한국음향학회지 제29권 제2호 pp. 133~140 (2010)

심음 기반의 심장질환 분류를 위한 새로운 시간영역 특징

New Temporal Features for Cardiac Disorder Classification by Heart Sound

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

*충북대학교 전자정보대학 제어로봇공학과
(접수일자: 2009년 11월 29일; 수정일자: 2010년 1월 21일; 채택일자: 2010년 2월 7일)

연속 심음신호로부터 추출한 새로운 시간영역에서의 특징들을 추가하여 심장질환 분류의 성능을 개선한다. 기존에 사용되고 있는 켑스트럼 영역 특징인 멜주파수 켑스트럼 계수 (MFCC)에 심음 포락선, 심잡음 확률벡터, 심잡음 진폭값 변동으로 구성된 새로운 3 종류의 시간영역 특징을 추가한다. 심장 질환 분류 및 검출 실험에서, 시간영역 특징의 분류 정확도에 대한 기여도를 평가하고 순차적 특징선택 방식을 이용하여 시간영역 특징을 선택한다. 선택된 특징들은 다층 퍼셉트론 (MLP), support vector machine (SVM), extreme learning machine (ELM)와 같은 신경회로망 패턴 분류기에 대하여 의미있고 일관되게 분류 정확도를 개선함을 보여준다.

핵심용어: 심음인식, 특징 검출, *ELM*
투고분야: 생체 및 의학 음향 분야 (15.4)

We improve the performance of cardiac disorder classification by adding new temporal features extracted from continuous heart sound signals. We add three kinds of novel temporal features to a conventional feature based on *mel*-frequency *cepstral coefficients* (MFCC): Heart sound envelope, murmur probabilities, and murmur amplitude variation. In cardiac disorder classification and detection experiments, we evaluate the contribution of the proposed features to classification accuracy and select proper temporal features using the sequential feature selection method. The selected features are shown to improve classification accuracy significantly and consistently for neural network-based pattern classifiers such as multi-layer perceptron (MLP), support vector machine (SVM), and extreme learning machine (ELM).

Keywords: Heart Sound Classification, Feature Extraction, Extreme Learning Machine
ASK subject classification: Biological and Medical Acoustics (15.4)

I. 서 론

심장질환은 전체 사망원인 중에서도 차지하는 비중이 점점 늘고 있는 치명적인 질병으로서, 예방과 조기발견을 위하여 간편하고 정확한 초기진단의 필요성이 대두되고 있다. 전 세계적으로 심장질환이 사망의 주요 원인으로 되면서 사망률이 점점 늘어나고 있는 추세이다. 심장질환으로 인한 사망의 대상 연령층도 점점 낮아지고 있어서 국가적인 건강문제가 되고 있는 현실이다. 심장질환을 진단하기 위한 심전도 검사는 정확하지만, 시간과 비용이 많이 소요되는 단점이 있다. 그리고 심초음파 검사는 공기, 지방, 뼈 등은 잘 투과하지 못하는 특수성 때문에 비만환자나 폐질환이 있는 환자는 좋은 영상을 얻을 수 없다. 따라서 심초음파 또는 심전도 검사 전에 전자청진기로 획득한 심음신호를 이용하여 심장질환의 유무와 종류에 대한 정확한 사전정보를 얻을 수 있는 시스템은 건강한 사람들에게는 심장질환을 예방할 수 있고 비만환자나 폐질환, 심장질환을 가지는 환자들에게는 조기발견으로 비용 절감과 진단시간 단축을 가져올 수 있다. 그리고 내과의사에게는 시스템이 질환 우려가 있다고 알려주는 환자를 집중적으로 진단함으로써 정신적, 육체적 부

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

담을 줄일 수 있다.

심장질환 분류 알고리듬으로서 인공 신경회로망 (artificial neural network; ANN)과 은닉 마코프 모델 (hidden Markov model; HMM)을 이용한 알고리듬이 제안되었다. ANN 방식 [1-3]은 연속 심음신호에서 단일주기로 분할하기 위해 전처리 단계에서 자동분할 알고리듬을 가지고 있어야 한다. 자동분할 알고리듬으로 인한 분할 오류들은 인식 정확도를 떨어뜨린다. HMM 방식 [4-7]은 자동분할 알고리듬을 이용하여 연속 심음신호로부터 단일주기로 분할하여 심장질환 종류를 판단할 수 있고 심음신호 분할 과정 없이 연속 심음신호로부터 직접 심장질환 종류를 판단할 수 있으나, 심장질환 분류 정확도가 만족스럽지 않다는 단점이 있다.

두 방식 모두 기존 연구에서는 스펙트럼 (spectrum) 또는 켑스트럼 (cepstrum) 특징들을 기반으로 심장질환을 분류하였다. 그러나 비정상 심음신호는 심잡음 (murmur)과 클릭음 (click sound)의 위치와 특성이 중요하므로, 이를 고려한 시간영역 특징을 사용하는 것이 바람직하다 [8][9].

본 논문에서는 연속 심음신호의 한 주기로부터 추출한 켑스트럼 영역 특징에 심잡음의 위치와 특성을 판단하는데 효과적인 심음 포락선, 심잡음 확률벡터, 심잡음 진폭값 변동과 같은 새로운 시간영역에서의 특징들을 추가한다. 제안된 시간영역 특징의 성능을 평가하기 위하여 신경회로망 기반의 패턴분류기를 사용한다.

제2장에서는 심장질환 분류 알고리듬의 개략적인 구조를 기술한다. 제3장에서는 본 논문에서 새로이 제안한 시간영역에서의 특징들을 추출하는 기법을 설명하고, 제4장에서는 multi-layer perceptron (MLP) [13], support vector machine (SVM) [15][16], extreme learning machine (ELM) [10][11]을 이용하여 새로운 시간영역에서의 특징들의 분류 정확도에 대한 기여도를 비교하여 특징을 선택하고, 심음 분류 및 검출 정확도를 평가한다.

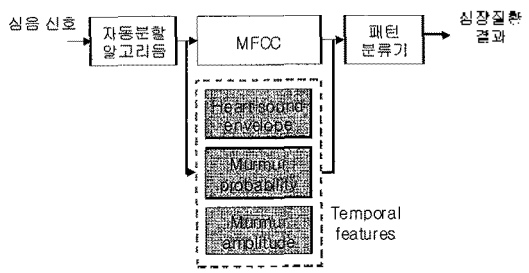

그림 1. 심음 분류 알고리듬
Fig. 1. The heart sound classification algorithm.

제5장에서 결론을 맺는다.

II. 심음 분류 알고리듬

2.1. 전체 구조

본 논문에서 제안한 심음신호 분류 알고리듬은 그림 1에서 보는 바와 같이 구성된다. 연속 심음신호부터, 자동분할 알고리듬을 이용하여 심음신호의 한 주기 심음신호를 획득한다. 한 주기 심음신호로부터 켑스트럼 영역 특징인 멜주파수 켑스트럼 계수 (mel-frequency cepstral coefficients; MFCC) [9]와 로그 에너지 값을 추출한다. 패턴 분류기는 심장질환의 종류를 결정한다. 아래와 같이 묘사한 시간영역에서의 특징들은 이 기본 알고리듬에 추가된다.

2.2. 자동분할

심장질환을 분류하기 위해서 심잡음 또는 클릭음의 위치 정보가 중요하므로 연속 심음신호에서의 제1음 (S1)과 제2음 (S2)의 위치를 검출하여야 한다. 단일 주기의 심음신호를 검출하기 위해 그림 2와 같이 S1, S2 시작점을 검출하고 교정한다 [9].

2.3. 특징 추출

MFCC 및 로그 에너지를 추출하기 위하여 윈도우 크기는 30 ms, 윈도우 이동은 10 ms를 사용한다. 전체 주파수 범위를 멜 척도 (mel-scale)에 따라서 분할하여 필터뱅크 계수를 계산한다. 필터뱅크 출력 값에 log값을 취한 후 이산 코사인 변환 (discrete cosine transform; DCT)을 하여 MFCC를 얻는다.

2.4. 패턴 분류

본 논문에서는 정적 패턴 분류에 높은 성능을 나타내는 신경회로망 기반의 MLP [13], SVM [15][16], ELM [11] 패턴분류기를 사용한다.

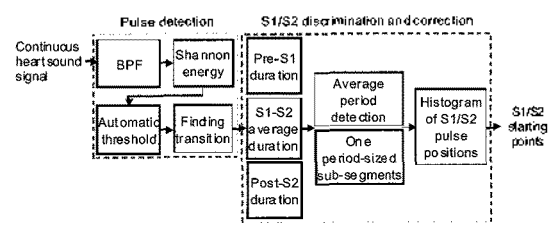

그림 2. 자동분할 알고리듬 [9]
Fig. 2. Automatic segmentation algorithm [9].

MLP는 그림 3과 같은 은닉층을 포함한 연결구조를 가진 신경회로망으로서, 정적 패턴 분류를 위하여 가장 널리 사용된다. MLP에서의 출력 노드값은 다음과 같이 표현된다.

$$z_j(n) = \sum_i g(\omega_{ji}(n)x_i(n)) + b_j \quad (1)$$

$$y_k(n) = \sum_j \omega_{kj}(n)z_j(n) + b_k \quad (2)$$

x_i는 입력층의 i번째 입력값이고, ω_{ji}는 입력층의 i번째 입력값과 은닉층의 j번째 은닉뉴런사이의 가중치 값이고, $g(.)$는 활성함수이고, z_j는 은닉층의 j번째 은닉뉴런의 출력값이다. ω_{kj}는 은닉층의 j번째 은닉뉴런과 출력층의 k번째 출력값사이의 가중치 값이고, y_k는 출력층의 k번째 출력값이다. b_j는 은닉층의 j번째 은닉뉴런의 바이어스 (bias)이고 b_k는 출력층의 k번째 출력뉴런의 바이어스 (bias)이다.

MLP는 단층 퍼셉트론과 달리 임의의 결정 구역을 분류할 수 있으며, 역전파 (back-propagation; BP) 알고리듬 [17]을 이용하여 효율적으로 학습이 가능하다. BP 알고리듬은 전향 단계에서 신경 회로망에 입력 패턴을 제시하고 각 노드에 대해서 입력 함수와 활성화 함수를 이용하여 출력을 산출하고 후향 단계에서 목표 값과 학습 데이터의 실제 출력값의 오차를 최소화하도록 역방향 순서대로 층과 층 사이의 연결 강도를 갱신하여 학습한다.

SVM은 방사 기저함수 (RBF), 그리고 다층 퍼셉트론 (MLP) 분류기의 대안적인 학습방법으로 패턴을 고차원 특징 공간으로 사상시킬 수 있고 적은 양의 학습데이터만으로도 신속하게 분리 학습을 수행할 수 있다. 네트워크의 가중치는 선형 부등 조건을 가진 이차식 계획법 (quadratic programming; QP) [17]문제를 해결함으로써 얻어진다. 또한 SVM은 고정되어 있지만, 알려지지 않은 확률 분포를 갖는 데이터에 대해 오분류 확률을 최소화하는 구조적 위험 최소화 (structural risk minimization; SRM) 방법 [17]을 이용하여 학습 모델을 얻는다. 선형 SVM에 있어서 두 개의 클래스를 구분할 수 있는 초평면 (hyperplane)은 무수히 많으나, 그림 4에서 보는 바와 같이 두 클래스 간점들의 거리 마진 M을 최대화하도록 하는 선형 평면 분류 경계 (optimal separating hyperplane; OSH)는 유일한 해로 존재한다. OSH는 거리 마진 M을 최대화하는 최적의 가중벡터 w와 바이어스 b로서 얻어질 수 있다. QP는 식 (3)의 라그랑지안 (Lagrangian)함수의 안장점 (saddle point)을 찾는 문제로써, 편미분과 Kuhn-Tucker 조건으로서 식 (4)를 최대화 하는 라그랑제 승수 (Lagrange multipliers) α를 찾는 문제로 바꿀 수 있다.

$$J(w,b,\alpha) = \frac{1}{2}w^Tw - \sum_{i=1}^{N}\alpha_i[y_i(w^Tx_i+b)-1] \quad (3)$$

$$Q(\alpha) = \sum_{i=1}^{N}\alpha_i - \frac{1}{2}\sum_{i=1,j=1}^{N}\sum^{N}\alpha_i\alpha_jy_iy_jx_i^Tx_j, \quad y_i\in\{-1,1\} \quad (4)$$

ELM은 그림 5와 같이 단일 은닉층을 갖는 신경회로망으로서, MLP와 같은 고전적 학습 방법들의 단점을 해결하고 빠른 학습시간을 위하여 제안된 것이다. ELM에서의 출력 노드값은 다음과 같이 표현된다.

$$o_{km} = \sum_{j=1}^{N}\beta_{kj}g(\omega_{ji}x_{im}+b_j) \quad (5)$$

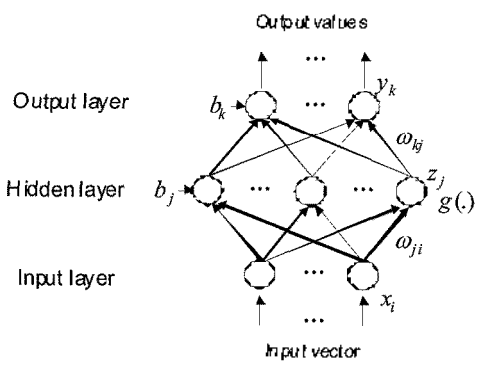

그림 3. MLP 네트워크 구조
Fig. 3. Structure of MLP network.

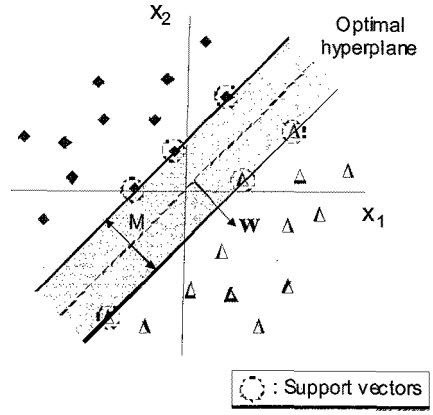

그림 4. OSH, 최대 마진 (M), support vector
Fig. 4. OSH, maximum margin (M), support vector.

x_{im}은 m번째 학습데이터의 i번째 입력값을 나타내고, o_{km}은 m번째 학습데이터의 k번째 출력값을 나타낸다. ω는 은닉 뉴런과 입력 뉴런사이에 연결된 가중치 행렬이고, β는 은닉 뉴런과 출력 뉴런사이에 연결된 가중치 행렬이다. b_j는 j번째 은닉 뉴런의 바이어스이다. $g(.)$는 활성함수이다. N은 은닉 뉴런의 개수를 나타낸다.

ELM의 입력 가중치와 뉴런의 바이어스는 학습되지 않으며, 오직 출력 가중치만이 학습된다는 점이 다른 신경회로망과 다르다. 학습 알고리듬은 놈 최소 자승해와 모어 페로스의 일반화된 역행렬을 이용하여 학습 데이터의 실제 출력값과 목표 출력값의 오차가 최소화되도록 학습한다.

III. 새로운 시간영역 특징

3.1. 심음 포락선

S1/S2과 심잡음의 진폭값 변화는 정상/비정상 심음신호를 판별하는데 있어서 중요하다. 본 논문에서는 정상 심음신호의 분류정확도 저하를 감소시키기 위하여 원 심음신호의 심음 포락선 값을 구한다. 단일주기 심음신호의 포락선을 알기 위해 균일한 길이를 갖는 N개의 부세그먼트 (sub-segment)로 분할하였다. 심음신호의 주기는 약 800~1000 ms이고 클릭음은 약 30 ms 이하의 길이를 가지므로, 본 논문에서는 N=30으로 정하였다. 부세그먼트 내의 샘플 개수는 $K=\lfloor T/N \rfloor$ 으로 결정된다. 여기서 T는 단일주기 심음신호의 샘플 개수이다. 마지막 부세그먼트의 샘플 개수가 K 미만인 경우에는 심음신호의 뒷 부분을 0으로 채운다. 심음 포락선 f_{he}은 다음과 같이 각 부세그먼트의 절대값의 평균값으로 정의된다.

$$f_{he}(n)=\frac{1}{K}\sum_{k=1}^{K}|s(n,k)|, \quad n=1,2,\cdots,N \qquad (6)$$

여기서 $s(n,k)$는 n번째 부세그먼트의 k번째 샘플값을 나타낸다. 심음 포락선 알고리듬의 블록도는 그림 6과 같다.

3.2. 심잡음 확률벡터

비정상적인 심장질환은 시간영역에서 심잡음의 시간적 위치 정보가 심장질환을 분류하는데 있어서 중요하다. 심잡음 신호가 S1/S2 신호에 묻혀져 있는 경우 심잡음의 시간적 위치 정보를 알 수 없다. 본 논문에서는 시간영역에서의 보다 정확한 심잡음 위치를 분석하기 위하여 심잡음 확률벡터를 구한다. 심음신호에서의 심잡음 신호를 강조하기 위해 S1/S2 신호는 차단하고 심잡음 신호는 통과하는 대역통과필터를 적용하여 $\hat{s}$를 계산하였다. 심잡음 확률벡터를 계산하기 위하여 한 주기 심음신호는 M개의 균일한 길이를 가지는 부세그먼트로 분할하였다. 심음신호의 주기는 약 800~1000 ms이고 심잡음의 길이는 약 40~50 ms 이므로 M=20개의 부세그먼트로 분할하였다. 절대값 출력신호는 S1/S2 클래스 (ω_1)과 심잡음 클래스 (ω_2)로 표현되는 2개의 가우시안 확률 분포를 가지는 가우시안 혼합 모델 (Gaussian mixture model; GMM) [17]을 이용하여 모델링된다. GMM 모델링 전에, 묵음 (silence) 부분은 배제한다. 먼저 m번째 부세그먼트의 평균 절대값 $x(m)$를 얻은 후에, 가우시안 분포로부터 심음 확률 $p(x(m)|\omega_1)$ 및 심잡음 확률 $p(x(m)|\omega_2)$을 계산하고, 최종적으로 사후확률 (a posteriori probability) $p(\omega_2|x(m))$을 계산하였다.

$$x(m)=\frac{1}{K}\sum_{k=1}^{K}|\hat{s}(m,k)|, \quad m=1,2,\cdots,M \qquad (7)$$

$$p(x(m)|\omega_i)=\frac{1}{\sqrt{2\pi}\,\sigma_i}e^{-\frac{1}{2}\left(\frac{x(m)-\mu_i}{\sigma_i}\right)^2}, \quad i=1,2 \qquad (8)$$

$$p(\omega_2|x(m))=\frac{p(x(m)|\omega_2)}{p(x(m)|\omega_2)+p(x(m)|\omega_1)} \qquad (9)$$

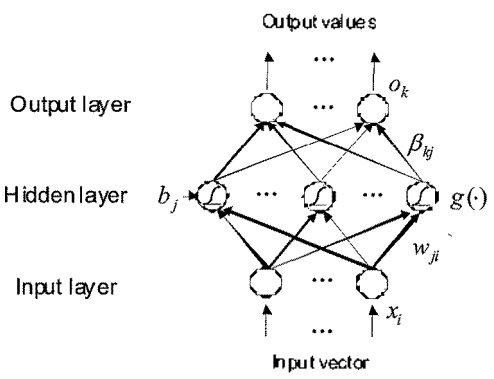

그림 5. ELM 네트워크 구조
Fig. 5. Structure of ELM network.

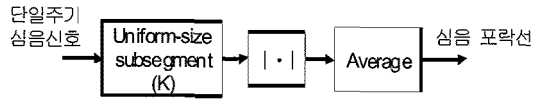

그림 6. 심음 포락선
Fig. 6. Heart sound envelope.

여기서 대역통과필터를 적용한 $\hat{s}(m,k)$는 m번째 부세그먼트의 k번째 샘플값을 나타낸다. $p(x(m)|\omega_i)$는 i번째 클래스에 대한 가우시안 확률분포를 나타내고, μ_i는 i번째 클래스에 대한 평균을 나타내고, σ_i는 i번째 클래스에 대한 표준편차를 나타낸다. 심잡음 확률벡터 알고리듬은 그림 7에서 보는 바와 같이 구성된다.

그림 8은 심잡음 확률벡터 벡터를 구하는 예를 나타낸다. 그림 8 (a)에서 보는 바와 같이 진폭값 (amplitude)이 -1에서 1사이의 값을 가지도록 정규화 (normalization)된 단일주기 심음신호에 대역통과필터를 적용한 후 정규화 하여 그림 8 (b)에서 보는 바와 같이 심잡음을 강조한 출력신호를 얻었다. 대역통과필터의 출력신호에 절대값을 계산하였다. 그리고 그 신호를 절대값 출력신호라고 부른다. 그림 8 (c)는 S1/S2 클래스 (실선)와 심잡음 클래스 (점선)의 가우시안 확률분포를 보여준다. 그림 8 (d)는 절대값 출력신호에 겹쳐진 각 부세그먼트의 심잡음 사후확률을 보여준다.

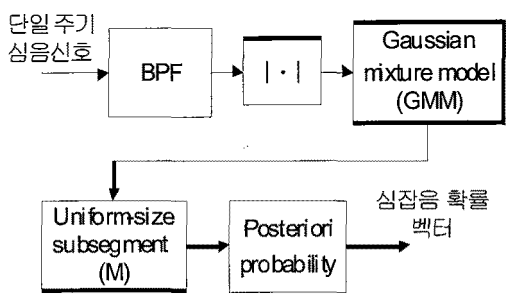

그림 7. 심잡음 확률벡터 계산
Fig. 7. Murmur probability vector computation.

3.3. 심잡음 진폭값 변동

비정상적인 심장질환은 시간영역에서 심잡음 진폭값의 변화가 심장질환을 분류하는데 있어서 중요하다. 본 논문에서는 심음신호에서의 심잡음 신호를 강조하기 위해 S1/S2 신호는 차단하고 심잡음 신호는 통과하는 대역통과필터를 적용하여 $\hat{s}$를 구한다. 대역통과필터를 적용한 절대값 출력 신호는 심잡음의 진폭값 변동을 표현하기 위해 10개의 균일한 길이를 가지는 부세그먼트로 분할하였다. 심음신호의 주기는 약 800~1000 ms이고 심잡음 진폭값의 변동크기는 약 100 ms 이하이므로 L=10개의 부세그먼트로 분할하였다. 각 부세그먼트의 값 $\hat{s}$는 식 (10)과 같은 처리과정을 거쳐 심잡음 진폭값 변동의 10차 특징벡터 f_{mur}를 계산하였다.

$$f_{mur}(l) = \max_k\{|\hat{s}(l,k)|\}, \quad l = 1,2,\cdots,L \qquad (10)$$

여기서 $\hat{s}(l,k)$는 대역통과필터를 적용한 l번째 부세그먼트의 k번째 샘플값을 나타낸다. 심잡음 진폭값 변동 알고리듬은 그림 9에서 보는 바와 같이 구성된다.

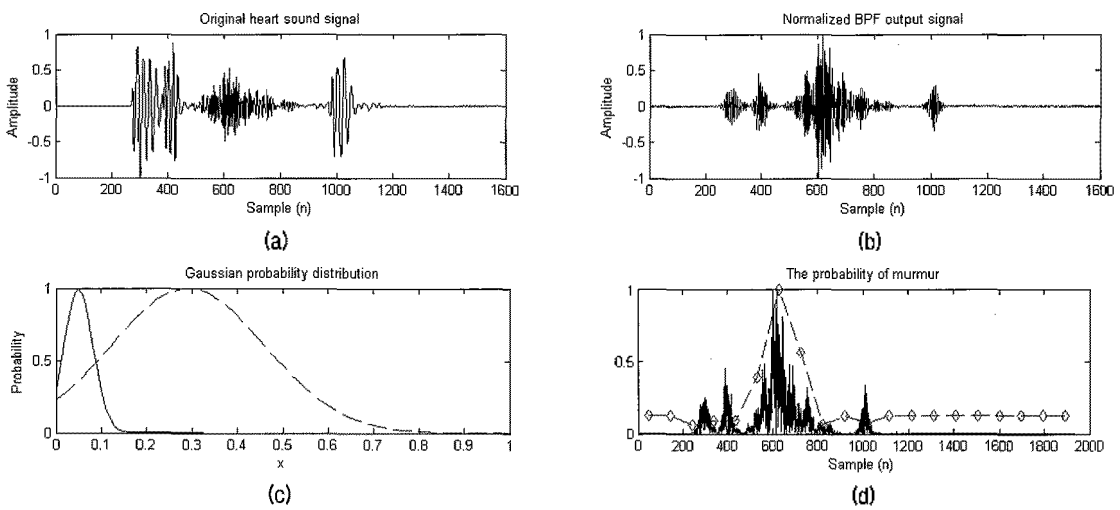

그림 8. 심잡음 확률벡터 계산 예제
(a) 한 주기 심음신호 (b) 대역통과필터 출력신호
(c) 가우시안 확률분포 (d) 절대값 출력신호에 겹쳐진 심잡음 확률벡터
Fig. 8. An example of murmur probability vector computation.
(a) A period of heart sound signals (input) (b) Band-pass filtered signals
(c) Gaussian probability distributions (d) Murmur probability vector overlapped on the absolute value of output signals

IV. 실험 결과

4.1. 심음 데이터

심장질환 분류 능력을 기르기 위해서 제작된 교육용 오디오 시디 (CD) [12]와 Washington 의과대학 [18], Texas 심장협회 [19]에서 공개한 심음 데이터베이스로부터 심음신호를 추출하였다. 여기에 본 연구실에서 수집한 실제 정상인의 심음신호를 추가하여 데이터베이스를 구축하였다. 심음데이터는 2 kHz로 샘플링 되어 16비트 펄스 코드 변조 (pulse code modulation; PCM)로 저장되었다.

심음 데이터베이스는 다수의 주기를 포함하는 연속 심음 데이터로 구성된다. 본 논문에서 각 연속 심음 데이터로부터 추출한 단일 주기 심음을 사용한다. 실험에 사용된 정상 및 심장질환별로 나누어진 연속 심음 데이터의 개수는 표 1과 같다.

총 9개 종류의 심음데이터를 이용하여 학습된 모델을 구축하고 인식실험을 하였다. 심장질환 분류실험에서 비정상적인 심장질환에 대한 데이터의 개수가 적으므로 전체 160개의 심음데이터에서 159개의 심음데이터는 학습용 데이터로 사용하고 1개의 심음데이터만 인식용 데이터로 사용하였다. 인식용 데이터를 바꾸어 가면서 이러한 과정을 반복하여 모든 데이터가 반드시 한 번씩 인식용 데이터로 사용되도록 함으로써, 적은 데이터를 이용하여도 신뢰성 있는 인식결과를 얻을 수 있는 교차검증 (cross-validation) 방식을 이용하였다.

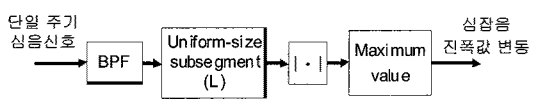

그림 9. 심잡음 진폭값 변동
Fig. 9. Murmur amplitude variation.

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

심장질환 종류		심음 데이터 개수
정상		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

4.2. 신경회로망 기반 심장질환 분류기

MLP 기반의 심음 분류기는 2개의 은닉층을 가지고 출력층은 9가지 심장질환 확률을 가지는 신경회로망으로 구성하였다. 입력층은 특징벡터로 구성되어 있다. 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 시그모이드 (sigmoid) 함수를 사용하였고 학습 함수는 scaled conjugate gradient 알고리듬 [14]을 사용하였다.

SVM 기반의 심장질환 분류기의 입력층은 특징벡터로 구성되어 있고 출력층은 9가지 심장질환 확률을 가지는 신경회로망으로 구성하였다. 방사 기저함수 구조 (Radial-basis function networks; RBFN) [17]커널을 사용하였고 상반관계 (trade-off) 가중치 값 C는 이전 연구 [9]에서 보는 바와 같이 상대적으로 좋은 성능을 보이는 500으로 설정하였다. One-against-all [16]을 사용하여 멀티 클래스로 확장하였다.

ELM 기반의 심음 분류기는 1개의 은닉층을 가지고 출력층은 9가지 심장질환 확률을 가지는 신경회로망으로 구성하였다. 입력층은 특징벡터로 구성되어 있다. 은닉층 뉴런의 개수는 이전 연구 [9]에서 보는 바와 같이 상대적으로 좋은 성능을 보이는 1000로 설정하였다. 활성 함수는 시그모이드 함수를 사용하였다.

4.3. 심장질환 분류

본 논문에서는 MFCC의 다양한 특징차원에 따른 심장질환 분류성능을 비교하였다. 표 2에서 보는 바와 같이 MLP, SVM, ELM기반의 다양한 패턴분류기에서 MFCC의 다른 차원에 따른 분류정확도를 비교하였다. 다양한 패

표 2. 다른 MFCC 차원에 따른 분류 정확도
Table 2. Classification accuracy with different MFCC dimension.

MFCC dimension	Classification Accuracy (%)			
	MLP	SVM	ELM	Average
21	72.8	72.2	73.8	72.9
31	73.1	74.1	75.0	74.1
41	73.4	74.7	75.0	74.4
51	71.3	73.1	76.1	73.5

턴분류기에서 41차 MFCC (로그 에너지 포함)의 41차 특징벡터일 때 가장 높은 평균 정확도를 보였다. 심음신호는 음성신호보다 더 긴 기본 주기를 가지므로 음성인식을 위한 13차 MFCC와 비교하여 더 많은 계수들을 요구한다. 앞으로 본 논문에서는 기본 특징 (baseline feature)으로 41차 MFCC를 사용한다.

본 논문에서는 표 3에서 보는 바와 같이 기본 특징에 각각의 시간영역 특징을 추가하여 정확도를 계산하였다. 표 3에서 보는 바와 같이 기본 특징인 41차 MFCC에 20차 심잡음 확률벡터 ('Probability')를 추가한 MLP 심장질환 분류기는 80.3 %를 나타내었고 기본 특징인 41차 MFCC에 1차 심잡음 지속시간 ('Duration')을 추가한 MLP 심장질환 분류기는 71.9 %를 나타내었다. 비정상적인 심음신호는 심잡음의 시간적 위치와 포락선 정보가 중요하므로 심잡음 확률벡터, 심음 포락선 ('Envelope'), 심잡음 진폭값 변동 ('Amplitude') 등과 같은 특징들은 현저하고 일관된 향상을 보였다. 그러나 심잡음 지속시간은 정확도가 향상되지 않았다. 심잡음 확률벡터를 추가하였을 경우, 심잡음의 시간적 위치를 가장 잘 반영하므로 가장 높은 분류정확도를 나타내었다. 심음 포락선과 심잡음 진폭 변동값은 심잡음 포락선 정보를 가진다. 심잡음 진폭 변동값은 대역통과필터를 통과하므로 잡음신호가 존재하는 정상 심음신호에서의 분류 정확도가 저하된다. 그러므로 심음 포락선은 심잡음 진폭값 변동보다 더 높은 분류 정확도를 나타내었다.

위의 결과를 기반으로 하여 본 논문에서는 가장 좋은 성능을 획득한 시간영역의 특징들을 점증적으로 추가하였다. 표 4에서 보는 바와 같이 ELM 기반의 심장질환 분류기는 41차 MFCC의 경우 75.0 %를 나타내었고, 41차 MFCC에 20차 심잡음 확률벡터를 추가한 경우 81.3 %를 나타내었고, 41차 MFCC와 20차 심잡음 확률벡터에 30차 심음 포락선을 추가한 경우 84.4 %를 나타내었고, 41차 MFCC, 20차 심잡음 확률벡터, 그리고 30차 심음 포락선에 10차 심잡음 진폭값 변동을 추가한 경우 85.3 %를 나타내었다. 본 논문에서 제안한 모든 특징들을 사용하였을 경우, 그 알고리듬은 표 4에서 보는 바와 같이 MLP, SVM, ELM 기반의 심음 분류기는 각각 80.0 %, 81.6 %, 85.3 %의 분류 정확도를 나타내었다. 이 결과들은 기본 특징과 비교하여 24.8 %, 27.3 %, 41.2 %의 상대적 개선율을 나타내었다.

표 3. 시간영역 특징들의 분류 정확도 기여도
Table 3. Contribution of temporal features to accuracy.

Added features (dim)	Classification Accuracy (%)			
	MLP	SVM	ELM	Average
Envelope (30)	75.9	76.3	79.7	77.3
Probability (20)	80.3	78.1	81.3	79.9
Amplitude (10)	76.6	74.7	76.3	75.9
Duration (1)	71.9	73.4	75.6	73.6

4.4. 심장질환 검출

9개의 심장질환 종류에 대한 심장질환 분류실험에서 나온 결과를 사용하여 심장질환 유무를 판단하는 심장질환 검출성능을 측정하였다. 기존의 41차 MFCC 특징벡터를 이용한 ELM 기반 패턴분류기는 6.9 %의 오거부율 (false rejection rate)과 5.6 %의 오인식률 (false alarm rate)을 보였다. 하지만, 지속시간을 제외한 모든 시간특징을 추가한 ELM 기반 패턴분류기는 표 5에서 보는 바와 같이 0.6 %의 오거부율과 4.4 %의 오인식률을 보였다. 이러한 결과는 제안한 알고리듬이 전자 청진기 또는 건강 시스템에 효과적으로 활용될 수 있음을 나타낸다.

V. 결론

본 논문에서는 심잡음과 클릭음이 심장질환 종류를 결정하는데 중요함을 고려하여 새로운 시간영역 특징을 추가한 심장질환 분류 알고리듬을 제안하였다. 기존의 켑스트럼 특징에 추가된 시간영역 특징은 심잡음 신호의 위치 정보를 가지는 심잡음 확률벡터, 심잡음 신호의 포락선 정보를 가지는 심음 포락선 및 심잡음 진폭값 변동

표 4. 시간영역 특징들을 점증적으로 추가될 경우 분류 정확도
Table 4. Classification accuracy when the temporal features are appended incrementally.

Incremental Feature (dim)	Classification Accuracy (%)			
	MLP	SVM	ELM	Average
MFCC (41)	73.4	74.7	75.0	74.4
+Probability (20)	80.3	78.1	81.3	79.9
+Envelope (30)	78.9	80.9	84.4	81.4
+Amplitude (10)	80.0	81.6	85.3	82.3

표 5. ELM을 이용한 제안한 알고리듬의 심장질환 검출 성능
Table 5. Cardiac disorder detection performance of proposed algorithm using ELM.

입력 \ 인식결과	정상(%)	비정상(%)
정상	99.4	0.6
비정상	4.4	95.6

으로서, 더 정확한 심잡음 신호의 시간적 위치 특성을 반영한다. 제안된 시간영역 특징들은 MLP, SVM, ELM 기반의 심음 분류 실험에서 켑스트럼 특징만을 사용한 경우에 비하여, 24.8 %, 27.3 %, 41.2 %의 상대적 개선율을 나타내었다. 또한 제안한 시간특징을 이용한 심장 질환 검출기는 0.6 %의 오거부율과 4.4 %의 오인식률을 보였다. 이 결과는 전자청진기를 이용한 심장질환의 조기 발견에 활용될 수 있다.

감사의 글

이 논문은 2009년 정부 (교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (2009-0073257).

참 고 문 헌

1. 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.
2. 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.
3. 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.
4. A. Ricke, R. Provinelli, and M. Johnson, "Automatic segmentation of heart sound signals using hidden Markov models," *in Proc. Computers in Cardiology 2005*, pp. 953-956, 2005.
5. 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, March, 2008.
6. 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.
7. 김희근, 정용주, "Ergodic hidden Markov model을 이용한 연속 심음분류에 관한 연구," *대한의료정보학회지*, 13권, 1호, 35-41쪽, 2007.
8. 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, 2008.
9. 곽철, 권오욱, "자동 분할과 ELM을 이용한 심장질환 분류 성능 개선," *한국음향학회지*, 28권, 1호, 32-43쪽, 2009.
10. 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 (IJCNN'2004)*, vol. 2, pp. 985-990, July. 2004.
11. G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: Theory and applications," *Neurocomputing*, vol. 70, pp. 489-501, 2006.
12. Daniel Mason, *Listening to the Heart: A Comprehensive Collection of Heart Sounds and Murmurs*, F. A. Davis Company, Philadelphia, 2000.
13. M. Leshno, V. Y. Lin, A. Pinkus, and S. Schocken, "Multilayer feedforward networks with a nonpolynomial activation function can approximate any function," *Neural Networks*, vol. 6, pp. 861-867, 1993.
14. M.F. Møller, "A scaled conjugate gradient algorithm for fast supervised learning," *Neural Networks*, vol. 4, no. 4, pp. 525-533, 1993.
15. F. Schwenker, "Hierarchical support vector machines for multi-class pattern recognition," *International Conference on Knowledge-based Intelligent Engineering Systems & Allied Technologies*, Brighton, UK, vol. 2, pp. 561 - 565, 2000.
16. Y. Liu and Y.F. Zheng, "One-against-all multi-class SVM classification using reliability measures," *IEEE International Joint Conference on Neural Networks*, vol. 2, pp. 849-854, 2005.
17. Simon Haykin, *Neural Networks: A comprehensive foundation*, 2nd ed, Prentice Hall, 1999.
18. University of Washington department of medicine, *Technique: Heart Sounds & Murmurs*, http://depts.washington.edu/physdx/heart/tech.html
19. Texas heart institute at 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)
한국음향학회지 제28권 제1호 참조