

ECG 신호에 기반한 효과적인 알고리즘의 연구

이 현 주¹, 신 동 일, 신 동 규
세종대학교

nedkelly@gce.sejong.ac.kr, dshin@sejong.ac.kr, shindk@sejong.ac.kr

A study on an effective algorithms based on ECG signal

Lee Hyun Ju¹, Shin Dong Il, Shin Dong Kyoo
Sejong University

요 약

심전도는 가장 일반화되어 있는 생체신호의 하나이다. 심전도를 측정하여 심장병의 유무와 여러 질환들을 예측하고 예방할 수 있다. 심전도 신호를 추출 하는 방법에는 여러 방법이 있는데, 본 논문에서 활용한 두 논문은 계층적인 분류로 HOS, HBF, HMH 세 방법으로 실험을 하였고, 적응가변형 윈도우를 이용한 R파 추출을 실행하였다. 두 논문은 공통적으로 MIT-BIH Arrhythmias Database(MIT-BIT 부정맥 데이터베이스)를 데이터로 실험 하였으며, 알고리즘으로는 SVM, Cross-Validation등을 사용하였다. 마지막으로 두 논문의 실험결과를 바탕으로 정확도를 높일 수 있는 효과적인 알고리즘 연구를 제안하였다.

1. 서 론

심전도(electrocardiogram, ECG)신호는 심장활동 시에 나타나는 전기적 신호로써 심장 상태와 질환을 알아볼 수 있는 중요한 자료로 쓰인다[3].

최근에는 심장 질환이 증가함에 따라 심장의 전기적 활동을 나타내는 심전도 자동 진단에 대한 연구와 진단의 정확성을 높이기 위한 알고리즘 개발이 활발히 이루어지고 있다[4]. 심전도 신호에서 부정맥(arrhythmia)은 심전도 형태를 띤 연속된 비정상적 형태로 드물게 발생 할 수 있으며, 이를 찾기 위해 24시간 이상 환자의 심전도를 측정할 수 있는 홀터(holter)를 이용하여 장시간의 심전도데이터를 저장하게 된다. 따라서 이러한 대량의 데이터를 사람이 직접 분석하는 데에는 많은 시간과 비용이 들기 때문에, 환자의 부정맥 진단을 위한 자동화 기술들이 개발되고 있다. 부정맥을 식별하는데 있어서 가장 중요한 단계는 각 심장박동이 어떤 클래스(class)에 속하는지를 정확히 분류(classification)하는 것이며, 그 결과 중 비정상적인 심장박동이 연속적으로 나타나는 특정 패턴에 따라 다양한 부정맥 리듬으로 진단하게 된다[5].

심전도 파형은 일반적으로 P, QRS, T파로 구분되고, 이들 파형 중 QRS-complex는 심장박동이 건강한 리듬 비트인지 아니면 부정맥으로 인한 비정상 리듬 비트인지를 결정하고 해석하는데 가장 중요하게 쓰이는 부분이다. 심전도의 심장박동클래스 분류를 위한 심전도 파형 특징점 추출방법에는 심전도 형태학적 특징추출, 심장박동

간격의 특징추출, 그리고 주파수 관련 특징추출 등 여러 가지가 있다. 여기서, 전형적인 심전도 특징점 추출방법은 기본적으로 P, QRS, T파의 진폭과 위치 정보 그리고 심장박동의 간격 등의 특징들을 추출하여 특징점으로 사용한다. 이 방법은 특징점을 추출함에 있어 P, QRS, T파가 정상적으로 추출되었을 때에는 가능하지만, 종종 P파나 T파의 추출을 정확하게 하지 못한 경우에는 특징점 추출에 문제가 있을 수 있고, 결국 정확한 분류에 악영향을 줄 수 있다[6].

따라서 본 논문은 기존의 심전도 데이터 추출에 관련된 두 논문을 비교 분석하여 논문들의 실험결과에 따른 효과적인 심전도 데이터 분석 및 정확도를 높이는 알고리즘을 제안하는데 초점을 두고 있다.

2. 관련연구

2.1 데이터수집

두 논문은 Physionet의 MIT-BIH 부정맥 데이터베이스를 가지고 실험하였다. MIT-BIH 부정맥 데이터베이스는 48명 환자의 두 채널 심전도 데이터로써, 이들 기록(recording)은 환자 별로 30분 정도의 데이터를 가지고 있으며 총 234개의 레코드로 구성되어 있다. 이 기록들 중 23개 기록은 입원환자(약 60%)와 외래환자(약 40%) 4,000명으로부터 임의로 선택된 것이며, 나머지 25개 기록은 위 환자 중 임상적으로 중요한 부정맥이 있는 환자 기록이 선택된 것이다[7]. MIT-BIH 부정맥 데이터베이스는 0.1~100Hz band-pass 필터링한 신호를 11bit와 360Hz

본 연구는 문화체육관광부 및 한국 콘텐츠 진흥원의 2009년도 문화콘텐츠산업기술지원사업의 연구결과로 수행되었음

로 샘플링 한 것이다. 심장박동은 15개 타입으로 나뉘어 있고, 각 기록 안에는 심장박동에 따른 타입과 기준점(fiducial point)의 시간에 대한 정보가 주석 안에 포함되어 있다[7]. 논문들은 계층적 심전도 비트 분류[1]를 하기 위해서 MIT-BIH 데이터를 사용하였고, PVC분류를 위해서 P파를 추출하였다[2]. MIT-BIH 데이터는 48개의 기록들로 구성되어 있지만, Association for the Advancement of Medical Instrumentation(AAMI) 권고에 따라 48개 기록들 중 심장박동 조절기에 의한 데이터가 포함된 4개 기록은 삭제하여 44개 기록을 사용하였고 [1], 이에 따라 15개 MIT-BIH 심장박동 타입을 5개 심장박동 클래스로 합쳐 실험하였다[8].

차단하는 유한 임펄스 필터(finite impulse response, FIR)를 사용하고 있다[9]. 그러나 [1]에서는 baseline wandering을 제거하기 위해 메디안 필터를 두 번 사용하였다. 먼저 P파와 ORS-Complex를 제거하기 위해 200ms를 사용하고, 다음은 T파 제거를 위해 600ms의 필터를 사용했다. 그러므로 [1]은 직접적인 실험에는 baseline를 제거한 신호만으로 실험을 하였다. R파 추출에 중점을 둔 [2]의 경우는 먼저 QRS파를 추출하기 위해 Pan & Tompkins 알고리즘을 보완하여 사용하였고, R파 추출과 신호의 정확도를 위해 이동평균 간격을 기존 150ms에서 80ms로 수정하였다[2].

R파 추출 전처리과정[2]에서는 차단 주파수가 20Hz인 저역통과필터, 5Hz인 고역 통과 필터를 통하여 잡음을 제거한 후 baseline 변화의 안정화와 R파를 강조하기 위한 5-point 미분 방법을 사용하였다.

3. 실험 방법

3.1 데이터 추출방법

고차통계(HOS), HBF(Hermite basis function), 고차 통계의 Hermite 모델(HMH)는 박관수가 [1]에서 사용한 추출 방법이다. 세 방법은 신호처리 분야에서 사용되며 고차통계는 큐물런트(cumulants)로 표현된다. 큐물런트는 큐물런트 생성 함수인 테일러 전개에 계수를 말하며, 선형 또는 비선형 조합들을 통계적 모멘트로 표현하기도 한다[6]. [1]에서는 2,3,4차 큐물런트를 사용하였고, 평균이 0인 통계적 프로세스일 때, $x(t)$ 의 2차, 3차 큐물런트는 이와 대응되는 2차, 3차 통계적 모멘트로 나타낼 수 있다[6].

$$C_{2x}(\tau_1) = m_{2x}(\tau_1)$$

$$C_{3x}(\tau_1, \tau_2) = m_{3x}(\tau_1, \tau_2) \tag{1}$$

$$C_{4x}(\tau_1, \tau_2, \tau_3) = m_{4x}(\tau_1, \tau_2, \tau_3) - m_{2x}(\tau_1) m_{2x}(\tau_3 - \tau_2) - m_{2x}(\tau_2) m_{2x}(\tau_3 - \tau_1) - m_{2x}(\tau_3) m_{2x}(\tau_2 - \tau_1) \tag{2}$$

위의 식은 고차통계[1]에서 사용한 2, 3, 4,차의 큐물런트 식이다. c_{nx} 와 m_{nx} 는 $x(t)$ 의 n 차 cumulants와 n 차 통계적 모멘트를 나타내고, 이때 τ_1, τ_2 and τ_3 는 시간 간격(time lags)이다[1]. 2차 cumulants는 신호의 자기 상관을 나타내고, 3차와 4차 cumulants는 왜도(skewness)와 첨도(kurtosis)를 나타낸다[1]. HBF은 Fourier 시리즈와 유사하게 여러 개의 waveform의 합으로 새로운 신호를 생성할 수 있고, 따라서 이를 이용하여 심전도의 QRS-Complex를 근사치화 하는데 사용할 수 있다[10]. HBF 전개에 계수들은 심전도 비트의 QRS-Complex 커브를 대표하는 특징점 들이 된다[1].

AAMI heartbeat class	Description	MIT-BIT heartbeat types
N	Any heartbeat not in the S, V, F or Q classes	normal beat (NOR) left bundle branch block beat (LBBB) right bundle branch block beat (RBBB) atrial escape beat (AE) nodal (junctional) escape beat (NE)
S	Supraventricular ectopic beat	atrial premature beat (AP) aberrated atrial premature beat (aAP) nodal (junctional) premature beat (NP) supraventricular premature beat (SP)
V	Ventricular ectopic beat	premature ventricular contraction (PVC) ventricular escape beat (VE)
F	Fusion beat	fusion of ventricular and normal beat (fVN)
Q	Unknown Beat	paced beat (P)
		fusion of paced and normal beat (fPN) unclassifiable beat (U)

표 1. Merging the MIT-BIH heartbeat types to the AAMI heartbeat classes

표 1은 박관수가 논문[1]에서 사용한 MIT-BIH 데이터의 심장박동 타입을 옮겨 놓은 것이다.

2.2 전처리 과정

심전도 P, Q, R, S, T 데이터를 추출하는 과정에서 먼저 필터를 사용하여 잡음을 제거 하는 단계가 있다. 심전도 잡음제거는 일반적으로 0.5Hz 이하의 주파수를

$$x(t) = \sum_{n=0}^{N-1} C_n \Phi_n(t, \sigma) \quad (3)$$

박관수[1]가 제안한 식(3)은 c_n 은 전개 계수이고 σ 는 width 매개변수이며, $\Phi(t, \sigma)$ 는 n 차의 HBF이다. 마지막으로 HMH는 위의 두 식을 조합한 방법으로 HOS를 통해 재해석된 심전도 심장박동의 2차, 3차, 4차 cumulants에 HBF를 적용함으로써, HOS에서 나온 특징점의 수를 줄이는 동시에 잡음을 제거한다[1]. 먼저, QRS-Complex의 $x(t)$ 에 HOS를 적용하여 2차, 3차, 4차 큐물런트를 구하고, 각각의 큐물런트 파형에 20차 Hermite 다항식을 적용하여 나온 계수를 특징 점으로 사용한다[1].

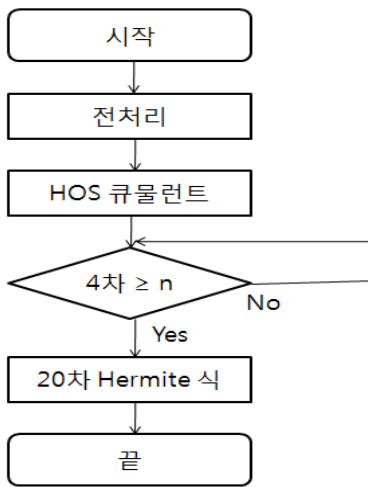


그림 1. HMH 모델

다른 추출방법으로는 적응가변형 윈도우가 있다. 적응가변형 윈도우는 윈도우에 입력되어 들어오는 신호 간격의 변화에 따라 자동적으로 간격이 변화되고, 신호가 윈도우의 내에서 적응형 가변 문턱치를 초과할 때 최고점을 추출하여 R파를 결정하는 방법이다[2]. 전 처리된 신호에서 초기 R파를 추출하고, 추출된 R파 진폭의 30%를 문턱 값으로 결정한 후에 추출된 6개의 R파의 평균값을 가지고 가변문턱전위를 설정한다[2]. 또한 추출된 6개의 R파를 통하여 R-R간격을 계산하고, 5개 R-R간격 평균의 50%로 윈도우 간격으로 결정하였다[2].

3.2 실험 및 결과

데이터를 DS1과 DS2 두 집단으로 분류하여 실험한 [1]의 경우는 MIT-BIH 부정맥 데이터베이스를 각각 22개로 한 집단에 11개씩 부여한 11-fold cross validation을 하여 성능 평가를 하는 recording-based cross validation을 진행하였다. 이 방법을 선택한 이유는 한꺼번에 beat-based cross validation을 하게 되면 데이터가 중복될 확률이 높기 때문이다. 계층적 분류에서는 DS1을 이용하여 전형적인 분류와 계층적 분류에 따른 성능평가 비교는 SVM(Support Vector Machine)을 사용하였다. SVM은 교사학습을 통한 분류 알고리즘의 한 종류이며, 인공지능의 한 분야로 Artificial Neural Networks,

Bayesian Networks, K-Means등의 학습 알고리즘의 한 종류로써 식별 알고리즘으로 많이 사용된다[11]. 따라서 [1]에서는 학습 시 선형 커널과 비선형 커널을 이용하여 나온 결과를 비교하였다. SVM은 양성과 음성을 판단해 주며 테스트 데이터에서는 0~1사이의 확률 값으로 나온다. 그리고 전형적인 분류에서는 확률 값이 0.5 이상이면 양성 데이터로 판단하고, 미만이면 음성 데이터로 판단한다. 밑의 표 2는 [1]의 DS2로 실험한 계층적 분류와 멀티 클래스 분류의 결과이며, 정확률(accuracy), 각 클래스의 민감도(sensitivity), 양성예측도(positive predictivity) 및 평균민감도(mean of sensitivity)를 구하여, 평균민감도가 가장 좋은 것을 선택하였다.

Parameter	Multi	HOS+	HBF+	HMH+
N Sensitivity	99.65	81.23	86.25	82.98
S Sensitivity	0.00	57.65	82.63	75.23
V Sensitivity	84.48	83.11	80.88	84.17
F Sensitivity	0.52	79.90	54.90	82.47
Accuracy	94.21	80.47	85.56	82.80
Mean of Sensitivity	46.16	75.47	76.16	81.21
+P" of S	0.00	21.50	24.78	24.12
+P" of V	72.37	46.11	89.09	84.69

(Multi: 전형적인 다중클래스, HOS: 고차통계, HBF: Hermite basis function, HMH: 고차통계의 Hermite 모델, +P: 양성 예측도[1])

표 2. DS2로 실험한 계층적 분류와 멀티 클래스 분류

민감도, 특이도 그리고 정확도는 아래의 식으로 계산할 수 있다.

$$\text{민감도(sensitivity)} = \frac{TN}{TN + FP} \quad (4)$$

$$\text{특이도(specificity)} = \frac{TP}{TP + FN} \quad (5)$$

$$\text{정확도(Accuracy)} = \frac{TP+TN}{TP+TN+FP+FN} \quad (6)$$

위의 식에서 FN(False Negative)는 거짓 부정으로 분류 모델에 의해 올바르게 예측된 긍정적 사례의 수에 해당하고, FP(False Positive)는 참 부정으로 분류모델에 의해 긍정적으로 잘못 예측된 부정적 사례의 수에 해당한다. 또한 TN(True Negative)는 참 부정으로 분류모델에 의해 올바르게 예측된 부정적 사례의 수에 해당하고, TP(True Positive)는 참 긍정으로 분류모델에 의해 올바르게 예측된 긍정적 사례의 수에 해당한다[12].

R파를 추출한 [2]에서도 위의 사례가 사용되는데, 여기서는 먼저 최적화된 샘플을 선정하였다. 그리고 기준 샘플을 200, 250, 300과 분류샘플을 100, 125, 150에 대해 알고리즘을 적용한 결과를 가지고 최적샘플이 200

samples/s라는 것을 확인 하였다[2].

$$\text{추출률} = \frac{\text{total bit} - (\text{FP} + \text{FN})}{\text{total bit}} \quad (7)$$

Total beat는 MIT-BIH에 존재하는 R파의 총 개수이며, 총 38개 레코드를 대상으로 한 R파 추출률은 약 99.33%가 나왔고, 100% 추출률은 3개, 97% ~99.99% 추출률은 33개, 그 이하 추출률은 2개로 나타났다[2].

따라서 두 논문의 실험방법을 합쳐서 표현하면 아래와 같은 알고리즘으로 표현된다. 먼저 전처리를 마치고 QRS를 추출하기 위한 계층적 분류를 사용하여 QRS를 추출하고, 다음에 적응가변형 윈도우를 설정하여 R파를 추출한다. 그 후에 데이터세트인 DS1과 DS2를 Cross-Validation을 사용하여 분류실험을 실시하고, SVM으로 양성 과 음성 여부를 분류한다. 마지막으로 민감도, 특이도, 정확도를 계산하고 총 추출률을 계산하면 끝난다.

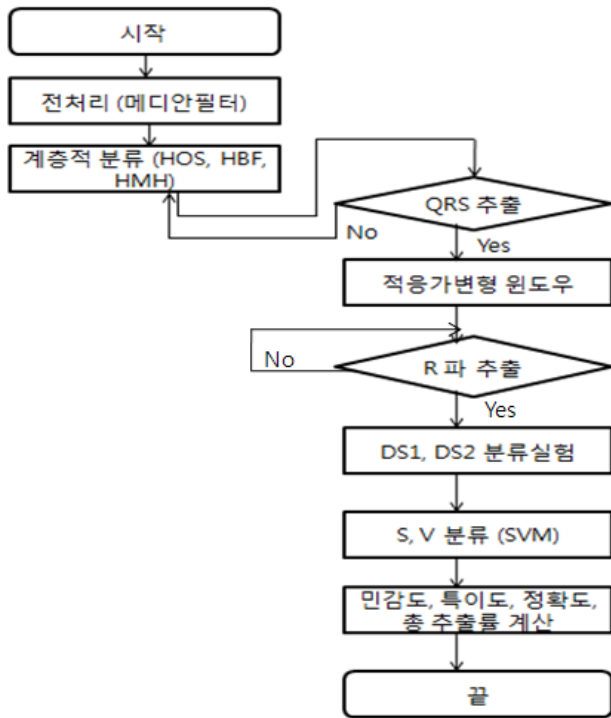


그림 2. Total 실험 알고리즘

두 논문에서는 데이터 추출과 알고리즘을 이용한 분류실험 후의 정확도와 추출률을 계산하는 부분이 주 과제였다. 정확도에 있어서는 [1]의 경우는 정확도에 있어서 HOS는 80.47%, HBF는 85.56%, HMH는 82.80%로 90%이상의 결과를 얻진 못하였고, [2]의 경우는 R파 추출률에 있어서는 99.33%로 100%에 가까운 결과를 얻었다. 그러므로 데이터 추출과 분류에 있어서의 성능을 높여주는 알고리즘을 제안한다.

그림 3은 다른 논문들을 바탕으로 효율성이 높다고 판단된 필터와 알고리즘을 추가하여 구성한 것이다. 먼저 적응제어 필터는 [9]에서 Iravanian 과 Thung(2002)가 FIR(유한 임펄스 필터)를 사용한 경우보다 우수한 잡음제거 성능을 보인다고 하여, 잡음 제거에 효율을 높

여 줄 수 있다고 예측하여 제안하였다. 그리고 데이터의 최적화에 있어서는 ACO알고리즘을 제안한다.

ACO(Ant Colony Optimization)알고리즘은 매우 복잡한 조합이 가능한 최적화 문제에 대하여 페로몬 자취를 통신 수단으로 이용하는 개미의 행동방식에 기초한 알고리즘으로 경험적인 접근을 통한 솔루션을 찾는 최적화 알고리즘 이다[13]. 개미의 최종 이동경로를 통해 이동할 확률을 만들어 내는 방법이므로, 데이터를 분류할 때 데이터가 이동하는 부분에 있어서 오류를 줄여 줄 것이고, 그에 따라 데이터의 정확도를 높여줄 것이라 예측된다.

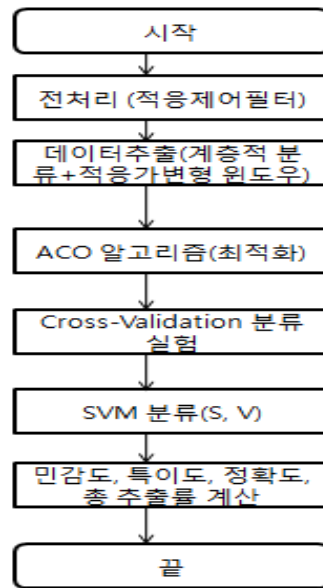


그림 3. 제안 알고리즘

4. 결론 및 향후 연구 방향

계층적 분류를 이용한 [1]의 경우에는 HOS은 통계적인 방법을 이용하여 QRS-Complex를 재해석하였고, HBF은 QRS-complex를 Hermite 다항식의 계수들의 조합으로 파형들을 잘 형상화할 수 있지만, 파형에 남아있는 잡음에 영향을 받을 수 있어 분류성능에 영향을 미칠 수도 있다. HMH의 경우 HOS 추출을 통한 잡음에 민감하게 반응하지 않는 특징점을 추출할 수 있고, 이들 특징점은 HBF를 통해 HOS의 특징을 유지하면서 특징점의 개수를 줄일 수 있다. 따라서 HMH이 위의 두 추출방법들 보다 나은 성능을 가지고 있다. 성능평가 비교를 위해서는 SVM과 Cross-validation(DS1, DS2)을 사용하여 실험하였고, 민감도와 정확도 등을 계산하였다.

적응가변형 윈도우를 사용하여 R파를 추출한 [2]의 경우엔 전처리 과정과 적응가변형 문턱치를 통해 R파를 추출 하였고, 추출의 효율성을 위하여 R-R 간격을 사용한 적응가변형 윈도우를 적용하였다. 성능은 R파는 평균 99.33%의 추출결과를 나타내었다.

따라서 두 논문을 포괄한 Total알고리즘을 구성하여 성능을 높이기 위한 알고리즘을 제안하였다. 제안한 알

고리즘은 전처리 과정에서 잡음을 효율적으로 제거하기 위한 적응제어 필터로 메디안과 FIR 등 다른 필터를 사용했을 때 보다 높은 성능을 보일 것이라 예측된다. 그리고 데이터 분류에 있어서는 ACO 알고리즘을 사용하여 데이터를 최적화 시켜 정확한 데이터를 획득하여 실험 시에 정확도와 민감도 그 외의 실험결과의 성능을 효과적으로 높여 줄 것이라 예측된다.

심전도는 심장의 상태와 관련 질병들을 예측할 수 있는 전기적 신호이다. 따라서 의공학 분야에 있어서 계속적으로 연구되어야 하는 분야이다. 그러므로 앞으로의 연구 방향에 있어서 정확한 데이터 추출이 중요한 과제이다. 잡음을 최소화 하기 위한 필터의 성능 향상과 환자의 데이터를 분류하는데 있어서 보다 정확한 분류를 해 줄 수 있는 알고리즘의 지속적인 연구와 실험이 필요하다.

참고문헌

- [1] Kwan Soo Park, Baek Hwan Cho, Do Hoon Lee, Su Hwa Song, Jong Shill Lee, Young Joon Chee, In Young Kim, and Sun I. Kim, "Hierarchical Classification of ECG Beat Using Higher Order Statistics and Hermite Model", J Kor Soc Med Informatics, 15, 1, page.117-131, 2009.
- [2] 조익성, 권혁승, "PVC 분류를 위한 적응형 문턱치와 윈도우 기반의 R파 검출 알고리즘", 한국 통신학회 논문지, 34, 11, page.1289-1295, 2009.
- [3] Hu YH, Palreddy S and Tompkins W, "A patient adaptable ECG beat classifier using a mixture of experts approach", IEEE Trans Biomed Eng, 44, page.891-900, 2007.
- [4] 장형중, 임준식, "심박수 변이도와 퍼지 신경망을 이용한 부정맥 추출", 한국 인터넷 정보학회, 10, 5, page.107-116, 2009.
- [5] Chazal P, O'Dwyer M and Reilly R, "Automatic Classification of Heartbeats Using ECG Morphology and Heartbeat Interval Features", IEEE Trans Biomed Eng, 51, page.1196-1206, 2004.
- [6] Osowski S, Hoai LT and arkiewicz T, "Support vector machine-based expert system for reliable heartbeat recognition", IEEE Trans Biomed Eng, 51, page.82-89, 2004.
- [7] Mark R and Mody G, "MIT-BIH Arrhythmia Database", <http://www.physionet.org/>, 1997.
- [8] American National Standard, "Testing and reporting performance results of cardiac", ANSI/AAMI EC57, 1998/(R)2003.
- [9] C. H. Choi, Y. J. Kim, T. H. Kim, Y. H. Ahn and D. R. Shin, "Analysis of QRS-wave Using Wavelet Transform of Electrocardiogram", J. of Biosystems Eng, 33, 5, page. 317-325, 2008.
- [10] Nikias C and Petropulu A, "Higher Order Spectral Analysis", Prentice-Hall, 1993.
- [11] Kang Han Hun, "A study on user's purchase history and preference based clothes recommendation", The graduate school of Sejong University, page.13-15, 2008.
- [12] Pang Ning Tan, Michael Steinbach and Vipin Kumar, "Introduction to Data Mining", Addison-Wesley, page.288-289, 2007.
- [13] 이대열, 양명훈, 김용준, 박영규, 윤현준, 강성호, "ACO를 이용한 저전력 ECC H-매트릭스 최적화 방안", 전자공학회 논문지, 45, 1, page.43-48, 2008.