

계층구조적 분류모델을 이용한 심전도에서의 비정상 비트 검출

이도훈, 조백환, 박관수, 송수화, 이종실, 지영준, 김인영, 김선일

한양대학교 의용생체공학과

Detection of Abnormal Heartbeat using Hierarchical Classification in ECG

Do Hoon Lee, Baek Hwan Cho, Kwan Soo Park, SooHwa Song, Jong Shill Lee, Young Joon Chee, In Young Kim, Sun Il Kim

Department of Biomedical Engineering, Hanyang University

(Received October 6, 2008. Accepted December 15, 2008)

Abstract

The more people use ambulatory electrocardiogram (ECG) for arrhythmia detection, the more researchers report the automatic classification algorithms. Most of the previous studies don't consider the un-balanced data distribution. Even in patients, there are much more normal beats than abnormal beats among the data from 24 hours. To solve this problem, the hierarchical classification using 21 features was adopted for arrhythmia abnormal beat detection. The features include R-R intervals and data to describe the morphology of the wave. To validate the algorithm, 44 non-pacemaker recordings from physionet were used. The hierarchical classification model with 2 stages on domain knowledge was constructed. Using our suggested method, we could improve the performance in abnormal beat classification from the conventional multi-class classification method. In conclusion, the domain knowledge based hierarchical classification is useful to the ECG beat classification with unbalanced data distribution.

Key words : arrhythmia detection, unbalanced data distribution, hierarchical classification, domain knowledge, support vector machine

1. 서론

부정맥은 심장의 전기적 신호의 전달과정에서 방해요인이 작용하여 심장박동 주기의 불규칙성, 혹은 정상적인 심장박동 파형의 일그러짐을 유발하는 심장질환의 일종이다. 부정맥은 일반적으로 크게 두 가지로 나눌 수 있는데 첫째는 심실세동(ventricular fibrillation)이나 빈맥(tachycardia)과 같이 생명에 직접적인 위협을 주고 응급조치를 요하는 위험한 형태이다. 두 번째는 당장의 생명에 직접적인 영향을 끼치지 않지만 상당히 위험한 결과를 불러올 수 있는 형태의 부정맥들이다[1]. 잠재적인 위험요소가 강한 부정맥들은 조기에 발견해서 조치를 취하지 않는다면 생명을 위협하는 심각한 위험을 초래할 수 있다.

이러한 부정맥은 발생 빈도가 적은 경우가 많아 짧은 시간의 관찰로 진단을 하기가 어렵다. 그래서 홀터(holter) 심전도장비를 통해서 24시간, 혹은 그 이상의 장시간 데이터를 이용하여 부정맥을

진단하게 된다. 장시간 데이터를 관찰함으로써 환자의 부정맥 출현 유형이나 위험도가 얼마나 높은지 알 수 있기 때문에 현대의학에선 홀터 데이터를 이용한 심장질환에 관한 연구가 많이 진행되고 있다. 그러나 판독자가 장시간의 심전도 데이터를 직접 검사하는 것은 시간적, 경제적으로 매우 비효율적이다.

이러한 난점을 해결하기 위해 부정맥 자동진단 알고리즘의 개발이 필요하다. 최근 수십 년 동안 데이터 마이닝과 기계 학습 분야의 발전, 컴퓨터 성능의 발전에 힘입어 부정맥 자동진단 알고리즘에 대한 연구가 국내외로 많이 수행 되었다. 특히 기계 학습 분야에서 심전도 데이터로부터 추출 가능한 특징점들과 분류모델에 관한 연구가 많이 진행 되었다[2-9]. 특징점에 관하여 형태학적인 특징점[3-4], 간격에 관한 특징점[3-5], 고차통계 기법으로 구한 특징점[6] 등을 다룬 연구가 있었으며 분류모델에 관하여 선형 판별법(linear discriminant)에 기초한 분류법[1,3], back propagation neural network[3-5], self-organizing network[8]등에 관한 연구가 있었다. 이러한 연구들 중 한 예로, Chazal 등의 연구를 살펴보면 RR(R-peak to R-peak)간격, 심전도를 구성하는 파형의 간격, 형태학적인 특징점들을 이용하여, 선형 판별법에 기초한 분류법으

Corresponding Author : 김인영

서울 성동구 행당동 17 한양대학교 의용생체공학과

Tel : +82-2-2291-1713 / Fax : +82-2-2296-5943

E-mail : iykim@hanyang.ac.kr

본 논문은 지식경제부의 실버의료기기 핵심기술개발 사업의 지원으로 수행되었습니다.

로 약86.2%의 예측정확률(accuracy)을 보이고 있다[1].

선행된 연구에서는 데이터가 가지는 클래스의 분포에 대해서 자세하게 설명 되어있지 않거나 임의로 비율을 조절하여 성능을 평가하는 연구가 많았다[10-12]. 실제의 부정맥 데이터는 정상적인 비트(beat)가 상대적으로 많기 때문에 데이터의 분포를 살펴보면 상대적으로 양성데이터(심각한 질병을 가진 환자의 데이터)가 적은, 불균형적인(unbalanced) 양상을 띠고 있는 경우가 대부분이다. 데이터의 분포를 임의로 조절해서 비율을 맞춘 데이터를 분류하는 알고리즘은 실제 데이터 적용 시 성능이 저하될 가능성이 있다. 이는 대부분의 실제 데이터는 양성데이터가 적은데, 이러한 불균형적인 데이터에 분류(classification)나 예측(predict) 같은 기법을 적용하는 연구의 경우에는 한쪽으로 치우쳐진 결과(skewed result)를 도출할 확률이 높기 때문이다. 그렇기 때문에 그러한 연구결과는 높은 성능이 도출 되어도, 그 결과가 얼마나 실제 데이터에 대해서도 좋은 성능을 나타낼지는 평가하기 어렵다[13]. 이러한 문제를 해결하기 위해서는 데이터의 분포에 대해서 명확하게 밝히고 데이터의 불균형적인 분포를 고려한 연구가 필요하다.

대부분의 다중 클래스의 분류 문제는 상당히 복잡적이며 계산적 복잡성(complexity)이 높다는 문제점이 있다[14]. 분류(classification)와 관련된 문제를 해결하기 위해 최근에 support vector machine(SVM)이 많이 사용되고 있다. SVM을 이용하여 다중분류를 수행할 경우에는 'one-against-one'의 접근법이 가장 보편적으로 많이 사용된다. 이것은 k개의 클래스를 대상으로 k(k-1)/2개의 분류 모델을 세워서 투표방식(voting strategy)으로 최적의 분류 모델을 선정하는 방법이다[15]. 이는 계산시간이 오래 걸리는 문제뿐 아니라 편중된 분포를 갖는 데이터에는 적용하기 힘들다. 즉, 여러 개의 클래스 중에서, 특정 클래스의 데이터를 민감하게 분류할 수 있도록 패널티를 조절하는 cost sensitive 방법의 적용이

매우 어렵다[16]. 그래서 이러한 단점을 해결하기 위한 여러 접근법이 연구 되었는데 그 중 제안된 기법이 계층적 분류 기법이다. 다중분류를 이진 분류(binary classification)로 재구성 하게 되면 위에서 언급한 구조적인 복잡성이 해결될 수 있다. 그러나 기존의 계층적 분류 방법은 분류 모델의 모든 경우의 수를 구하여 조합을 통한 모델링 생성과정을 거치기 때문에 불필요한 계산량이 포함될 가능성이 매우 높다. 즉, 최적의 분류 모델을 도출하는데 많은 시간을 필요로 한다[17].

따라서, 본 연구에서는 분포가 한쪽으로 치우쳐진 데이터 문제를 해결하기 위하여, SVM기반의 계층구조적인 분류 모델을 세워, 클래스를 세분화 하여 분류하는 방법(hierarchical classification)을 제안하였다. 또한, 본 연구에서 제안한 계층구조적 분류 모델은 클래스를 세분화 할 때 영역 지식(domain knowledge)을 적용하여 효과적인 특징점 만을 사용하고, 불필요한 모델생성의 과정을 줄임으로써 계산 속도를 향상시킬 수 있다는 장점을 가지고 있다. 본 연구에서 제안한 영역 지식을 적용한 특징점 선택이 올바른 접근법이었는지 성능을 평가하기 위한 비교 실험을 진행하였으며, 제안된 계층적인 분류 모델을 평가하기 위해 전통적인 다중 분류와 최종 성능 비교를 하였다.

II. 재료 및 방법

A. 데이터 수집

본 연구에서는 MIT-BIH 부정맥 데이터베이스에 있는 총 44개의 30분 길이의 부정맥 데이터 레코드를 사용하였다[18]. Association for the Advancement of Medical Instrumentation (AAMI)의 권고에 따라 총 48개의 레코드 중 페이스 메이커에 의한 비트가 포함되어 있는 4개의 레코드는 제외하고 평가하였다

표 1. AAMI에서 권고하는 비트클래스 재 분류

Table 1. Mapping the MIT-BIH arrhythmia database heartbeat types to the AAMI heartbeat classes.

AAMI heartbeat class	N	S	V	F	Q
Description	Any heartbeat not in the S, V, F or Q classes	Supra-ventricular Ectopic beat	Ventricular ectopic Beat	Fusion beat	Unknown beat
MIT-BIH Heartbeat types	Normal beat (NOR) Left bundle branch Block beat (LBBB) Right bundle branch Block beat (RBBB) Atrial escape beat (AE) Nodal(junctional) escape Beat (NE)	Atrial premature beat (AP) Aberrated atrial premature beat (aAP) Nodal(junctional) premature beat (NP) Supra-ventricular premature beat (SP)	Premature ventricular contraction (PVC) Ventricular escape Beat (VE)	Fusion of ventricular and normal beat (fVN)	Paced beat (P) Fusion of paced and normal beat Unclassified beat (U)

표 2. Dataset에 포함된 클래스의 분포

Table 2. Beat distribution of each dataset

	N	S	V	F
DS1	46365	803	3916	379
DS2	44238	1834	3221	388

[19]. 또한, 각각의 레코드는 두 개의 심전도 채널에 대한 정보가 포함되어 있지만 본 연구에서는 두 번째 채널의 데이터가 표준 심전도 유도법 상에서 레코드 별로 일치 하지 않는 점을 고려하여 첫 번째 채널의 정보만을 사용하였다.

각각의 데이터는 0.1~100Hz로 대역통과필터를 거쳤으며 360Hz로 샘플링 되었다. 총 109000개의 비트에 서로 다른 총15 가지 형태의 부정맥 결과가 주석으로 달려있으며 가장 많은 클래스는 ‘Normal beat’ 이고 가장 적은 클래스는 ‘Supra-ventricular premature beat’ 이다. ANSI/AAMI 에서는 이 15가지의 비트를 영역지식에 근거하여 유사한 형태의 비트끼리 재분류할 것을 권고 했다[19]. AAMI에 근거하여 표1과 같이 총 15종류의 비트를 N, S, V, F의 4가지 클래스로 재분류 하였으며 페이스 메이커에 의한 비트가 포함된 Q(Unknown) 클래스는 제외하였다.

사용된44개의 MIT-BIH레코드는 22개씩의 레코드를 포함하는 두 개의 레코드 셋(DS1, DS2)으로 나누었다. DS1은 분류모델의 학습(training) 및 성능평가를 위해 사용되었고, DS2는 부정맥 자동진단 알고리즘의 최종 성능평가를 위해 사용되었다. 전체 레코드 중 21개의 레코드에는일반적으로 정상적인 레코드(normal beat가 많은)가 많이 포함된 경향이 있으며 나머지 23개의 레코드는 복합적인 심실, 접합부, 상심실성 부정맥 등의 정보가 포함되어 있는 경향이 있다. 따라서, 표 2과 같이 성능 테스트의 신빙성을 높

이기 위하여 DS1과 DS2에 분포한 클래스의 비율을 비슷하게 맞추어 레코드 셋을 나누었다[1].

B. Preprocessing

본 연구에서 사용된 MIT-BIH 데이터들은 두 개의 미디안 필터 (median filter)를 사용하여 베이스라인을 제거하였다. 먼저 200ms 넓이의 미디안 필터를 사용하여 QRS 군과 P파를 제거하고 600ms 넓이의 미디안 필터를 사용하여 T파를 제거하였다. QRS 군과 P, T파가 제거된 저주파 곡선을 베이스라인이라 간주하고 원 신호에서 베이스라인을 빼주어서 베이스라인을 제거하였다. 베이스라인이 제거된 신호에는 60Hz 전원 노이즈와 고주파성분의 신호를 제거하기 위하여 12차 저대역 통과 필터를 적용하였다[1].

C. 특징점(feature) 추출

본 연구에서는 RR간격 정보와 형태학적 정보를 각각 사용하였으며 RR간격 특징점 3개, 형태학적 특징점 18개를 사용하였다. RR 간격 특징점과 형태학적 특징점은 부정맥을 판단함에 있어 중요한 특징점이다. RR간격의 차이는 경우에 따라 다양한 형태를 띠지만 부정맥에 있어서 심전도의 정상파형을 구성하는 P파, QRS 군, T파의 부재로 인한 RR간격의 차이를 보이는 경우가 많기 때문




그림 1. FP를 기준으로 실시한재 표본화. FP를 기준으로 첫 번째 창을 씌운 후 60Hz로 재 표본화 하여10개의 sample을 얻고, 두 번째 창을 씌운 후 20Hz로 재 표본화 하여8개의 sample을 얻는다.

Fig. 1. Re-sampling after determining the Fiducial Point. Ten ECG signal points are sampled at 60Hz in the first window. In the second window, another eight ECG signal points are sampled at 20Hz.

에 RR간격은 정상파형과 비정상파형을 구분하는데 중요한 지표가 될 수 있다. 이에 더해, 심실성 이소성박동(ventricular ectopic beat)과 같은 경우 QRS군의 파형에서 정상파형과 비교했을 때 파형의 형태학적인 면이 큰 차이를 보이기 때문에 형태학적인 특징점은 이러한 심실의 이상파형을 검출하는데 유용한 특징점이 된다 [20].

RR간격 특징점을 추출하기 위해서는 비트 검출(beat detection)을 통한 R극점(R-peak) 정보가 필요하다. 본 연구에서는 비트 검출 과정 대신, MIT-BIH에서 제공하는 주석(annotation) 파일에 있는 기준점(Fiducial Point, FP)정보를 이용하여 R극점을 설정하였다[1]. 이 기준점을 이용하여 이전 비트와의 간격인 pre-interval, 인접한 10개의 RR간격의 평균값인 local averaged interval, 그리고 현재 비트를 local averaged interval로 나누어 주어 평균편차를 알려 주는 RR 간격비 값을 구하였다.

형태학적 특징점을 추출하기 위해서 심전도 파형에 윈도우를 씌워 특정 위치의 데이터 값을 재 분화 하였다. 특히 심실성 이소성박동과 같이 QRS군과 T파에서 형태학적으로 큰 차이를 보이는 점을 감안하여 QRS군과 T파의 정보를 특징점으로 사용하기 위해서 서로 다른 넓이의 두 개의 창을 사용하였다. 그림 1에서 보여진 바와 같이 기준점을 중심으로 -50ms 지점부터 +100ms 지점까지 (QRS군) 창을 씌워 창 안의 데이터를 60Hz로 정규 재 표본화를 통해 10개의 특징점을 뽑아내고, +150ms부터 +500ms 지점까지 (T파) 창을 씌워 창 안의 데이터를 20Hz로 정규 재 표본화 하여 8개의 추가적인 특징점을 뽑아내었다[1].

D. Support Vector Machine

SVM은 통계적 학습이론에 기반을 두고 있는 기계 학습법의 일종이다. SVM은 분류 및 예측 기법에 많이 사용되고 있으며, 그룹간의 데이터를 N차원의 벡터공간에서 그룹을 구분 짓는 초월평면(hyper-plane)을 구하는 기법이다. 예를 들어 두 그룹이라고 가정

했을 때, 두 그룹을 구분 짓는 선형 평면 분류 경계를 Optimal Separating Hyper-plane(OSH)이라고 하는데, 이 OSH에 가장 가까운 점들을 support-vector라고 부른다. 그래서 이 OSH와 support vector간의 거리, 즉 마진(margin)을 최대화 하는 것이 SVM기법이다[21-22].

이렇게 찾은 초월평면에 대하여 새로운 데이터인 테스트 데이터를 적용하여 분류할 때, 보다 더 정확한 예측을 할 수 있다는 가정을 전제로 두고 SVM은support-vector들을 구한다음 이 support-vector들만을 가지고 분류모델을 세우게 된다.

구해진 분류모델(classifier)로부터 최종적으로 수식1과 같이 결정함수(decision function)를 구할 수 있게 된다. 구해진 결정함수에 테스트 데이터를 적용하였을 때 함수의 결과 값이 양수이면 양성 데이터로, 음수이면 음성 데이터로 분류하게 된다.

$$F(x) = \text{sgn}\left(\sum_{i=1}^n \alpha_i y_i K(x, x_i) + b\right) \quad (1)$$

α 는 Lagrange multiplier로써, 모든 학습데이터마다 하나씩의 양수 값을 가지게 되는데, support-vector외의 다른 데이터는 모두 0의 값을 가지게 된다. K는 커널함수(kernel function)라고 하며 경우에 따라서 선형 커널과 비선형 커널이 사용된다.

E. 계층구조적 분류

본 연구에서는 다중 분류를 이진 분류로 재구성하는 계층구조적 분류모델을 그림 2와 같은 형태로 제안하였다. 먼저 첫 번째 단계에서 입력 비트를 (N, S)그룹혹은 (V, F) 그룹으로 분류하도록 한다. 그 후 두 번째 단계에서 (N, S)그룹으로 분류된 비트를 최종적으로 N 혹은 S 중 하나의 라벨로 분류하고, 마찬가지로 (V, F)그룹의 비트도 V혹은 F중 하나의 라벨로 분류한다. 제안된 계층구조적 분류모델은 영역 지식을 적용하여, 비정상 비트의 특성을 고려하

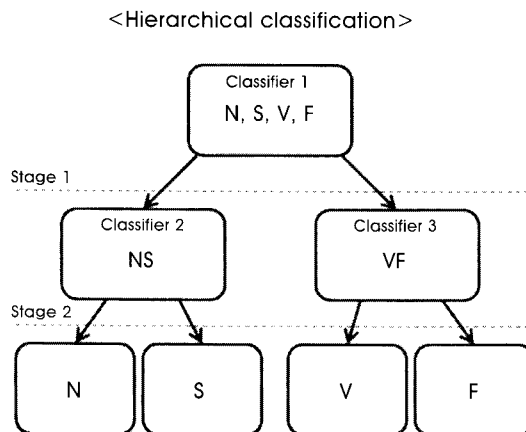


그림 2. Hierarchical classification 설계도.
Fig. 2. Hierarchical classification scheme.

여 설계되었다. N비트와 S비트는 형태학적인 측면에서 살펴보았을 때 정상비트와 비슷하다는 점을 이용하여 같은 클래스로 구분 지을 수 있다. V비트와 F비트는 정상비트와 형태학적 정보가 확연하게 다르다는 점을 이용하여 같은 부류로 구분 지을 수 있다. 따라서 먼저 (N, S)와 (V, F)를 첫 번째 단계에서 분류하도록 하여, 오류가 일어날 확률을 최소화하고자 하였다.

각각의 분류단계(stage)에서도 영역 지식을 활용하여 특징점을 선정하였다. 첫 번째 단계에서는 추출한 21개의 모든 특징점을 사용하였다. 심실상성 이소성박동(supra-ventricular ectopic beat)은 S파의 부재로 인해 정상 비트와 RR간격에서 큰 차이를 보이게 된다. 그러나 QRS 군 및 T파는 정상 비트와 심실상성 이소성박동간에 큰 차이를 보이지 않는다[20]. 그러므로 N과 S비트를 구분하는 두 번째 단계에서는 RR간격과 관련된 특징점만을 이용하였다.

이렇게 영역 지식을 바탕으로 설계된 계층구조적 분류모델은 불필요한 분류모델을 세움으로써 드는 비용, 시간을 절감할 수 있는 이점을 가지고 있다. 또한 ROC곡선 아래 영역(area under curve, AUC)을 구해서 각 클래스의 민감도를 효과적으로 조절하여 최적의 분류모델을 비교적 쉽게 생성할 수 있다는 장점을 가지고 있다. 하지만 본 연구에서 제안한 계층구조적 분류 모델은 영역지식을 적용한 직관적인 분류모델이기 때문에 이 분류모델이 최적의 모델인지를 검토할 필요성이 있다. 또한 분류단계에서 유용한 특징점만을 선택한 것도 직관적인 선택이기 때문에 타당성을 검증하는 단계가 필요하다.

F. 실험절차 및 평가방법

전처리 과정을 완료한 데이터는 상대적으로 큰 용량이기 때문에 모델링을 하는 과정에서 시간이 오래 걸리는 단점이 있다. 그래서 본 연구에서는 예측 모델 생성 및 cross-validation에 필요한 계산 시간을 줄이기 위해서 DS1의 데이터로부터 클래스 라벨의 비율을 정확하게 유지하여 표본을 추출하였다. 원본 DS1은 약 50,000개의 비트로 구성되어 있으며 원본의 데이터 분포를 정확히 유지하여 원본의 20% 데이터를 표본추출 하였다. 그래서 DS1은 약 10,000개의 비트로 구성되어 있으며 Training에 필요한 계산 시간은 1.86GHz의 CPU와 2.00 GB RAM의 사양을 가지는 PC에서 표3과 같이 경감되었다.

표 3. 평균계산속도 경감 시간
Table 3. Computation time variance

	표본추출 전	표본추출 후
1 Fold	10분 ¹	3분
11 Fold	105분	30분

¹같은 각 과정의 평균 시간

학습단계에서 분류성능을 평가하고, 분류기의 파라미터를 튜닝(tuning)하기 위하여 주로 cross-validation을 수행하는데, 이 때 일반적으로 학습 데이터를 무작위로 추출하게 된다(random cross-validation, RCV). 하지만 무작위 추출을 수행하면 그 결과는 과대평가가 되었을 확률이 높다. 그 이유는, 같은 클래스라 하더라도 레코드 별로 각각의 RR간격이나 형태학적인 특징이 조금씩 상이한데 무작위 추출을 하게 되면 학습 데이터와 테스트 데이터가 같은 레코드에서 선정될 확률이 매우 높다. 그러므로 같은 레코드에서 학습 데이터와 테스트 데이터가 선출되게 되면 데이터의 독립성이 의심받을 수 있고, 그에 따라서 결과가 과대평가될 가능성이 높다. 따라서 본 연구에서는 그림3에서와 같이 DS1으로 학습하는 단계에서 22개의 레코드 별로 11-fold cross-validation (constrained cross-validation, CCV)을 수행하여 과대평가가 되는 것을 최대한 방지하였다. 첫 번째 실험으로 전통적인SVM을 적용한 11-fold CCV와 RCV에 대해 DS1을 이용하여 cross-validation 결과를 비교하였다. 그리고 나서 계층구조적 분류모델과의 성능 비교를 위하여 DS2를 이용하여 테스트 실험을 수행하였다.

본 연구에서 제안한 계층구조적 분류 모델이 최적의 모델인지를 검토하기 위해서 표4와 같이4개의 클래스로 생성할 수 있는 다른 분류모델들의 성능들을 본 연구에서 제안한 계층구조적 분류모델의 성능과 비교하였다. 그리고 영역 지식을 적용하여 N과 S를 분류하는데 유용한 특징점은 RR간격이라고 판단하였다. 그래서 예비실험으로 N과 S를 분류하는데 사용된 특징점들을 바꿔가면서 영역 지식을 적용한 근거의 타당성을 검증하였다.

마지막으로, 계층구조적 분류모델의 성능을 평가하기 위해 DS1을 가지고 CCV를 수행하고 ROC곡선의 곡선아래면적을 비교하여 최적의 분류모델을 찾아내었다. 최종적으로 DS2를 이용하여

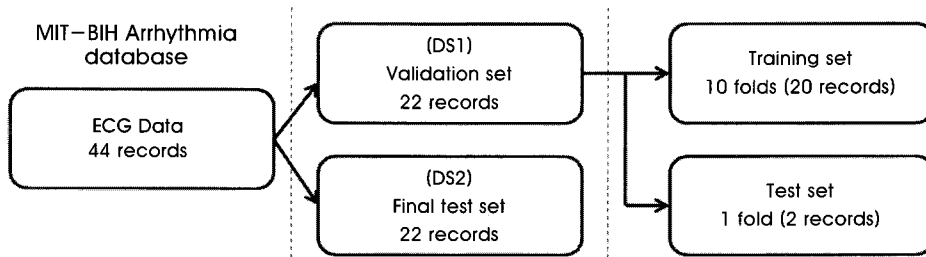


그림 3. 11-fold constrained cross-validation 블록도
Fig. 3. 11-fold constrained cross-validation framework

표 4. 계층적 분류모델의 모든 경우의 수

Table 4. All of hierarchical classification scheme for the 4 classes

Scheme No.	Stage 1	Stage 2
1	NS vs. VF	N vs. S V vs. F
2	NV vs. SF	N vs. V S vs. F
3	NF vs. SV	N vs. F S vs. V

계층구조적 분류모델의 성능을 평가하였다.

모델링 결과는 예측정확률, 민감도(sensitivity), 특이도(specificity), AUC등을 비교하였고, 최종성능은 이에 더해 표5와 같이 결정 매트릭스(confusion matrix)를 통하여 평가하였다[18].

표5는 실제 비트의 상태와 예측된 결과를 비교하고 성능을 평가하는 지표를 계산할 때 사용되는 결정 매트릭스를 나타내는 표이다. 결정 매트릭스로 결과를 표현하는 방법은 잘못 예측된 결과나, 잘 예측된 결과는 어느 정도인지 한눈에 알아보기 쉽다는 것이 장점이다. 이에 비트별 True Positive (TP), True Negative (TN), False Positive (FP), False Negative (FN)를 계산하여 예측정확률, 민감도, 특이도를 계산하여 정량적으로 성능을 평가하기에 쉬운 표로 작성하게 된다. 결정 매트릭스로부터 각 지표를 계산하는 방법은 수식 (2)-(10)과 같다.

$$FN_n = Nn + Ns + Nf \quad (2)$$

$$FN_s = Sn + Sv + Sf \quad (3)$$

$$FN_v = Vn + Vs + Vf \quad (4)$$

$$FN_f = Fn + Fs + Fv \quad (5)$$

$$SenN = Nn / FN_n \quad (6)$$

$$SenS = Ss / FN_s \quad (7)$$

$$SenV = Vv / FN_v \quad (8)$$

표 5. 결정 매트릭스

Table 5. Confusion matrix

	Predicted label					Sensitivity
	N	S	V	F		
Original label	N	Nn	Ns	Nv	Nf	Sen N
	S	Sn	Ss	Sv	Sf	Sen S
	V	Vn	Vs	Vv	Vv	Sen V
	F	Fn	Fs	Fv	Ff	Sen F

표 6. 각 학습단계별 곡선아래면적값 결과

Table 6. Performance of each classification scheme

Scheme No.	Stage 1	AUC	Stage 2	AUC
1	NS vs. VF	0.9486	N vs. S V vs. F	0.9012 0.7658
2	NV vs. SF	0.7133	N vs. V S vs. F	0.9604 0.7869
3	NF vs. SV	0.9459	N vs. F S vs. V	0.7330 0.8902

$$SenF = Ff / FN_f \quad (9)$$

$$Accuracy = \frac{Nn + Ss + Vv + Ff}{Sum All} \quad (10)$$

III. 결과

예비 실험으로 4개의 클래스로 구성할 수 있는 계층적 분류모델의 모든 경우에 대하여 AUC의 결과를 표6에 비교하였다. Scheme 1번은 본 연구에서 제안한 계층적 분류모델이며 2번과 3번의 결과와 비교하였다. 2번 모델에서 (N, V) 그룹과 (S, F) 그룹을 분류할 때는 결과가 0.7133으로 다른 모델에 비해서 현저히 낮은 값을 볼 수 있었다. 3번의 결과는 1번의 결과와 비교했을 때 미소한 차이를 보였지만 두번째 단계의 분류결과를 살펴봤을 때 1번의 결과보다 낮은 결과를 보였다.

다음으로 전통적인 SVM학습법의 비교실험을 하기 전, 영역 지식을 적용하여 N과 S를 분류하는데 RR간격 정보만이 유용하다는 본 연구의 판단을 검증하기 위한 실험을 진행하였다. RR간격 정보만 사용한 단계와 형태학적인 특징점만을 사용한 단계, 두 종류의 특징점을 모두 사용하였을 때의 결과들을 표 7에 비교하였다. 결과를 보면 알 수 있듯이 RR간격 정보만을 사용했을 때 AUC값이 가장 높았다. N과 S를 분류할 때는 간격과 관계된 특징점만을 사용하는 것이 효과적인 것을 알 수 있었다.

다음은 전통적인 SVM학습법으로 다중 분류를 수행하여 실험한 결과를 정리하였다. 표8은 전통적인 SVM학습법을 이용하여

표 7. N과 S를 분류하는 단계의 특징점별 곡선아래면적값 비교.

Table 7. Performance of each feature set in the N vs. S stage

Feature set	AUC
Interval	0.901
Morphology	0.417
Interval & Morphology	0.804

표 8. 전통적인 방법의 SVM학습법을 적용한 random cross-validation 결과
Table 8. Performance of conventional SVM learning by the random cross-validation

	Original label	Predicted label				민감도(%)
		N	S	V	F	
	N	46332(41018) ¹	0(307)	33(1603)	0(1310)	99.928(92.721)
	S	199(1467)	573(339)	31(26)	0(2)	71.357(18.484)
	V	109(239)	0(44)	3798(2926)	9(12)	96.986(90.841)
	F	89(281)	0(1)	18(105)	272(1)	71.767(0.257)
평균민감도(%)						85.009(50.575)
예측정확률(%)						99.051(89.136)

¹DS1(DS2) : 괄호 밖의 숫자는 DS1을 이용한 cross-validation결과, 괄호 안의 숫자는 DS2를 이용한 테스트 결과임.

DS1에 RCV를 적용한 결과와 DS2를 이용하여 테스트한 결과를 괄호 안에 함께 정리한 표이다. SVM학습을 위해서 비선형 커널인 RBF커널을 사용하였다. RCV의 결과를 보면cross-validation결과와 비교해봤을 때 테스트결과가 좋지 않다는 사실을 알 수 있다. Cross-validation에서의 평균민감도는 85.0%였지만 테스트결과에서는 50.6%로 수치가 현격히 낮아졌다.

다음은 전통적인 SVM 학습법에 DS1을 이용하여 CCV를 적용한 결과와 역시 DS2를 이용하여 테스트한 결과를 함께 표8에 정리하였다. CCV의 결과 중 cross-validation결과를 살펴보면 평균민감도가 40.3%로 RCV의 결과와 비교했을 때 현격하게 낮은 결과이다. 그러나, 테스트결과를 보면 RCV와 비교했을 때 52.1%로 더 높은 수치를 보였다. 뿐만 아니라 DS2를 이용한 테스트 결과를 보면 평균민감도는 약 52.1%, 예측정확률은 약 88.3%로써 DS1을 이용한cross-validation결과와 큰 변화가 없음을 알 수 있었다.

다음은 계층구조적 분류모델을 적용한 CCV결과를 표 10에 정리하였다. 계층구조적 분류모델은 본문에서도 언급했지만 다중분류를 2개의 분류단계를 가지는 3개의 이진분류로 재구성하였다. 그러므로 각 이진분류마다 cross-validation결과를 도출해야 하기 때문에 표8, 표9과 같이 결정 매트릭스로 결과를 정리하기가 어렵

다. 이진분류이기 때문에 receiver operating characteristic(ROC) 커브 분석에 의한 커브아래면적(AUC) 값으로 결과를 정리하였다. 각 이진분류에서 AUC의 값이 가장 높은 분류모델을 선정하였으며, 결과를 살펴보면 첫 번째 단계인 NS/VF에서 AUC값은 약 0.95의 결과를 보였고, 두 번째 단계인 N/S, V/F에서는 각각 0.91, 0.76의 결과를 보였다.

위의 실험에서 선정된 분류모델의 ROC커브 분석을 통하여 문턱값을 조절할 수 있으므로 문턱값에 따른 3가지의 결과들을 표10에 함께 정리하였다. 그림4는 NS와 VF 를 분류하는 첫 번째 단계에서 cross-validation을 수행하여 도출된 결과값을 이용하여 그린 ROC커브이다. 그림4에 도시한 것과 같이 민감도가 90%인 지점의 문턱값과 특이도가 90%인 지점의 문턱값을 구하여 문턱값의 변화에 따른 결과를 정리하였다. 그리고 민감도와 특이도가 모두 100%인 지점에서 ROC곡선과 가장 가까운 곳을 closest point로 정하고 closest point의 문턱값을 적용한 결과도 정리하였다.

각각의 cross-validation결과로부터 민감도와 특이도의 평균값을 구해 가장 높은 결과를 보이는 문턱값을 이용하여 DS2를 적용한 계층구조적 분류모델의 테스트결과를 표11에 정리하였다. 또한 기존의 연구내용과의 비교를 위해Chazal[1]등의 연구결과를

표 9. 전통적인 방법의 SVM학습법을 적용한 constrained cross-validation 결과
Table 9. Performance of conventional SVM learning by the constrained cross-validation

	Original label	Predicted label				민감도(%)
		N	S	V	F	
	N	44276(40531) ¹	0(315)	2089(1842)	0(1550)	95.494(91.620)
	S	666(1410)	0(400)	137(21)	0(3)	0.000(21.810)
	V	1290(237)	53(50)	2573(2918)	0(16)	65.704(90.593)
	F	321(249)	1(1)	57(121)	0(17)	0.000(4.381)
평균민감도(%)						40.299(52.101)
예측정확률(%)						91.034(88.292)

¹DS1(DS2) : 괄호 밖의 숫자는 DS1을 이용한 cross-validation결과, 괄호 안의 숫자는 DS2를 이용한 테스트 결과임.

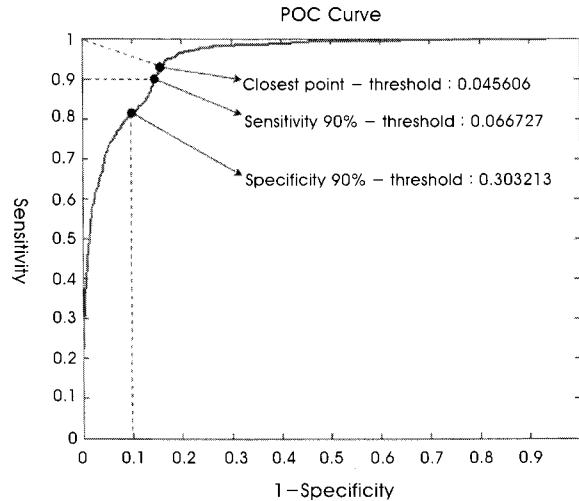


그림 4. NS와 VF 모델링을 통해 도출한 ROC 커브. 곡선 위의 3점은 각각 민감도 90%, 특이도 90%, closest point

Fig. 4. Receiver operating characteristic (ROC) curve of the NS and VF classification stage. The 3 black points are sensitivity 90%, specificity 90% and closest point, respectively.

함께 정리하였다. Chazal 등의 연구결과와 비교했을 때 N과 V의 민감도가 각각 91.6%, 93.7%로 더 높은 결과를 보였으며 S와 F의 민감도는 각각 70.9%, 4.4%로 더 낮은 결과를 보였다. 평균민감

도는 65.2%로 낮은 결과를 보였으나 예측정확률은 90.3%로 높은 결과를 보였다.

최종 성능 평가에 더하여 F 클래스를 제외하고 N, S, V의 클레

표 10. DS1에 계층구조적 분류모델을 적용한 후 곡선아래 면적값

Table 10. Performance of hierarchical classification using DS1

	Sensitivity 90% ¹		Specificity 90% ²		Closest Point		
	Sen(%)	Spec(%)	Sen(%)	Spec(%)	Sen(%)	Spec(%)	Spec(%)
Stage 1 NS/VF	90.000	85.197	82.133	90.000	92.872	84.173	0.946
Stage 2 NS	90.000	85.302	65.984	90.000	90.206	84.765	0.905
Stage 2 V/F	90.000	50.114	29.076	90.000	79.070	66.273	0.756

¹Sensitivity 90% : ROC 커브에서 민감도가 90% 인 지점의 probability를 문턱값으로 설정했을 때의 민감도와 특이도

²Specificity 90% : ROC 커브에서 특이도가 90%인 지점의 probability를 문턱값으로 설정했을 때의 민감도와 특이도

표 11. DS2 를 이용한 계층구조적 분류모델의 최종 성능 평가

Table 11. Performance of hierarchical classification using DS2

	Original label	Predicted label				민감도(%)	기존연구(Chazal et al.)
		N	S	V	F		
N		40531	2836	583	288	91.620	87.056
S		206	1301	251	76	70.938	75.980
V		137	50	3018	16	93.698	80.308
F		249	1	121	17	4.381	89.433
평균민감도(%)						65.159	83.194
예측정확률(%)						90.310	86.239

최종 성능 평가에 더하여 F 클래스를 제외하고 N, S, V의 클래스만을 가지고 계층 구조적 분류모델을 세우기 위해 AUC 값을 구해서 표 12에 정리하였다.

표 12. F비트를 제외한 클래스의 계층구조적분류모델의 곡선아래 면적값
 Table 12. Performance of hierarchical classification with N, S, V

Scheme No.	Stage 1	AUC	Stage 2	AUC
1	N vs SV	0.944	S vs. V	0.889
2	S vs NV	0.786	N vs. V	0.960
3	V vs NS	0.957	N vs. S	0.901

스만을 가지고 계층 구조적 분류모델을 세워 AUC값을 구해서 표 12에 정리하였다.

Scheme 3번의 결과가 0.957로 가장 높게 나왔으며 2번째 단계에서도 0.901로 3번의 결과가 가장 높았다. 두번째 단계에서는(N, V)가 가장 높았지만 첫번째 단계에서 0.786으로 상대적으로 낮은 결과를 보였다.

IV. 토 의

A. Validation 방법론 비교

전통적인 방법의 SVM다중분류의 결과 중, RCV의 결과를 보면 cross-validation결과와 테스트 결과를 비교했을 때 cross-validation의 평균민감도는 약 89.0%였는데 비해, 테스트를 했을 때 평균민감도는 약 50.6%로 현격한 차이를 나타내었다. 반면, 데이터를 레코드 별로 추출 하여 cross-validation을 수행하는 CCV의 결과를 보면 예측정확률이 약 91.0% 였고, 평균민감도는 약 40.3%로써 비교적 낮은 결과를 나타내었다. 하지만 테스트 결과의 평균민감도는 52.1%로 cross-validation결과와 비교했을 때 결과의 차이가 크지 않았던 것을 알 수 있었다. 또한, RCV의 테스트결과와 비교했을 때 평균민감도가 더 높았음을 알 수 있었다.

이러한 결과를 살펴봤을 때 DS1으로 RCV를 수행한 결과는 과대평가가 된 결과라는 것을 알 수 있었다. 따라서 데이터를 레코드와 상관없이 무작위로 추출 하는 RCV는 본 연구에서와 같은 데이터에서는 적합하지 않다는 사실을 알려준다. 기존의 연구에서는 데이터의 클래스 분포나 이러한 validation에 대한 명확한 설명이 포함되어 있지 않는 경우가 있었는데 validation의 방법도 데이터에 따라 반드시 고려해 주어야 할 문제라는 것을 알 수 있었다. 또한, 본 연구에서 적용한 CCV는 RCV보다 적합한 validation방법이라는 것을 알 수 있었다.

B. 영역 지식을 적용한 계층구조적 분류 모델

본 연구에서는 N과 S를 분류하는 단계에서 영역 지식을 적용하여 RR간격 특징점만이 분류모델에 적합한 특징점이라고 판단하였다. 예비 실험으로 진행한 결과를 살펴보면 RR간격 특징점만을 적용하였을 때 AUC가 약 0.9190으로 가장 높았다. 그리고 두번째로 실시한 예비실험에서는 AUC가 첫번째 단계(NS vs. VF)에서 0.9486, 두번째 단계(N vs. S), (V vs. F)에서는 각각 0.9012,

0.7658으로 가장 높은 값을 보였다.

이 결과는 영역 지식을 적용하여 효과적인 특징점만을 사용하고, 효과적인 분류 모델을 사용하고자 했던 본 연구의 판단을 뒷받침해주는 결과였다. 따라서 영역 지식을 활용한 특징점 선택 및 모델선정으로 인해 불필요한 계산량을 줄여주고 분류모델의 성능을 저하시키는 요인을 효과적으로 방지할 수 있었음을 알 수 있었다. 또한, 기존의 계층구조적 학습법은 공식처럼 모든 분류모델에 대해서 계층적인 구조를 이루는 학습법이었는데 이는 계산량의 기하급수적인 증가를 초래한다. 본 연구에서 사용된 영역 지식을 이용한 계층구조적 분류모델은 이러한 단점들을 보완할 수 있는 가능성을 제시한다.

C. 전통적인 방법의 SVM다중분류와 계층구조적 분류 비교

본 연구에서와 같이 불균형적인 데이터 분포를 갖고 있는 다중 클래스의 분류 문제에 있어서, SVM을 이용한 전통적인 다중분류 기법은 적용하기가 어렵다는 것을 알 수 있었다. 본 연구에서 제안한 계층구조적 분류모델의 결과들을 살펴보면 전통적인 다중분류와 비교하여 편중된 결과가 많이 개선된 것을 볼 수 있었다. 최종적으로 전통적인 다중분류 기법과 본 연구에서 제안한 계층구조적 분류모델의 평균민감도를 비교했을 때 약 40.3% 였던 평균민감도가 약 65.2%까지 개선된 것을 볼 수 있었다. 클래스 별로 민감도를 살펴보면 F비트를 제외한 N, S, V 에서 비교적 높은 수치를 보여준 것을 볼 수 있었다. 전통적인 방법의 SVM 다중분류는 분류 모델(classifier)의 수가 클래스의 개수에 비례해서 수가 크게 늘어나므로 민감도와 특이도 조절, 그리고 ROC분석 등에 있어서 어려움이 있다. 계층구조적 분류모델은 본 연구에서 사용되었던 MIT-BIH 부정맥 데이터의 정상 비트가 비정상 비트보다 압도적으로 수가 많았던 점에서, 비트의 비율을 맞추기보다는 편중된 비율 자체로부터 문제를 해결하기 위해 고안되었다. 기존의 SVM 다중 분류 학습법에서 다루기 힘들었던 민감도와 특이도의 조절이 가능하다면 굳이 데이터의 비율을 임의로 조절하지 않더라도 충분히 괄목할 만한 성과를 낼 수 있을 것이라 판단되었다.

D. 기존 연구와 계층구조적 분류모델의 비교

Chazal 등의 연구결과와 비교해서 정리된 결과를 살펴보면 N과 V에서는 각각 91.6%, 93.7%로 계층구조적 분류모델이 더 높은 민감도를 보였으나 S는 약 5% 정도 낮은 약 70.9% 민감도를 보였




그림 5. 전형적인 V비트와 F비트(왼쪽이 F, 오른쪽이 V)
Fig. 5. Sample signals of ventricular ectopic beat(VEB) and Fusion beat (The left one is the F beat, and the right is VEB)




그림 6. 전형적인 N비트와 F비트(왼쪽이 N, 오른쪽이 F)
Fig. 6. Sample signals of normal beat and Fusion beat(The left one is the N beat, Right is F beat)

다. 특히 F비트의 성능이 약4.4%로 다른 비트의 검출 성능보다 낮게 도출되었다. 평균민감도를 살펴보면 Chazal 등의 연구결과에서의 평균민감도는 약83.2%이며 계층구조적 분류모델의 결과에서는 약65.2%로 더 낮은 결과를 보였다.

F비트의 성능이 낮은 이유는 Chazal 등의 연구와 비교했을 때 특징점의 부재가 가장 큰 원인이었다고 판단된다. 최종 결정 매트릭스를 살펴보면 F비트가 S비트라고 분류된 경우가 가장 많은데 이것은 첫 번째 단계에서 이미 NS비트로 상당수 분류되었음을 의미한다. 그 후 S비트로 많은 양이 분리되었는데 이는 본 연구에서 사용된 특징점으로는 F비트를 결정하는데 있어서 정보가 상당히 부족했던 것이라고 판단된다. 그림5와 6에서 F비트의 파형을 살펴보니 V비트 혹은 N비트와 육안으로도 구분하기 힘들 정도로 흡사한 비트가 상당수 있었다.

E. 분류성능에 대한 고찰

F비트로 인해 Chazal의 연구결과와 비교했을 때 평균민감도가 더 낮게 나왔다. Chazal의 연구와 본 연구의 가장 큰 차이점은 Chazal의 연구에서 사용된 특징점을 본 연구에서는 모두 사용하지 않았다는 점이다.

그러나, MIT-BIH의 주석파일을 살펴보면 F비트는 전체 데이터 중 0.8%밖에 차지하지 않으며, 최종적으로 Bigeminy, Trigeminy와 같은 부정맥을 진단하는데 있어서, V나 S비트보다는 상대적으로 덜 중요한 비트이다. 또한, 본 연구의 목표는 특징점보다는 전통적인 SVM 학습법의 약점을 극복하기 위한 계층구조적 분류모델의 타당성을 입증하는 것이다. 이러한 취지에서 F비트를 제외한 평균민감도를 계산했을 때 적은 특징점을 사용했음에도 본 연구에서 제안한 계층구조적 분류모델이 결과적으로 성능향상을

가져올 수 있는 가능성을 가지고 있다고 판단된다.

F. 비트 검출(Beat detection)

실질적인 부정맥 조기진단 알고리즘은 심전도 데이터를 이용하여 비트 검출을 하는 단계를 통해서 각 비트의 R-peak 및 비트의 특징점을 구하고, 이 정보를 바탕으로 부정맥을 구성하는 이상 비트의 유무를 판단하게 된다. 비트 검출과 관련된 연구는 과거부터 전통적으로 상당히 많은 연구가 진행 되었다. 비트 검출이 중요한 이유는 비트 검출 단계에서 비트가 제대로 검출되지 않으면 이상 비트를 분류하는 단계에서 잘못된 결과가 도출될 가능성이 매우 높아지기 때문이다. 그러나 본 연구에서 초점을 맞추고 있는 부분은 분류단계에서의 성능 향상이기 때문에 비트 검출은 또 다른 연구 분야라고 판단하였다. MIT-BIH에서 제공하는 주석 파일은 모든 레코드에 있는 모든 비트에 대해서 QRS 군 중 R파의 극점 혹은 S파의 극점의 시간위치에 비트의 타입을 정의해 놓은 파일이다. 그러므로 본 연구에서는 이 파일의 기준점을 R극점 정보로 사용하였다.

V. 결론

본 연구에서는 부정맥 조기진단 알고리즘의 분류단계의 성능 향상을 위해서 영역 지식 바탕의 계층구조적 분류모델을 제안하였다. 결과를 바탕으로 전통적인 방법의 다중분류 보다 본 연구에서 제안한 계층구조적 분류모델이 더 좋은 성능을 보임을 확인할 수 있었다. 계층구조적 분류모델은 ROC해석을 통한 민감도 조절과 특이도 조절을 하기가 쉽다는 장점과 영역 지식을 활용한 효율적인 모델링을 통해서, 적은 계산량으로 효율적인 결과를 도출할 수 있다는 장점을 가진다. 기존에 있었던 양성데이터와 음성데이터의

비율차이나, 민감도와 특이도를 조절하기 난해한, 그리고 많은 계산량 같은 단점들을 보완하는데도 효과적이라고 할 수 있다. 또한, 심전도 이상비트 분류에 있어서 영역 지식을 고려하여 계층구조적으로 분류법을 적용한 것은 최초의 사례라는데 의의가 있다고 할 수 있다. 향후 위와 같은 문제점들을 보완하는데 도움이 될 수 있는 연구라고 판단되며 다른 연구와 연계하여 부정맥 자동진단 알고리즘과 관련된 다양한 연구를 진행할 수 있을 것이라고 판단된다.

차후의 연구에서는 본 연구에서 부족했던 특징점에 초점을 맞추는 연구가 필요하다. 본 연구에서는 기술적인 문제인 특징점을 구하는 것 보다는 기존에 존재했던 SVM 학습법의 약점을 극복하기 위한 방법에 초점을 맞추었다. F비트의 낮은 민감도는 Chazal 등의 연구결과와 비교했을 때 F비트를 분류하는데 필요한 특징점의 부족함에서 기인했다고 판단된다. 특징점은 결국 결과에 가장 큰 영향을 미치는 요소라고 할 수 있다. 특히 영역 지식을 바탕으로 연관성이 높은 가능성이 큰 특징점들을 연구하고 적용하면 분명히 좋은 성능의 부정맥 자동진단 시스템을 구축할 수 있으리라고 기대된다. 그리고 비트 검출 자체가 결과에 영향을 많이 미칠 수 있으므로, 향후에는 비트 검출에 대한 연구를 통해 전체적인 시스템의 향상을 시킬 것이다.

또한 특징점의 단순한 추가뿐 아니라 다른 접근으로 특징점을 다루는 연구가 필요하다. 특징점의 차원(dimension)을 주성분분석법(principal component analysis) 등의 특징점 감소(feature reduction) 기법을 적용하여 계산시간의 절감과 불필요한 정보의 감소를 시켜줄 수 있는 접근법이 있다. 또 다른 접근법으로는 특징점 선택(feature selection)같은 기법을 적용하여 가장 좋은 결과를 얻을 수 있는 효과적인 특징점이 무엇인지 가려내는 접근법이 있다. 앞으로는 이런 연구를 특징점 연구와 함께 병행하여 계층구조적 분류모델이 가지는 강점을 더욱 살리는 연구가 필요하다.

참고문헌

- [1] Philip de Chazal, Maria O'Dwyer, and Richard B. Reilly, "Automatic Classification of Heartbeats Using ECG Morphology and Heartbeat Interval Features," *IEEE Trans. Biomed. Eng.*, vol. 51, no. 7, 1196-1206, July 2004.
- [2] L. Senhadji, G. Carrault, J.J. Bellanger, and G. Passariello, "Comparing wavelet transforms for recognizing cardiac patterns," *IEEE Eng. Med. Biol. Mag.*, vol. 14, pp. 167-173, Mar.-Apr. 1995.
- [3] T. H. Yeap, F. Johnson, and M. Rachniowski, "ECG beat classification by a neural network," in *Proc. Annu. Int. Conf. IEEE Engineering Medicine and Biology Soc.*, pp. 1457-1458, 1990.
- [4] Y.H.Hu, W.J. Tompkins, J.L. Urrusti, and V.X. Afonso, "Applications of artificial neural networks for ECG signal detection and classification," *J. Electrocardiol.*, vol. 26, pp. 66-73, 1993.
- [5] S. Osowski and T. L. Linh, "ECG beat recognition using fuzzy hybrid neural network," *IEEE Trans. Biomed. Eng.*, vol. 48, pp. 1265-1271, Nov. 2001.
- [6] S. Osowski, "Support vector machine-based expert system for reliable heartbeat recognition" *IEEE Trans. Biomed. Eng.*, vol. 51, no. 4, pp. 582-589, April 2004.
- [7] Y. H. Hu, S. Palreddy, and W. J. Tompkins, "A patient-adaptable ECG beat classifier using a mixture of experts approach," *IEEE Trans. Biomed. Eng.*, vol. 44, pp. 891-900, Sept. 1997.
- [8] M. Lagerholm, C. Peterson, G. Braccini, L. Edenbrandt, and L. Sornmo, "Clustering ECG complexes using hermite functions and self-organizing maps," *IEEE Trans. Biomed. Eng.*, vol. 47, pp. 838-848, July 2000.
- [9] Mehmet Engin and Serdar Demirag, "Fuzzy-Hybrid neural network based ECG beat recognition using three different types of feature sets," *Cardiovascular Eng. An international Journal*, vol. 3, no. 2, pp. 71-80, June 2003.
- [10] Chia-Hung Lin, "Classification enhancible grey relational analysis for cardiac arrhythmias discrimination", *Med Biol Eng Comput.*, vol. 44, pp. 311-320, March 2006.
- [11] Chuang-Chien Chiu, Tong-Hong Lin and Ben-Yi Liau, "Using correlation coefficient in ecg waveform for arrhythmia detection", *Biomed Eng Appl Basis Comm.*, no. 17, pp. 147-152, June 2005.
- [12] I Christov, I Jekova and G Bortolan, "Premature ventricular contraction classification by the Kth nearest-neighbours rule", *Physiol. Meas.* vol. 26, pp. 123-130, January 2005.
- [13] B. H. Cho, J. S. Lee, Y. J. Chee, K. W. Kim, I. Y. Kim, S. I. Kim, "Prediction of diabetic nephropathy from diabetes dataset using feature selection methods and SVM learning," *Kor Society of Medical & Biological Eng.*, vol. 28, pp. 255-262, 2007.
- [14] David Casasent, Yu-Chiang Wang, "A hierarchical classifier using new support vector machines for automatic target recognition", *Neural networks*, vol. 18, pp. 541-548 2005.
- [15] Chih-Chung Chang and Chih-Jen Lin, *LIBSVM: a Library for support vector machines*, June 14, 2007 (National Science Council of Taiwan).
- [16] K. Veropoulos, N. Cristianini, and C. Campbell, *Controlling the sensitivity of support vector machines*, Proceedings of the Int Joint Conf Artif Intell, Stockholm, Sweden, August 1999.
- [17] Mahesh S. Khadtare and J.S. Sahambi, "ECG arrhythmia analysis by multi-category support vector machine," LNCS 3285, pp. 100-107, 2004.
- [18] R. Mark and G. Moody, MIT-BIH Arrhythmia Database 1997[Online]. Available: <http://ecg.mit.edu/dbinfo.html>.
- [19] *Testing and Reporting Performance Results of Cardiac Rhythm and ST Segment Measurement Algorithms Association for the Advancement of Medical Instrumentation*, Arlington, VA, 1998, ANSI-AAMI EC57:1998 (American National Standard).
- [20] Ary L. Goldberger, *Clinical Electrocardiography: A simplified approach*, Mosby Inc., an affiliate of Elsevier Inc., 2006.
- [21] N. Cristianini and J. Shawe-taylor, *An Introduction to support vector machines and other kernel-based learning methods*, Cambridge univ. Press, 2000.
- [22] E. Osuna, R. Freund, and F. Girosi., *Support vector machines: Training and applications*, AI Memo 1602, Massachusetts Institute of Technology, 1997.