

신경망 분류법을 사용한 PCA, ICA, LDA에 따른 부정맥 판별 성능 평가

김진권, 신광수, 신항식, 이명호
연세대학교 전기전자공학과

Comparison of performance for classification arrhythmia with PCA, ICA, LDA using artificial neural network

Jinkwon Kim, Kwangsoo Shin, Hangsik Shin, Myoungcho Lee
Dept. of Electrical and Electronic Engineering, Yonsei University

Abstract - 본 논문에서는 부정맥 판별을 위한 전처리 과정으로 PCA, LDA, ICA를 바탕으로 하여 정확도를 비교하여 보았다. 각각의 전처리는 고유의 특성을 가지고 있으며 본 논문의 목적은 부정맥 판별상 어떤 전처리가 더욱 정확성의 면에서 효과적인지를 알아보는 것이다. 본 논문의 데이터는 MIT-BIH에 기반하고 있으며, Beat의 분류는 정상(Normal), 좌각차단(Left Bundle Branch Block, LBBB), 우각차단(Right Bundle Branch Block, RBBB), 조기심실수축(Premature Ventricular Contraction, PVC), 조기심방수축(Atrial Premature Beat, APB), paced Beat, 심실보충수축(Ventricular Escape Beat)로 나누었다. 실험적 결과는 PCA-BPNN의 경우 95.53%, ICA-BPNN의 경우 93.95%, LDA-BPNN의 경우 96.42%로 LDA가 가장 ECG 부정맥 판별 응용에 있어 가장 효율적인 방법으로 나타났다.

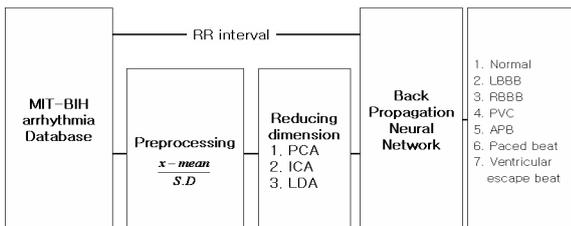
1. 서 론

심장 부정맥 판별 알고리즘에 대한 연구는 지난 수십 년 동안 다양한 방법으로 수행이 되어왔다. 최근 morphology 비교를 통해 부정맥을 판별하는 연구들이 많이 이루어졌으나 morphology를 판별 기준으로 한 알고리즘들은 ECG 파형을 직접 사용하기 때문에 계산량 소모가 많다. 따라서 많은 데이터 차원감소 기법들이 morphology 비교 기법에서 중요한 부분으로 사용되었으며, 다양한 연구들이 이루어져 왔다[1][2]. 데이터 차원감소기법 중 주성분 분석법(Principal Component Analysis, PCA), 독립성분 분석법(Independent Component Analysis, ICA), 선형판별 분석법(Linear Discriminant Analysis)은 가장 일반적으로 사용되는 기법이다. 주성분 분석법은 고유벡터로 데이터를 사상시켜 가장 데이터를 손실 없이 압축시키는 방식이며, 독립성분분석법은 non-gaussian source로 신호를 분석하여 데이터를 압축할 수 있다. LDA는 최적 분류 성능을 갖도록 데이터를 새로운 공간에 사상시키나 선형분류 가능할 경우에 좋은 성능을 보인다. 본 연구에서는 PCA, ICA, LDA를 통하여 심장 부정맥 판별 알고리즘을 설계하고 성능을 평가함으로써 ECG를 통한 심장 부정맥 판별 응용에 가장 적합한 특징의 데이터 압축방법을 얻고자 한다.

2. 본 론

2.1 시스템의 구성

본 연구에서 제안하는 부정맥 판별 알고리즘은 아래의 <그림 1>에 제시된 바와 같다. MIT-BIH arrhythmia database를 통해 획득한 데이터를 beat annotation 기준으로 총 105ms(38 samples)에 해당하는 데이터를 추출하고, 획득한 38 samples의 morphology 데이터에 PCA, ICA, LDA를 각각 적용하여 입력 벡터의 차원을 축소하였다. 차원 축소된 Morphology 특징벡터와 RR interval 값을 Back Propagation Neural Network의 입력특징벡터(input feature vector)로 사용하였으며, Morphology 특징벡터의 성분 개수 변화에 따른 정확도를 평가하였다.



<그림 1> 시스템의 구성

2.1.1 Principal Component Analysis

주성분 분석법은 데이터의 정보손실을 최소화 하면서 데이터의 차원

을 감소시키는 기법이다. 주성분 분석법으로 분석할 d 차원 데이터 \mathbf{x}_k 을 d' 차원으로 투영할 경우의 오차 J_d' 를 아래 식(1)과 같이 mean square error 값들의 합으로 표현할 수 있다.

$$J_{d'} = \sum_{k=1}^n \left\| \left(\mathbf{m} + \sum_{i=1}^{d'} a_{ki} \mathbf{e}_i \right) - \mathbf{x}_k \right\|^2 \quad (1)$$

위의 오차를 최소화 하는 값을 유도하기 위해 식(1)에 데이터의 공분산 행렬(covariance matrix)을 대입한다. 여기서 공분산 행렬을 \mathbf{S} 데이터 벡터를 \mathbf{x}_k , 데이터의 평균 벡터를 \mathbf{m} 이라 하면 공분산 행렬을 아래의 식 (2)과 같이 구할 수 있다.

$$\mathbf{S} = \sum_{k=1}^n (\mathbf{x}_k - \mathbf{m})(\mathbf{x}_k - \mathbf{m})^t \quad (2)$$

위 식을 식(1)에 대입하고 Lagrange 승수 λ_i 를 이용하여 벡터 \mathbf{e}_i 의 최소값을 구하면, 벡터 \mathbf{e}_i 가 공분산 행렬의 고유 벡터들인 경우에 최소값을 갖게 된다. 공분산 행렬은 실수이고 대칭이므로 고유벡터들은 서로 직교하며 이 고유 값의 크기 순서로 선정된 고유벡터들을 통해 차원 축소된 기저 벡터 집합을 형성하게 된다.

2.1.2 Independent Component Analysis

독립성분 분석법은 m개의 기저신호들을 s_1, s_2, \dots, s_m 라 하고 이들이 a_{ij} 에 의해 선형적인 조합으로 만들어진 m개의 관찰신호들을 x_1, x_2, \dots, x_m 이라 할 때 이들의 관계는 식(3)과 같이 표현 할 수 있다.

$$\mathbf{X} = \mathbf{A}\mathbf{S} \quad (3)$$

원하는 기저신호를 얻기 위하여 투영된 값이 기저신호와 얼마나 가까 운지를 나타내는 기준이 필요하며 이것은 central limit theorem에 근거 하여 신호의 nongaussianity를 측정하면 가능해 진다. 어떤 신호의 nongaussianity가 높을수록 그 신호는 기저신호에 가까워지는 것이다. nongaussianity를 측정하는 대표적인 방법으로는 kurtose와 negentropy 를 이용한 방법으로 나눌 수 있으며 본 논문에서는 negentropy를 이용한 알고리즘을 적용하였다. 또한 기저신호들을 한 번에 하나씩 추출하는 단점을 극복하기 위하여 centering과 whitening이라는 두가지 기법을 사용하였다.

기저신호 \mathbf{S} 와 관찰신호 \mathbf{X} 의 관계가 $\mathbf{S} = \mathbf{W}\mathbf{X}$ 일때 확률밀도함수를 표현한다면 식(4)와 같이 표현 할 수 있다.

$$p(x) = |\det \mathbf{W}| p(s) = |\det \mathbf{W}| \prod p_i(s_i) \quad (4)$$

식(4)를 log우도에 적용하면 식(5)와 같다.

$$\frac{1}{T} \log L(\mathbf{B}) = E \left\{ \sum_{k=1}^c \log p_i(w_i^T x) \right\} + \log |\det \mathbf{W}| \quad (5)$$

\mathbf{B} 는 $\mathbf{Y} = \mathbf{M}\mathbf{X}$ 에서 $\mathbf{Y} = \mathbf{M}\mathbf{A}\mathbf{S} = \mathbf{B}\mathbf{S}$ 의 벡터이고 T 는 x 의 갯수, \mathbf{W} 는 $\mathbf{W} = (w_1, w_2, \dots, w_m)^T$ 이다. 이를 이용해 우도가 최대가 되게 하는 \mathbf{W} 를 찾는다.

2.1.3 Linear Discriminant Analysis

선형판별 분석법은 성분이 서로 다른 집단을 집단 간의 분리가 잘 되 게 표현하도록 만들어진 방법으로 구성성분의 변화와 그 밖의 다른 요 인에 의한 변화를 잘 구분할 수 있게 한다. 선형판별분석은 변환 후 서 로 다른 구성 성분을 가지는 집단에 속하는 데이터 간의 분산은 최대로 하고 구성 성분이 같은 집단내부의 데이터 간의 분산을 최소가 되도록 하는 변환을 구해냄으로써 이를 수 있게 된다. LDA는 변환행렬 \mathbf{W} 를 선택하여 클래스 간 분산과 클래스 내의 분산의 비가 최대가 되도록하는 것이다.

$$z_i = \mathbf{W}^T y_i \quad (6)$$

\mathbf{S}_w 가 비특이라고 가정하면 \mathbf{W} 의 기본 벡터가 $\mathbf{S}_w \mathbf{S}_B$ 의 고유치의 크 기 순서대로 m개의 고유벡터로 이루어진다. 여기서 \mathbf{S}_B 클래스 간 분산

행렬이라고 하고 S_W 를 클래스 내 분산행렬이라고 정의한다면 최적의 투영 W_{opt} 는 식(7)로 표현할 수 있다.

$$W_{opt} = \arg \max \frac{W^T S_B W}{W^T S_W W} = [w_1, w_2, \dots, w_m] \quad (7)$$

2.1.4 Back Propagation Neural Network

다층신경망은 입력층과 은닉층, 그리고 출력층 사이의 연결 강도나 바이어스 값을 원하는 결과에 맞게 조절하는 작업을 학습이라 하며 BPNN은 다층신경망을 학습시키는 방법 중의 하나이다. BPNN을 분석적으로 살펴보기 위해 다음과 같은 훈련 에러함수를 정의한다. t_k 와 \bar{t} 는 목표 값을 의미하며 z_k 와 Z 는 출력 값을 의미한다.

$$J(W) = \frac{1}{2} \sum_{k=1}^n (t_k - z_k)^2 = \frac{1}{2} \|T - Z\|^2 \quad (8)$$

BPNN은 경사강하기법에 기반을 두고 있으며 가중치들은 임의의 값(0 제외)으로 초기화되며, 아래와 같은 방향으로 가중치를 수정하여 식(8)을 감소시킨다. W 는 가중치, η 는 학습률이다.

$$\Delta W = -\eta \frac{\partial J}{\partial W} \quad (9)$$

본 논문에서 사용한 인공신경망의 구조는 은닉뉴론 20개, 학습률 0.01, 학습횟수 1000회, 활성화 함수는 가장 널리 쓰이는 sigmoid 함수를 사용하였다.

2.2 시스템의 평가

제안하는 알고리즘의 평가를 위해 MIT-BIH arrhythmia database의 beat annotation 중에서 정상(normal beat), 좌각차단(left bundle branch block, LBBB), 우각차단(right bundle branch block, RBBB), 조기심실수축(premature ventricular contraction, PVC), 조기심방수축(atrial premature beat, APB), paced beat, 심실보충수축(ventricular escape beat), 7가지에 대해 분류 성능을 평가했다. 데이터의 구성은 아래의 <표 1>과 같이 구성되어 있으며, Morphology 데이터는 평균을 감산하고 표준편차로 나누어 정규화 시켰다. 정규화 된 morphology 데이터는 각각 PCA, ICA, LDA를 사용하여 차원을 감소시켰으며, RR interval 값과 함께 테스트 벡터로 사용했다. 테스트 벡터는 역전과 알고리즘에 사용하여 부정맥 판별을 수행하였다. 시뮬레이션은 테스트 벡터에 사용하는 성분의 수를 변화시키며 최적 정확도에 대해 PCA, ICA, LDA의 비교연구를 수행하였으며, 기존의 연구들과 비교하여 평가하였다. 정확도 판별 기준은 아래의 식(12)와 같다. 평가환경은 AMD Athlon 64 Processor 3000+ 1.80 GHz, 1 GB RAM, PC 환경에서 MATLAB 7.1을 사용하였다.

<표 1> 데이터 구성

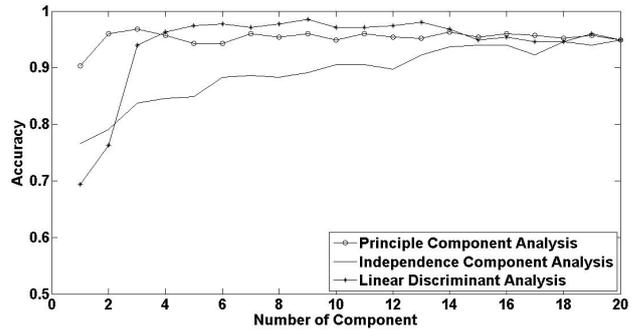
Type	MIT-BIH data file	data pool	Test set	Training set
Normal	100, 116, 209	100	50	50
LBBB	111, 207, 214	100	50	50
RBBB	118, 231, 232	100	50	50
PVC	116, 119, 208	100	50	50
APB	207, 209, 222	100	50	50
Paced beat	107	100	50	50
Ventricular escape beat	207	100	50	50
Total		700	350	350

$$accuracy = 1 - \frac{\text{number of misclassified beats}}{\text{number of total beats}} \quad (10)$$

2.3 평가의 결과

시뮬레이션 결과 PCA를 기준으로 component를 20개 사용할 경우 데이터 정보의 99% 이상을 사용할 수 있었다. 따라서 시뮬레이션 평가는 판별에 사용된 component의 수를 1개에서 20개로 증가시키며 정확도의 향상을 평가하였다. 이 과정에서 PCA, ICA, LDA의 성능을 비교평가하여 ECG 부정맥 분석에 적합한 차원감소 알고리즘을 찾아내고자 하였다. <그림2>은 부정맥 판별 정확도 시뮬레이션의 결과로서 사용된 component의 수가 15개 이상의 경우에는 PCA, ICA, LDA 모두에서 94% 이상의 판별정확도를 나타내었다. PCA는 2개의 component를 사용한 경우에 96%의 성능을 보인 후 component의 수를 늘려도 성능의 향상 없었으며, LDA의 경우에는 3개의 component를 사용한 경우 94%의 성능을 보인 후 95~6%대에서 유지되었다. 반면에 ICA의 경우 15개의 경우에 94%의 성능을 나타내었다. 가장 높은 성능을 보인 차원감소 알고리즘은 LDA로서 사용된 component의 수가 3개에서 20개까지인 구간

에서 saturation된 정확도 성능이 평균 96.42%로 나타났다. 이에 비해 PCA의 평균 정확도는 95.53%, ICA의 경우 93.95%로 나타났다.



<그림 2> 부정맥 판별 정확도 시뮬레이션 결과

<표 2>는 기본 부정맥 판별 연구들의 정확도로서, 85~98%의 성능을 보인다. 제안하는 세 가지 방식은 아래의 표에서 나타난 바와 같이 분류 가능 부정맥의 수와 정확도 측면에서 높은 성능을 보인다.

<표 2> 기존 부정맥 판별 연구의 정확도

Method	분류 가능 부정맥의 수	Accuracy
MOE [3]	4	94.0 %
FTNN [4]	3	98.0 %
Fhyb-HOSA[5]	7	96.06 %
BSS-Fourier[6]	5	85.04 %
DWT-NN[7]	13	96.79 %
Proposed PCA-BPNN	7	95.53 %
Proposed ICA-BPNN	7	96.42 %
Proposed LDA-BPNN	7	93.95 %

3. 결 론

본 논문에서는 대표적인 세 가지 데이터 차원감소 기법인 PCA, ICA, LDA를 ECG 부정맥 판별 응용에 활용하여 가장 적합한 차원감소 기법에 대해 평가하였다. 평가결과 LDA가 PCA와 ICA보다 높은 정확도 성능을 나타냈으며, 이는 ECG Morphology 성분의 선형 분리 가능성에 기여한다. 본 연구에서는 BPNN을 사용하여 판별을 수행하였으나, 차후 다양한 판별 알고리즘의 평가를 통해 본 응용 분야에 가장 적합한 데이터 차원감소기법과 판별알고리즘에 대한 연구를 수행할 것이다.

[참 고 문 헌]

- [1] Sung-Nien Yu, Kuan-To Chou, "Combining Independent Component Analysis and Backpropagation Neural Network for ECG Beat Classification", Engineering in Medicine and Biology Society, 2006. EMBS '06. 28th Annual International Conference of the IEEE, Page(s):3090 - 3093, Aug. 2006
- [2] Hao Zhang, Li-Qing Zhang, "ECG analysis based on PCA and Support Vector Machines" Neural Networks and Brain, 2005. ICNN&B '05. International Conference on Volume 2, 13-15, Page(s):743 - 747, Oct. 2005
- [3] 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, No. 9, pp. 891-900., 1997
- [4] K. Minami, H. Nakajima, and T. Toyoshima, "Real-time discrimination of ventricular tachyarrhythmia with Fourier-transform neural network," IEEE Trans. on Biomed. Eng., Vol. 46, No. 2, pp. 179-185 1999
- [5] S. Osowski, , and T. H. Linh, "ECG beat recognition using fuzzy hybrid neural network," IEEE Trans. Biomed. Eng., Vol. 48, pp. 1265-1271, 2001
- [6] M.I. Owis, A.-B.M. Youssef, and Y.M. Kadah, "Characterization of ECG signals based on blind source separation," Medical & Biological Engineering & Computing, Vol. 40 , pp.557-564, 2002
- [7] G. K. Prasad, and J. S. Sahambi, "Classification of ECG arrhythmias using multi-resolution analysis and neural networks," Proc. IEEE Conf. on Convergent Technologies (Tecon2003), Bangalore, India, Vol. 1, pp. 227-231, 2003