, W. Alkhalidi, N. Hamdy, and O.A. Alim, "Heart diseases diagnosis using HMM," Proc. IEEE MELECON 2002, Cairo, Egypt, 489-492, May, 2002.
5. A. Rieke, R. Provinelli, and M. Johnson, "Automatic segmentation of heart sound signals using hidden Markov models," Proc. Computers in Cardiology 2005, 953-956, Sep. 2005.
6. 김희근, 정용주, "Hidden Markov model을 이용한 심음분류에 관한 연구," 한국음향학회지, 3(25), 144-150, 2006.
7. 김희근, 정용주, "Ergodic hidden Markov model을 이용한 연속 심음분류에 관한 연구," 대한의료정보학회지, 13(1), 35-41, 2007.
8. E.R. Davies, *Machine Vision 3rd Ed: Theory Algorithms Practicalities*, (Morgan Kaufmann, 2005), Chap.4, pp.103-125.
9. G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: A new learning scheme of feedforward neural networks," 2004 International Joint Conference on Neural Networks (IJCNN2004), 2, 985-990, July, 2004.
10. G.-B. Huang, Q.-Y. Zhu and C.-K. Siew, "Extreme learning machine: Theory and applications," *Neurocomputing*, 70, 489-501, 2006.
11. Daniel Mason, *Listening to the Heart: A Comprehensive Collection of Heart Sounds and Murmurs*, (F. A. Davis Company, Philadelphia, 2000).
12. 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).
13. H. Liang, S. Lukkarienen, and I. Hartimo, "Heart sound segmentation algorithm based on heart sound envelopegram," Proc. Computers in Cardiology 1997, Lund, Sweden, 105-108, Sep. 1997.

14. M. Leshno, V. Y. Lin, A. Pinkus, and S. Schocken, "Multilayer feedforward networks with a nonpolynomial activation function can approximate any function," *Neural Networks*, 6, 861-867, 1993.
15. M.F. Miller, "A scaled conjugate gradient algorithm for fast supervised learning," *Neural Networks*, 4(4), 525-533, 1993.
16. F. Schwenker, "Hierarchical support vector machines for multi-class pattern recognition," *International Conference on Knowledge-based Intelligent Engineering Systems & Allied Technologies*, Brighton, UK, 2, 561-565, 2000.
17. Y. Liu and Y.F. Zheng, "One-against-all multi-class SVM classification using reliability measures," *IEEE International Joint Conference on Neural Networks*, 2, 849-854, 2005.

저자 약력

•곽 철 (Chul Kwak)



2007년 2월: 배재대학교 전자공학과 (공학사)
 2007년 3월: 현재: 충북대학교 제어계측공학과 (석사과정)
 ※주관분야: 음성인식, 심음인식, 음향부리, 음성및 오디오 처리

•권 오 욱 (Oh-Wook Kwon)



1986년 2월: 서울대학교 전자공학과 졸업
 1988년 2월: 한국과학기술원 전기및전자공학과 (공학석사)
 1997년 2월: 한국과학기술원 전기및전자공학과 (공학박사)
 1986년~2000년: 한국전자통신연구원 책임연구원
 1999년 4월~1999년 12월: 독일 Karlsruhe University 방문연구원
 2000년~2001년: 한국과학기술원 연구교수
 2001년~2003년: University of California, San Diego 박사후 연구원
 2003년 9월~ 현재: 충북대학교 전기전자컴퓨터공학부 부교수
 ※주관분야: 음성인식, 음성및오디오 처리