
DCT, DWT와 신경망을 이용한 심전도 부정맥 분류

윤석주* · 김광준** · 장창수**

Classification of ECG arrhythmia using Discrete Cosine Transform, Discrete Wavelet Transform and Neural Network

Seok-Joo Yoon* · Gwang-Jun Kim** · Chang-Soo Jang**

요약

본 논문은 DCT, DWT와 역전과 신경망을 이용하여 MIT-BIH 부정맥 데이터베이스의 심전도 신호로부터 정상파와 부정맥 분류를 제안하였다. 역전과 신경망에 사용할 특징입력을 추출하기 위해 첫 번째 단계에서는 DCT 변환을 이용하여 15개의 계수를 선택하였다. 두 번째 단계에서는 DWT 변환 후 각 detail 계수들의 최대값, 최소값, 평균, 분산, 표준편차를 추출하였다. 역전과 신경망은 55개의 특징입력을 이용하여 정상파와 부정맥 파형을 분류하였고, 98.8%의 분류 성능을 나타냈다.

ABSTRACT

This paper presents an approach to classify normal and arrhythmia from the MIT-BIH Arrhythmia Database using Discrete Cosine Transform(DCT), Discrete Wavelet Transform(DWT) and neural network. In the first step, Discrete Cosine Transform is used to obtain the representative 15 coefficients for input features of neural network. In the second step, Discrete Wavelet Transform are used to extract maximum value, minimum value, mean value, variance, and standard deviation of detail coefficients. Neural network classifies normal and arrhythmia beats using 55 numbers of input features, and then the accuracy rate is 98.8%.

키워드

Electrocardiogram, Arrhythmia, Discrete Cosine Transform, Discrete Wavelet Transform
심전도, 부정맥, 이산 코사인 변환, 이산 웨이블릿 변환

1. 서론

현대인들이 고통받는 질환 중 하나인 심장계 질환은 부정맥, 심근허혈, 심근경색등과 같이 심장 리듬의 이상으로 발생한다. 심전도는 심장활동시에 나타나는 전기적 신호로써 심장상태와 질환을 알아 볼 수 있는 중요한 자료로 쓰인다. 심전도 신호는 P, Q, R, S, T

의 다섯 파형으로 구성되며 파형의 높낮이와 간격의 특징에 따라 신호를 분류하고 심장의 상태와 질병의 유무를 판단한다. 심전도 신호를 통해 알수 있는 질환으로 부정맥이 있는데 일반적으로 심장 박동의 리듬이 비정상적으로 빠르거나 너무 느린 상태를 말한다. 이러한 심전도 자동 진단에 대한 연구와 진단의 정확성을 높이기 위한 알고리즘 개발이 활발히 이루어지

* 전남대학교 전기·전자통신·컴퓨터공학부(sjyoon@songwon.ac.kr)

** 교신저자 : 전남대학교 전기·전자통신·컴퓨터공학부(kgj@jnu.ac.kr)

*** 전남대학교 전기·전자통신·컴퓨터공학부(csjang@jnu.ac.kr)

접수일자 : 2012. 06. 25

심사(수정)일자 : 2012. 07. 26

게재확정일자 : 2012. 08. 09

고 있다. 심장질환을 자동 진단하기 위해 신경망 및 퍼지 이론을 결합한 퍼지 신경망이 제안되어 왔다. 심전도 신호의 특징을 추출하기 위해 푸리에 변환 및 웨이블릿 변환이 사용되고 있으며 퍼지 신경망과 함께 심장질환 분류에 사용되고 있다[1][2].

Erik Zellmer는 QRS 데이터셋과 T 데이터셋을 사용하여 여러 가지의 특성을 만든 후 비선형 SVM으로 LBBB, RBBB, PAC, PVC등을 분류하였고[3], Liang-Yu Shyu은 웨이블릿 변환을 이용하여 QRS 구간의 길이와 여러 가지 특징을 추출하여 퍼지 신경망을 사용하여 NB, PVC, LBBB, RBBB, APC등을 분류하였다[4][5][6]. 이러한 대부분의 방법들은 특징추출을 위해 P-QRS-T 지점의 정확한 측정과 검출이 필요하여 데이터의 가공과 복잡한 알고리즘을 사용해야 한다. 그러나 정상 QRS 구간의 폭, P파, T파의 크기 및 위치들이 개인차가 있어 파형을 구분할 수 없을 경우도 존재한다.

본 논문에서는 부정맥 파형에 대한 특징 추출시 정확한 QRS 구간의 폭, P파와 T파의 크기 및 위치를 요구하지 않고 부정맥 파형 형태에 대한 대표적 값과 통계적 방법을 개인차 때문에 생기는 일반화의 문제를 해결하기 위해 사용하였다. 이를 위해 본 논문에서는 부정맥을 분류하는 방법으로 DCT 계수와 DWT detail 계수의 통계적 방법을 통한 특징벡터를 역전과 신경망의 입력으로 정상신호와 부정맥 신호를 분류하는 알고리즘을 제안하였다.

II. 관련 연구

2.1. 부정맥

부정맥은 동방결절에서 생성된 전기 자극이 심근세포로 전도되어 발생하는 정상리듬을 제외한 모든 리듬으로 정의된다. 발생기전에 따라 자극발생이상, 자극전도장애등으로 분류되며, 발생부위에 따라 동방결절, 심방, 방실결합부, 심실등으로 분류된다. 부정맥은 여러 가지 원인에 의하여 심장내 전기적 신호의 형성이나 전달과정에 이상이 생겨 발생한다. 만일 이러한 이상에 의해 심장박동수가 심하게 느려지면 서맥성 부정맥, 비정상적으로 빨라지면 빈맥성 부정맥이라 한다.

MIT-BIH 부정맥 데이터베이스에 포함되어있는 여러 가지의 리듬 유형중에 정상동조율(Normal sinus rhythm, N)은 심박동수 60~180회/분에서 동일성과 규칙성을 유지한다[7]. 박동조율(Paced rhythm, P)은 심장박동기의 부위, 종류, 설정등에 따라 다양한 단조리듬을 유지하며, 심장 박동기에 의한 조율혼적 후 특징적인 P파 또는 QRS파가 발생된다. 우각차단(Right bundle branch block, RBBB)과 좌각차단(Left bundle branch block, LBBB)은 심실내 자극전도의 차단정도에 따라 0.12초 이상의 QRS폭을 가진 파형이 유지된다. 표 1은 MIT-BIH 부정맥 데이터베이스의 레코드에 표시된 비트 주석을 나타낸다. 보조박동(P), 우각차단(R), 및 좌각차단(L)은 단조리듬 심박에 해당되며, 심방조기수축(A) 및 심실조기수축(V)은 주요 비정상 심박에 해당된다.

표 1. MIT-BIH 부정맥 데이터베이스의 비트주석
Table 1. Beat annotation of MIT-BIH arrhythmic DB

기호	의미
N	Normal beat
R	Right bundle branch block beat
L	Left bundle branch block beat
A	Atrial premature contraction
V	Premature ventricular contraction

2.2. Discrete Cosine Transform

DCT는 일반적으로 이미지, 비디오, 오디오등의 압축에 널리 사용된다. 여러 가지의 직교변환 가운데 신호의 에너지 집중 특성이 뛰어나 압축에 효과적인 Karhunen-Loeve Transform(KLT)에 가까운 성능을 구현한 것이 DCT이다. 신호를 DCT 변환하면 공간영역에서 주파수 영역으로 변하게 된다[8]. 신호성분이 낮은 주파수에 몰리게 되는 에너지 집중현상이 나타난다. 벡터 x 의 DCT $v = [v_0 \ v_1 \ \dots \ v_{N-1}]^T$ 는 다음과 같이 정의된다.

$$v_0 = \frac{1}{\sqrt{N}} \sum_{n=0}^{N-1} x_n \tag{1}$$

$$v_k = \sqrt{\frac{2}{N}} \sum_{n=0}^{N-1} x_n \cos \frac{(2n+1)k\pi}{2N} \quad (2)$$

$$k = 1, 2, \dots, (N-1)$$

여기서 v_k 는 k 번째 DCT 계수이며, v 의 IDCT는 식(3)과 같다.

$$x_n = \frac{1}{\sqrt{N}} v_0 + \sqrt{\frac{2}{N}} \sum_{k=1}^{N-1} v_k \cos \frac{(2n+1)k\pi}{2N} \quad (3)$$

입력신호 N 샘플의 DCT는 식(4)와 같이 정의할 수 있다.

$$F(u) = \sqrt{\frac{2}{N}} C(u) \sum_{x=0}^{N-1} f(x) \cos \left[\frac{\pi(2x+1)u}{2N} \right] \quad (4)$$

$$\begin{aligned} \text{여기에서 } C(u) &= \frac{1}{\sqrt{2}} & u=0 \\ C(u) &= 1 & \text{otherwise} \end{aligned}$$

함수 $f(x)$ 는 입력신호의 x 번째 샘플값을, $F(u)$ 는 DCT 계수를 나타내며 IDCT는 식(5)와 같다.

$$f(x) = \sqrt{\frac{2}{N}} \sum_{u=0}^{N-1} C(u) F(u) \cos \left[\frac{\pi(2x+1)u}{2N} \right] \quad (5)$$

DCT의 에너지 압축 특성으로 데이터를 낮은 차원으로 표현할 수 있다. 영 요소에 가까운 주파수 값들은 무시할 수 있어 대표적인 중요 계수만을 선택하여 차원을 축소할 수 있다.

2.3. Discrete Wavelet Transform

웨이블릿 변환은 입력된 샘플링 주파수를 다른 형태의 샘플링 주파수로 변환시켜 다양한 주파수 대역에서 신호를 처리할 수 있는 다해상도 시스템이다. 심전도 신호에 적용함으로써 잡음제거 및 과형분할을 동시에 수행할 수 있어 신호내의 각 특징 요소들에 대한 높은 분해능을 제공한다[9].

웨이블릿 변환은 입력신호를 웨이블릿 함수와 스케일 함수에 각각 곱하여 고주파와 저주파로 주파수 대역을 나누어 원하는 주파수 대역에서의 변환된 신호를 분석할 수 있다. 웨이블릿 함수 $\Psi(a, d)(x)$ 로부터 스케일 계수 a 와 천이요소 d 로 구분하여 식(6)과 같

이 나타낼 수 있다.

$$\Psi(a, d)(x) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \Psi\left(\frac{t-d}{a}\right) dt \quad (6)$$

심전도의 이산신호 $x(n)$ 을 이산 웨이블릿으로 변환시키려면 식(6)에서의 스케일링 요소(a)와 천이요소(d)를 이산화 함으로써 얻을 수 있으며, 레벨 $j=-1$ 일 경우 고주파 성분인 신호인 $D_{2^j}[x(n)]$ 과 저주파 성분인 $A_{2^j}[x(n)]$ 으로 구분하여 표시할 수 있다. 심전도 이산 신호를 $x(n) = D_{2^j}[x(n)] + A_{2^j}[x(n)]$ 으로 나타내며 일반적으로 식(7), (8)과 같다.

$$D_{2^j}[x(n)] = \sum_{k=1} d_{2^j}(K) \Psi_{2^j}(n - 2^j k) \quad (7)$$

$$A_{2^j}[x(n)] = \sum_{k=1} a_{2^j}(K) \Psi_{2^j}(n - 2^j k) \quad (8)$$

이때 2^j 는 레벨 j 가 감소함에 따라 샘플수가 2분주됨을 나타낸다. 식(7)은 고주파 성분인 detail 신호로써 웨이블릿 함수의 천이요소(d)에 의해서 입력신호의 고주파 성분을 레벨 j 에 따라 분할하며, 식(8)은 저주파 성분 approximation 신호로써 스케일 요소(a)에 의해 입력신호의 저주파 성분을 레벨 j 에 따라 분할한다.

D_k (detail)는 웨이블릿 계수와 관련된 FIR 고대역 필터계수이고 A_k (approximation)는 스케일 함수 계수와 관련된 FIR 저대역 필터계수이다. 각 필터를 지나 그 길이가 반으로 감소한 신호를 다음 스케일 레벨에서 반복하여 변환시킨다. 웨이블릿 변환으로 추출된 웨이블릿 계수는 웨이블릿 모함수에 대한 유사도로 이는 주어진 시간에 따른 주파수 신호를 나타낸다. 그림 1은 입력신호가 저주파 부분과 고주파 부분으로 분해되고, 다시 같은 방식으로 저주파 부분을 순차적으로 분해해 가는 다중 해상도 분석과정을 단계별로 표시한 것이다.

본 논문에서는 db6 모함수를 사용한 8 레벨 웨이블릿 변환을 사용하였다.

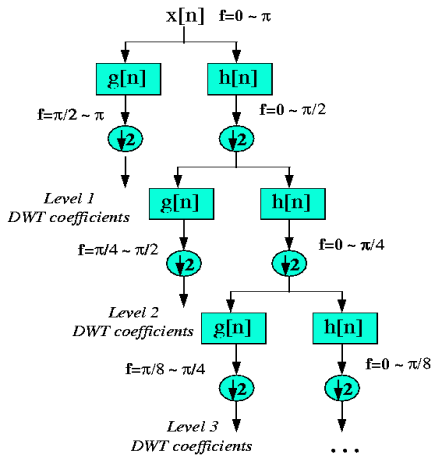


그림 1. 이산 웨이블릿 변환
Fig. 1 Discrete wavelet transform

2.4. 역전파 신경망 알고리즘

역전파 학습 알고리즘은 원하는 출력을 위하여 다층 신경망을 훈련시키기 위해 사용되는 기술이며 그림 2는 일반적인 다층 신경망을 나타내고 있다[10]. 입력층, 출력층, 은닉층등으로 구분되는데 역전파 알고리즘은 출력층으로부터 은닉층으로 목표 출력값에 대한 에러를 역으로 전파하는 원리로 동작한다.




그림 2. 다층 퍼셉론 신경망
Fig. 2 Multilayer perceptron neural network

신경망에 대한 각 층의 입출력은 그림 2와 같이 나타낼 수 있으며 각 층의 입력 x_i 에 대한 출력 y_i 와 학습을 통해 생성되는 결과값 z_k 는 식(9)(10)과 같이 나타낼 수 있다. w_{ji} 는 각 층의 가중치를 나타내며 학

습을 통해 변화된다.

$$y_j = f(net_j) = f\left(\sum_{i=1}^d w_{ji} x_i\right) \tag{9}$$

$$z_k = f(net_k) = f\left(\sum_{j=1}^H w_{kj} y_j\right) \tag{10}$$

역전파 알고리즘은 gradient descent error minimization에 기반하며 학습을 통하여 변화되는 가중치 w 는 식(11)과 같이 나타낼 수 있다.

$$w(k+1) = w(k) + \Delta w(k), \Delta w = -\eta \frac{\partial J(w)}{\partial w} \tag{11}$$

η 는 학습율이며, J 는 식(12)와 같다.

$$J(w) = \frac{1}{2} \sum_{k=1}^c (t_k - z_k)^2 = \frac{1}{2} \|t - z\|^2 \tag{12}$$

출력층과 은닉층간의 chain rule을 적용하여 정리하면 식(13)과 같이 표현된다.

$$\Delta w_{ji} = -\eta \frac{\partial J}{\partial w_{ji}} = \eta \left[\sum_{k=1}^c \delta_k w_{kj} \right] f'(net_j) x_i = \eta \delta_j x_i \tag{13}$$

이를 통하여 학습에 따른 Δw_{ji} 가 신경망에 적용되어 입력값과 목표 출력값에 대한 오차를 줄인다.

III. 실험 및 결과

본 논문에서는 MIT-BIH 부정맥 데이터베이스를 사용한다. MIT-BIH 부정맥 데이터베이스는 총 48명의 환자들의 기록으로 각각 30분 정도의 심전도 데이터로 구성되어 있다. 각 레코드는 2채널로 기록되었고 샘플링 레이트는 360Hz이다. 제한한 부정맥 분류 알고리즘의 개요는 그림 3과 같다.




그림 3. 부정맥 분류 알고리즘
Fig. 3 Arrhythmic classification algorithm

실험에 사용한 MIT-BIH 부정맥 데이터베이스의 레코드는 표 2와 같다. 레코드에 표시된 비트주석을 기준으로 좌측에서 89, 우측에서 90개의 데이터를 추출하여 180개의 데이터를 하나의 세그먼트로 구성한다. 그림 4는 비트 주석 분류별로 구성된 부정맥 세그먼트 파형의 예들이다.

표 2. MIT 데이터베이스에서 선택한 레코드
Table 2. Selected records from MIT BIH database

분류	MIT BIH DB 레코드 번호	갯수
Norm(N)	100, 103, 115, 116, 209, 221, 231	700
RBBB(R)	124, 207, 212, 231, 232	480
LBBB(L)	109, 111, 207, 214	400
APB(A)	118, 207, 222, 232	400
PVC(V)	106, 116, 119, 200, 203, 221, 233	700

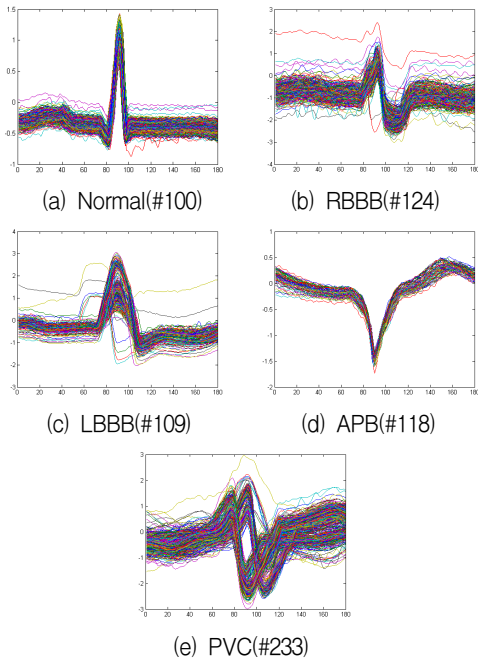


그림 4. 부정맥 파형
Fig. 4 ECG arrhythmic waveform

그림 5는 추출된 세그먼트로부터 DCT 변환을 적용하여 그중 대표 계수 15개만을 특징으로 추출하였다. 추출된 계수와 함께 db6 모함수와 레벨 8의 DWT 변환에서 나타난 각 레벨별 detail 계수의 최대값, 최소값, 평균, 분산, 표준편차를 구하여 특징벡터

로 사용한다.




그림 5. DCT 변환 파형
Fig. 5 DCT waveform

추출된 특징벡터는 역전과 신경망을 이용하여 정상파와 부정맥 신호를 분류한다. 신경망의 입력층으로는 추출된 특징벡터를 사용하며, 두 개의 중간층은 60개와 50개의 뉴런으로 구성하였으며, 출력층은 Normal(N), RBBB(R), LBBB(L), APB(A), PVC(V) 로 하였다. 역전과 신경망을 이용하여 훈련한 실험 결과는 표 3과 같다.

표 3. 부정맥 분류 결과
Table 3. Arrhythmia classification results

종류	N	R	L	A	V	분류율
N	700	0	0	0	0	100%
R	0	478	0	2	0	99.5%
L	0	1	387	5	7	96.7%
A	0	3	0	396	1	99%
V	1	2	4	2	691	98.7%

(N : Normal, R : RBBB, L : LBBB, A : APB, V : PVC)

IV. 결론

본 논문에서는 심전도의 P, QRS, T파의 검출없이 형태학적인 특징점을 추출하여 부정맥을 분류하는 알고리즘을 제안하였다.

제안한 분류 알고리즘은 평균 0.5초내외의 심전도 신호를 이용하여 DCT 변환계수와 DWT 변환의 detail 계수에 대한 최대값, 최소값, 평균값, 분산, 표준편차의 통계적 특징을 추출하여 역전과 신경망으로

학습하여 대표적인 부정맥신호를 자동 분류하였다. 제안한 알고리즘은 Normal(N) 100%, RBBB(R) 99.5%, LBBB(96.7%), APB(A) 99%, PVC(V) 98.7%의 분류 결과를 나타냈고 전체 분류율은 98.8%의 신뢰성 있는 결과를 나타냈다.

참고 문헌

- [1] M. Engin, "ECG beat classification using neurofuzzynetwork," Pattern Recognition Letters, Vol. 25, pp. 1715-1722, 2004.
- [2] S. Osowski and T. H. Linh, "ECG beatrecognition using fuzzy hybrid neural network," IEEE Trans. on Biomedical Engineering, Vol. 48, No. 4, pp. 1265-1271, 2001.
- [3] Erik Zellmer, Fei Shang, Hao Zhang "Highly Accurate ECG Beat Classification based on Continuous Wavelet Transformation and Multiple Support Vector Machine Classifiers", Biomedical Engineering and Informatics Conference MMEI, 2009, pp. 1-5, 2009.
- [4] 김광백, 우영운, "HSI 컬러 공간과 신경망을 이용한 내용 기반 이미지 검색", 한국전자통신학회논문지, Vol. 5, No. 2, pp. 152-157, April, 2010.
- [5] 김용연 "영상 통신을 위한 웨이블릿 변환 부호화", 한국전자통신학회논문지, Vol. 6, No. 1, pp. 61-67, Jan., 2011.
- [6] L. Y. Shyu, Y. H. Wu and W. C. Hu, "Using wavelet transform and fuzzy neural network for VPC detection from the holter ECG", IEEE Trans. Biomed. Eng., Vol. 51, pp. 1269, 2004.
- [7] PhysioBank : <http://www.physionet.org/physiobank/database/mitdb/>
- [8] N. S. Jayant, P. Noll, Digital Coding of Waveforms, Englewood Cliffs, NJ, Prentice-Hall, 1984.
- [9] I Daubechies, 'The Wavelet Transform, Time Frequency Localization and Signal Analysis', IEEE Trans. Info. Theory, Vol. 36, pp. 961-1005, 1990.
- [10] Miller, T., Sutton, R.s. and Werbos, P. J., "Neural Networks for Control", MIT Press, 1990.

저자 소개

윤석주(Seok-Joo Yoon)



1989년 조선대학교 컴퓨터공학과 졸업(공학사)

1993년 조선대학교 대학원 컴퓨터공학과 졸업(공학석사)

2010년 전남대학교 대학원 컴퓨터공학과 박사수료

1995년~현재 송원대학교 컴퓨터정보학과 조교수

※ 관심분야 : 정보보호, 의료정보 통신

김광준(Gwang-Jun Kim)



1993년 2월 조선대학교 컴퓨터공학과(공학사)

1995년 2월 조선대학교 컴퓨터공학과(공학석사)

2000년 2월 조선대학교 컴퓨터공학과(공학박사)

2003년~현재 전남대학교 컴퓨터공학과 조교수

※ 관심분야 : 가상화, 컴퓨터 네트워크, 실시간 통신 프로그래밍, 의료정보 통신 등

장창수(Chang-Soo Jang)



1980년 2월 조선대학교 전자공학과(공학사)

1982년 8월 건국대학교 전자공학과(공학석사)

1997년 2월 서강대학교 컴퓨터공학과(공학박사)

1984년~현재 전남대학교 컴퓨터공학과 교수

※ 관심분야 : 가상화, 컴퓨터구조, 병렬처리 구조, 상호연결망, 마이크로 프로세서, 의료정보 통신 등