

# 심전도 신호기반 개인식별을 위한 텐서표현의 다선형 판별분석기법

A Multilinear LDA Method of Tensor Representation for ECG Signal Based Individual Identification

임원철\*, 꺾근창\*\*

(Won-Cheol Lim, Keun-Chang Kwak)

## 요약

심전도 신호는 기본적으로 심장의 전기적 활동에 포함되며 이를 통해 심박수 측정, 심장 박동의 리듬 검사, 심장 이상 진단, 정서 인식 및 생체 인식과 같은 다양한 목적으로 분석 및 활용된다. 본 논문의 목적은 다차원 데이터 배열인 텐서 특성을 가진 다선형 판별분석(MLDA: Multilinear Linear Discriminant Analysis) 기법을 이용하여 개인식별을 수행하고자 한다. MLDA는 상위 차원의 텐서를 포함하는 분류 문제에 대해서 차원 문제를 해결 할 수 있으며, 상호 연관된 부분 공간은 서로 다른 클래스를 구별하기 위해 사용될 수 있다. 제시된 방법의 성능을 검증하기 위해 Physionet의 MIT-BIH 데이터베이스를 적용하였다. 이 데이터베이스에 대해 실험한 결과, MLDA는 기존 PCA와 LDA와 비교하여 개인식별 성능이 우수함을 확인하였다.

■ 중심어 : 다선형 판별 분석; 텐서표현; MIT-BIH 데이터베이스; 심전도; 생체인식

## Abstract

A Multilinear LDA Method of Tensor Representation for ECG Signal Based Individual Identification

Electrocardiogram signals, included in the cardiac electrical activity, are often analyzed and used for various purposes such as heart rate measurement, heartbeat rhythm test, heart abnormality diagnosis, emotion recognition and biometrics. The objective of this paper is to perform individual identification operation based on Multilinear Linear Discriminant Analysis (MLDA) with the tensor feature. The MLDA can solve dimensional aspects of classification problems in high-dimensional tensor, and correlated subspaces can be used to distinguish between different classes. In order to evaluate the performance, we used MPhysionet's MIT-BIH database. The experimental results on this database showed that the individual identification by MLDA outperformed that by PCA and LDA.

■ keywords : multilinear discriminant analysis; tensor representation; MIT-BIH database; electrocardiogram; biometrics

## I. 서론

개인 식별 기술은 인간의 고유한 특성과 이 특성을 기반으로 사람을 식별하거나 인증을 하는 기술이다. 신뢰할 수 있는 개인의 식별 방법의 새로운 접근 방법 중 하나가 생체인식이다 [1]. 개인 식별을 위해 이전부터 사용되고 있는 IC칩, 패스워드, 패턴인식 방식들을 사용하지만 이는 보안성이 미흡하여 신뢰하기 어렵다. 타인에게 쉽게 노출될 수 있는 문제점을 생체인식 기술로 해결 할 수 있다. 지문, 얼굴인식, 홍채, 음성, 정맥 등 외부적으로 관찰 가능한 특성들이 생체인식 시스템이 광범위하

게 사용되어지고 있으며 더 안정적인 성능을 얻기 위한 연구가 진행되고 있다[2-3]. 외부적으로 관찰 가능한 생체정보들은 여러 장점들이 존재하지만 생체 자체를 감지할 수 없는 문제가 있다. 즉, 생체 정보를 이용한 시스템이 생체 정보를 정확히 인식한다고 해도 인식된 당사자가 실제로 있는지 보장하기 어렵다. 2013년 아이폰의 화면에서 지문을 채취해 프린트 한 후 손가락에 시트를 붙이고 잠금을 해제한 사례와 사람의 얼굴을 촬영해 프린트하고 눈 부분에 콘택트렌즈를 올려놓는 것만으로 홍채인식 스캐너를 통과한 사례 등을 통해 생체정보가 위변조에 취약하다는 것을 알 수 있다. 위변조의 위협에 대한 우려가 존재하여 새로운 생체인식 방법인 심전도와 같은 생체신호가 제안되

\* 학생회원, 조선대학교 소프트웨어융합공학과

\*\* 정회원, 조선대학교 전자공학부

이 논문은 2017년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. 2017R1A6A1A03015496),

본 연구는 미래창조과학부 및 한국인터넷진흥원의 "고용계약형 정보보호 석사과정 지원사업"의 연구결과로 수행되었음(과제번호 H2101-16-1001)

접수일자 : 2018년 09월 27일

수정일자 : 2018년 11월 13일

게재확정일 : 2018년 11월 21일

교신저자 : 꺾근창 e-mail : kwak@chosun.ac.kr

고 있다[4-5]. 심전도는 최근 인증을 위한 생체 인식 특성으로 더 많은 관심을 받고 있으며 생체 인식 분야에서 심전도는 위변조가 어렵다. 심전도는 1차원 시간영역의 신호여서 계산 및 저장에 대한 요구가 낮기 때문에 개인 식별을 위한 이상적인 인식 방법이며 웨어러블 기기의 급격한 발전으로 인해 심전도 신호의 수집이 더욱 쉬워졌다.

심전도는 심장의 전기적 전위를 측정하고 기록하는 방법이며 신체 자체에 대한 고유한 생체 특징을 나타내며 심장의 생리적 차이가 각 사람마다 고유성을 나타내어지기 때문에 생체인식과 함께 개인을 인식하는데 특징 패턴으로 사용이 된다. 심전도 신호는 생체인식을 위해 심전도 신호는 P, Q, R, S, T 파의 정확한 측정이 필요하며 이를 위해 전처리 과정을 거쳐 특징 추출하여 신호를 분석한다[6]. 전처리 과정에서 대표적으로 사용되는 웨이블릿 변환(Wavelet transform)은 노이즈를 포함한 신호를 평활하거나, 신호와 노이즈의 경계를 구분할 수 있어 넓은 범위에서 응용되고 있으며 기저의 상사성을 유지시키기 위한 시간-주파수 분석 방법으로 사용된다[7]. 특징들을 학습시키기 위한 전통적인 특징추출 방법인 차원축소(Dimensionality reduction) 기법은 PCA(Principal Component Analysis), LDA(Linear discriminant analysis)와 ICA(Independent Component Analysis) 등이 있다[8-12].

기존의 부분 공간 학습 알고리즘인 PCA, LDA, ICA는 벡터에서 동작하는 선형 부분 공간 학습이다. 선형 부분 공간 학습(Linear subspace learning) 알고리즘은 입력 데이터를 벡터로 나타내고 저차원 공간에 대한 최적 선형 매핑(mapping)을 해결하는 전통적인 차원 감소 기술임에 반해 대규모 다차원 데이터를 다룰 때는 적절치 못한 경우가 많다. 이것을 해결하기 위한 방안으로 다차원 객체에서 특징을 추출하는 다선형 부분 공간 학습(Multilinear subspace learning)이 개발되었다. 다선형 부분 공간 학습은 차원감소에 대한 접근 방식이며 차원 축소를 통해 데이터가 벡터화가 되고 텐서로 구성되거나 텐서와 텐서로 연결되는 행렬로 구성될 수 있다. 다선형에서 사용되는 다차원 데이터 배열인 텐서는 벡터 및 행렬을 다차원 데이터 형식으로 확장한 것이며 다차원 데이터 배열인 텐서를 이용하여 고차원 텐서 표현에서 저차원의 벡터 또는 텐서 표현으로 매핑하는 것이 목적이다[13]. MLDA은 데이터의 객체 구조가 깨지지 않고 차원의 저주를 피하여 샘플 크기의 문제를 극복함으로써 부분 공간의 차원과 완전 투영을 최적화하여 성능을 향상시킬 수 있어 얼굴인식이나 보행자인식 등의 성능 분석에서도 사용되고 있다[14-15].

최근 다양한 분야에서 데이터가 급격히 증가하고 있으며 이 큰 데이터의 대부분은 다차원이면서 많은 중복성이 있다. 따라서 다선형 부분 공간 학습을 이용하여 데이터의 원래 구조를 유지하고 텐션을 표현하여 대용량 데이터를 처리함에 있어 비용

문제, 처리능력을 해결할 수 있다[16]. 본 논문에서는 심전도 신호의 개인 식별을 위해 신호에서 예상치 못하게 튀는 신호나 일부 정상적인 파형의 범위에서 벗어나는 신호를 효과적으로 인식 할 수 있도록 리드의 신호를 결합하여 시퀀스 형태로 형성하고 텐서로 재구성하여 MLDA를 통해 효율적인 차원축소를 하여 기존의 PCA, LDA방법과 성능을 비교한다. 2절에서는 차원 축소 기술인 LDA, MLDA의 분석, 3절에서는 전처리, 특징 추출 및 분류의 방법에 대해 설명하며 4절에서는 실험 결과 및 분석으로 결론짓는다.

## II. 차원 축소 기법

### 1. 선형 판별 분석(LDA) 기법

LDA는 차원감소에 대한 전통적인 통계적 접근 방법이다. 특정 공간상에서 클래스의 분리를 최대화 하는 주축으로 투영시켜 선형 공간으로 차원을 축소하는 방법이다. LDA는 클래스 내 거리를 최소화하고 클래스 간 거리를 동시에 극대화하여 최적의 투영을 계산하므로 클래스 구분을 최대화한다. LDA에서 최적의 변환은 분산 행렬에 고유 분해를 적용하여 쉽게 계산할 수 있다[17]. 그림 1은 3개의 클래스의 특징 데이터를 특정 공간상에서 투영시켜 1차원 공간으로 축소시킨 것으로 클래스 내의 분산과 클래스 간의 분산이 잘 분류 된 것을 보여준다.

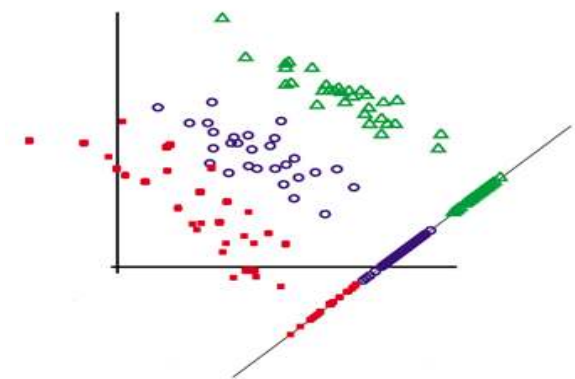


그림 1. LDA에 의한 차원 축소

선형 판별 분석 기법을 통한 차원 축소 과정은 아래와 같다. 학습 데이터의 벡터( $x^1, x^2, \dots, x^p$ )를 정의하고 각 클래스 데이터의 평균 벡터를 구하는 식은 다음과 같다.

$$x^1, x^2, \dots, x^p, \quad m = \frac{1}{p} \sum_{i=0}^{n_i} x_i \quad (1)$$

$$S_i = \sum_{x \in X_i} (x - m_i)(x - m_i)^T \quad (2)$$

식 (1)은 학습 데이터의 벡터와 클래스 데이터의 평균 벡터를 계산하며  $n_i$ 는 클래스 수를 나타낸다. 식 (2)은  $i$ 번째 클래스 내의 분산 행렬을 구하는 식이며,  $i$ 는 클래스를 나타내며  $p$ 는 데이터 수,  $m$ 은 전체 데이터  $p$ 개의 평균,  $m_i$ 은  $i$ 번째 클래스의 평균을 의미한다. 식 (1)을 이용해  $i$ 번째 클래스 내의 분산 행렬  $S_i$ 을 구할 수 있다.

$$S_W = \sum_{i=1}^c S_i \quad (3)$$

$$S_B = \sum_{i=1}^c n_i (m_i - m)(m_i - m)^T \quad (4)$$

식 (2)으로부터 전체 클래스 내의 분산 행렬  $S_W$ 을 식(3)처럼 구하며, 클래스 간 분산 행렬  $S_B$ 을 계산은 식(4)과 같이 나타낸다.  $n_i$ 은 각 클래스의 데이터 수,  $c$ 는 클래스의 수,  $m$ 은 전체 데이터의 평균을 나타낸다[18].

클래스 내의 분산 행렬과 클래스 간 분산 행렬의 비율이 최대가 되는 행렬을 찾는다. 클래스 수-1개의 0이 아닌 고유치가 존재하며, 따라서  $m$ 의 상한값은 클래스 수-1개가 존재하며 다음과 같이 구할 수 있다.

$$W^T = \operatorname{argmax} \frac{|W^T S_B W|}{|W^T S_W W|} = S_W^{-1}(\mu_1 - \mu_2) \quad (5)$$

$$S_W^{-1} S_B w = \lambda_i \quad (6)$$

식 (5)로부터  $[w_1, w_2, \dots, w_m]$ 의  $m$ 개의 고유벡터를 구할 수 있으며, 식 (2) 클래스 내의 분산 행렬과 식 (4) 클래스 간 분산 행렬로부터  $i$ 번째 고유치 중에서  $q$ 개( $\lambda_1, \dots, \lambda_q$ )의 가장 큰 고유값에 해당하는 고유벡터( $v_1, \dots, v_q$ )를 선택하여 이를 열로 하는 변환 행렬  $W$ 를 구성하며,  $S_W^{-1} S_B w$ 에 대한 고유값 분석에 대한 수행은 식 (6)으로 나타낼 수 있다.

위의 과정을 통해 인식 대상의 데이터에 대해 평균 데이터의 차  $\bar{y}_i = y^i - m$ 을 구하고 인식대상 데이터에 투영  $\tilde{y}^i = W_T y^i$  하여 인식값을 취할 수 있으며, 이로부터 데이터의 축소 및 분류를 할 수 있다.

### 2. 다선형 판별 분석(MLDA) 기법

다선형 판별 분석 (MLDA:Multilinear discriminant analysis)기법은 선형 판별 분석 기법의 확장된 기법으로 더 높은 차원의 특성 공간에서 적용되어 고차 텐서 및 선형 최적화 접근법을 통해 차원성 딜레마에서 벗어날 수 있다. 기존의 선형 판별 분석 기법은 데이터의 클래스 수에 따라 사용 가능한 차원이 제한되지만 다선형 판별 분석에서는 더 많은 차원을 사용하여 계산을 할 수 있으며 더 작은 크기의 공간에서 수행될 수 있기 때문에 계산에 따른 비용 측면에서도 크게 감소 될 수 있다. 데이터의 표현 및 특징 추출을 위한 벡터에서 텐서로의 확장이 이루어짐에 따라 알고리즘의 학습 능력 및 효율성을 향상시키기 위해 다른 알고리즘에도 적용이 될 수 있다[19].

다선형 판별 분석은 다선형 주성분 분석(MPCA:Multilinear Principal Component Analysis)과 결합되어 구성된다. 다선형 주성분 분석 알고리즘은 2차원 데이터를 기반으로 하는 기존의 방법을 무시하고 벡터 대신 여러 데이터를 고차원 텐서로 통합하고 텐서 공간에서 데이터를 처리한다. 이 접근법은 데이터의 정보를 지속적으로 구성 할 수 있기 때문에 결과적으로 픽셀 간의 공간 관계를 고려할 때 정확도가 향상된다. 다선형 판별 분석은 부분 공간에서 표본을 모으고 인식률을 향상시킬 수 있기 때문에 다선형 주성분 분석에 의해 처리 된 표본의 크기를 더욱 줄이기 위해 다선형 판별 분석으로 확장시킬 수 있다. 위의 특성들을 통해 다선형 판별 분석은 선형 판별 분석에서 확장된 자연스러운 제안이며 객체가 텐서 표현으로 나타낼 수 있으며 개인 식별 인식 성능을 높일 수 있다.

## III. ECG 기반 MLDA

### 1. 전처리 과정

데이터 신호의 여러 잡음을 제거하기 위해 500크기의 평균 필터를 통해 정규화와 스파이크를 제거 후 유효한 신호에서 R 피크 검출을 한다. 유효 신호에서 검출된 결과를 통해 R피크 기준으로 앞 뒤 400프레임에 대한 평균을 입력 신호로써 사용하며 전체 구성도는 그림 2와 같이 나타낸다.

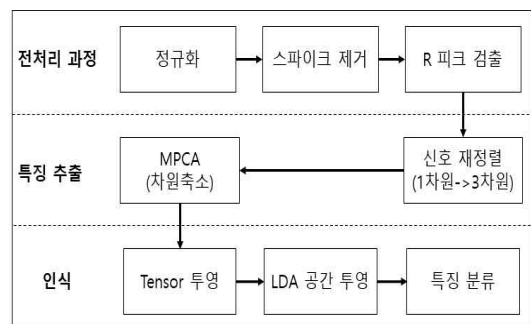

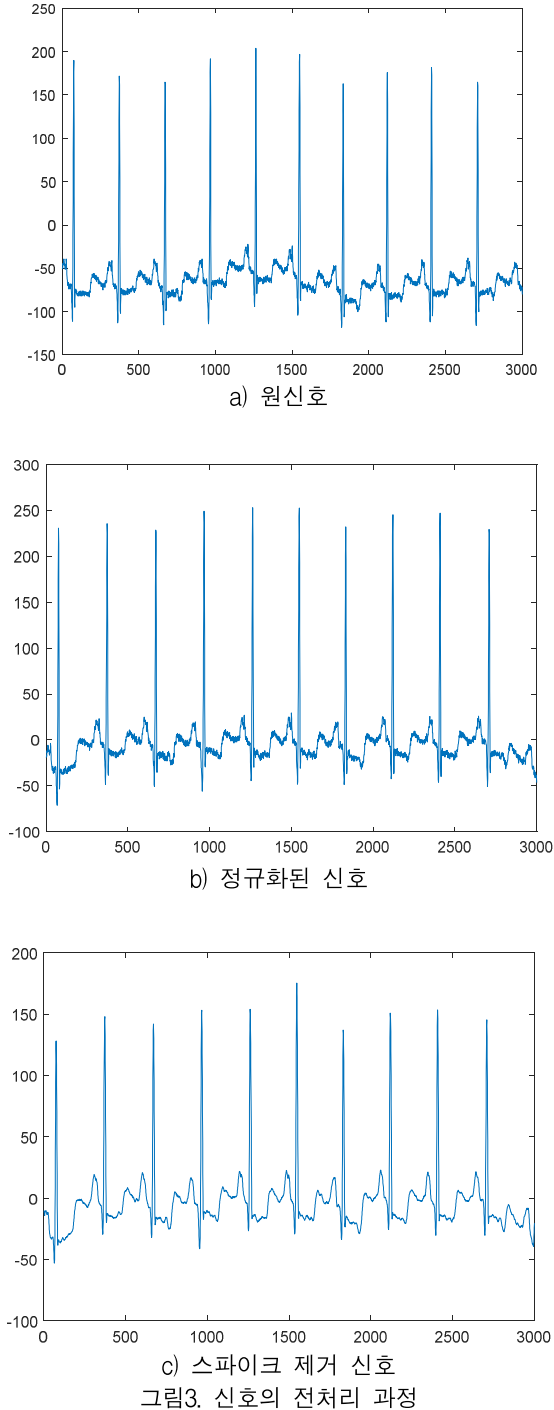


그림 2. 전체 구성도

그림 3은 원신호, 정규화된 신호, 스파이크 제거 그림을 나타낸다. 그림 3의 a)는 원신호를 나타내며 b)는 원신호를 정규화한 신호를 나타내고, c)는 정규화한 신호의 스파이크를 제거한 신호이며 d)는 500크기의 평균 필터를 통한 R피크검출을 한 것을 보여준다.



## 2. 특징 추출

학습 데이터와 검증데이터를 분류하고 전처리 과정을 거쳐 다선형 주성분 분석 기법을 통해 차원축소를 하고 선형 판별 분석의 공간으로 투영시켜 인식률을 계산하는 과정을 따른다. 다선형 주성분 분석의 간략한 설명은 다음과 같다.

다선형 주성분 분석을 간략하게 나타내면 다음과 같다. 텐서는 표기를  $A$ 이며, 차원 수  $N$ 은 텐서 순서를 표기한다. 텐서 요소는  $N$ 개의 지수이며 각 모드를 나타낸다.  $N$ 차 텐서의 표현은  $A \in R^{I_1 \times I_2 \times \dots \times I_N}$ 이다.  $N$ 개의 지수는  $i_n$ 이며 각  $A$ 의  $n$ -모드를 지정한다. 텐서  $A$ 와 행렬  $U \in R^{J_n \times I_n}$ 의 곱은  $A \times_n U$ 로 나타내며 다음과 같이 표현 할 수 있다.

$$(A \times_n U)(i_1, \dots, i_{n-1}, j_n, i_{n+1}, \dots, i_N) = \sum_{i_n} A(i_1, \dots, i_N) \cdot U(j_n, i_n) \quad (7)$$

두 텐서의 스칼라 곱인  $A, B \in R^{I_1 \times I_2 \times \dots \times I_N}$ 은 다음과 같이 나타낸다.

$$\langle A, B \rangle = \sum_{i_1} \sum_{i_2} \dots \sum_{i_N} A(i_1, i_2, \dots, i_N) \cdot B(i_1, i_2, \dots, i_N) \quad (8)$$

텐서  $A$ 의 프로베니우스 놈(Frobenius Norm)은  $\|A\|_F = \sqrt{\langle A, A \rangle}$ 으로 정의되며, 텐서  $A$ 의 세트  $[X_1, X_2, \dots, X_M]$ 이 존재할 때 텐서의 객체는  $X_m \in R^{I_1 \times I_2 \times \dots \times I_N}$ 으로 나타낸다. 이후 표준 다선형 대수식에 따라, 임의의 텐서  $A$ 는 곱의 형태로 표현될 수 있다.

$$A = S \times_1 U^{(1)} \times_2 U^{(2)} \times \dots \times_N U^{(N)} \quad (9)$$

식 (9)에서 S는 다음과 같이 표현된다.

$$S = A \times_1 U^{(1)T} \times_2 U^{(2)T} \times \dots \times_N U^{(N)T} \quad (10)$$

$U^{(n)} = (u_1^{(n)} u_2^{(n)} \dots u_{I_n}^{(n)})$ 은  $I_n \times I_n$  직교행렬이며 행렬을 분해한 값을 식 (9)와 식(10)을 통해 얻을 수 있다.

$$A_{(n)} = U^{(n)} \cdot S_{(n)} \cdot (U^{(n+1)} \otimes U^{(n+2)} \otimes \dots \otimes U^{(N)} \otimes U^{(1)} \otimes U^{(2)} \otimes \dots \otimes U^{(n-1)})^T \quad (11)$$

텐서의 각 모드를 투영하여 최대 분산을 만족하는 저 차원의 텐서를 얻을 수 있으며, 그림 4는 각 모드의 투영을 나타낸다.

$R^1 \otimes R^2 \dots \otimes R^N$ 에서  $\{X_m, m = 1, \dots, M\}$ 의  $M$ 텐서가 있다고 할 때 텐서들의 총 분산은 아래 식과 같이 나타낼 수 있다.  $\Psi$ 은 텐서들의 총 분산,  $\bar{X}$ 는 평균텐서를 나타낸다.

$$\Psi_X = \sum_{m=1}^M \|X_m - \bar{X}\|_F^2 \quad (12)$$

$$\bar{X} = \left(\frac{1}{M}\right) \sum_{m=1}^M X_m \quad (13)$$

$$V_{T_A}^{(n)} = \sum_{m=1}^M (A_{m(n)} - \bar{A}_{(n)}) \cdot (A_{m(n)} - \bar{A}_{(n)})^T \quad (14)$$




그림 4. 각 모드별 투영 과정

$A_{m(n)}$ 은  $A_m$ 의 n-mode 전개되지 않은 행렬을 나타낸다. 다시 말해, 다선형 주성분 분석은 총 텐서의 분산  $\Psi_Y$

$\{\bar{U}^{(n)} \in R^{I_n \times P_n}, n = 1, \dots, N\}$ 을 최대화 하는  $N$ 개의 투영 행렬은 아래와 같다[20-21].

$$\{\bar{U}^{(n)}, n = 1, \dots, N\} = \operatorname{argmax}_{\tilde{U}^{(1)}, \tilde{U}^{(2)}, \dots, \tilde{U}^{(N)}} \Psi_Y \quad (15)$$

다선형 판별 분석의 실행은 다선형 주성분 분석을 통해 차원 축소를 한 후 다선형 판별 분석의 공간 투영을 통해 인식률을 계산한다. 그림 5는 다선형 판별 분석의 전체 과정을 나타내며 표현식은 아래와 같다.

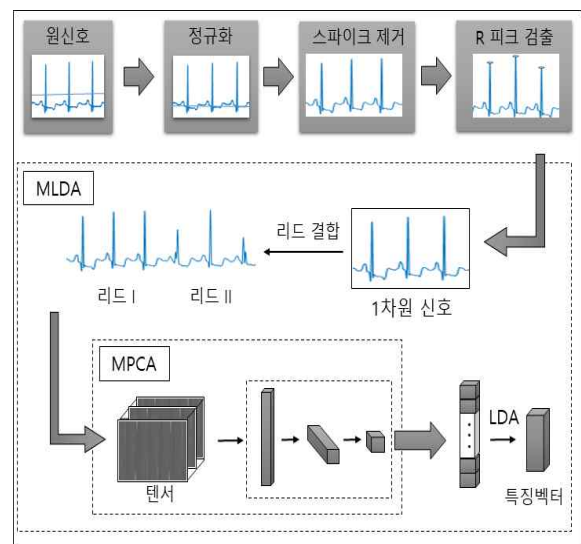


그림 5. MLDA 과정의 개략도

학습표본은  $\{X_i \in R^{m_1 \times m_2 \times \dots \times m_n}, i = 1, \dots, N\}$ 로 n차 텐서로 표현 할 수 있으며,  $X_i$ 는  $c_i \in \{1, 2, \dots, N_c\}$ 로 된 클래스에 속한다고 가정하고 결과적으로 (n+1)차 텐서  $\tilde{X} \in R^{m_1 \times m_2 \times \dots \times m_n \times N}$ 으로 나타낼 수 있다.

같은 차원의 두 개의 텐서 A와 B의 내적을 아래와 같이 정의 할 수 있다.

$$\langle A, B \rangle = \sum_{i_1=1, \dots, i_n=1}^{m_1, \dots, m_n} A_{i_1, \dots, i_n} B_{i_1, \dots, i_n} \quad (16)$$

텐서 A의 놈(norm)은  $\|A\| = \sqrt{\langle A, A \rangle}$ 로 정의되며, 텐서 A와 B 사이의 거리는  $D(A, B) = \|A - B\|$ 로 정의된다. 2차 텐서의 경우는 프로베니우스 놈(Frobenius Norm)은  $\|A\|_F$ 로 정의되며, k-mode의 곱은  $B = A \times_k U$ 로 정의된다. k-mode의 최적화를 위해 텐서의 한 방향에서만 목적함수를 최적화 하는 식은 아래와 같다.

$$(U_k^*) = \operatorname{argmax}_C \frac{\sum_c n_c \|\bar{X}_c \times_k U_k - \bar{X} \times_k U_k\|^2}{\sum_i \|X_i \times_k U_k - \bar{X}_{c_i} \times_k U_k\|^2} \quad (17)$$

k-mode의 최적화 후 선형 판별 분석 기법을 적용하여 식 (18)번과 같이 재구성 한다.

$$U_k^* = \operatorname{argmax} \frac{\operatorname{Tr}(U_k^T S_B U_k)}{\operatorname{Tr}(U_k^T S_W U_k)} \quad (18)$$

클래스 간 분산 행렬과 클래스 내의 분산 행렬을 계산 하는 식은 아래와 같이 정의 할 수 있다.

$$S_B = \sum_{j=1}^{\prod_{0 \neq k} m_0} S_B^j, S_B^j = \sum_{c=1}^{N_c} (\bar{X}_c^{k,j} - \bar{X}^{k,j}) (\bar{X}_c^{k,j} - \bar{X}^{k,j})^T \quad (19)$$

$$S_W = \sum_{j=1}^{\prod_{0 \neq k} m_0} S_W^j, S_W^j = \sum_{i=1}^N (X_i^{k,j} - \bar{X}_{c_i}^{k,j}) (\bar{X}_i^{k,j} - \bar{X}_{c_i}^{k,j})^T \quad (20)$$

$X_i^{k,j}$ 는 텐서  $X_i$ 로부터 k-mode 전개되지 않은 행렬인 행렬  $X_i^k$ 의 j번째 열벡터를 나타내고,  $\bar{X}_c^{k,j}$ 와  $\bar{X}^{k,j}$ 는  $X^{k,j}$ 와 같은 방식으로  $\bar{X}_c$ 와  $\bar{X}$ 에 대해 정의된다.

$$S_B U_k^t = S_W U_k^t, U_k^t \in R^{m_k \times m'_k} \quad (21)$$

$$U_k = U_k^t \in R^{m_k \times m'_k} \quad (22)$$

k-mode의 최적화 후의 클래스 간 분산 행렬과 클래스 내의 분산 행렬을 식 (21)로 계산하고 식 (22)을 통해 투영된 결과를 얻을 수 있다[13]. mode를 최적화하여 다선형 판별 분석의 과정을 통해 결과를 얻는 절차는 아래 그림 6과 같다.

**MLDA :**

Input :  $\{X_i \in R^{m_1 \times m_2 \times \dots \times m_n}, i = 1, \dots, N\}$

1. Initialize

$$U_1^0 = I_{m_1}, U_2^0 = I_{m_2}, \dots, U_n^0 = I_{m_n};$$

2. For  $t = 1, 2, \dots, T_{\max}$  do

a) For  $k = 1, 2, \dots, n$  do

$$Y_i = X_i \times_1 U_1^t \dots \times_{k-1} U_{k-1}^t \times_{k+1} U_{k+1}^{t-1} \dots \times_n U_n^{t-1}$$

$$S_B = \sum_{j=1}^{\prod_{0 \neq k} m_0} S_B^j, S_B^j = \sum_{c=1}^{N_c} (\bar{Y}_c^{k,j} - \bar{Y}^{k,j}) (\bar{Y}_c^{k,j} - \bar{Y}^{k,j})^T$$

$$S_W = \sum_{j=1}^{\prod_{0 \neq k} m_0} S_W^j, S_W^j = \sum_{i=1}^N (Y_i^{k,j} - \bar{Y}_{c_i}^{k,j}) (\bar{Y}_i^{k,j} - \bar{Y}_{c_i}^{k,j})^T$$

$$S_B U_k^t = S_W U_k^t, U_k^t \in R^{m_k \times m'_k}$$

b) If  $t > 2$  and  $\|U_k^t - U_k^{t-1}\| < m'_k m_k$ ,

$k = 1, \dots, n$ , break;

3. Output :  $U_k = U_k^t \in R^{m_k \times m'_k}, k = 1, \dots, n$

그림 6. 다중 선형 판별 분석의 절차

**3. 특징 분류**

특징 분류를 위해 일반적으로 가장 많이 사용되는 N차원의 공간에서 두 점간의 거리를 알아내는 유클리디안 거리(L2)를 사용하여 벡터 공간인 선형 공간에서의 최단거리를 구하여 특징벡터간 유사도를 통해 특징을 분류하였다. 유클리디안 거리를 계산하는 식은 다음과 같이 나타낼 수 있다.

$$L_2 = \sqrt{\sum_{h=1}^n (|a(h) - b(h)|)^2} \quad (23)$$

## IV. 실험 및 결과

### 1. 심전도 데이터베이스

본 실험에서는 사용한 심전도 데이터는 PhysioNet의 MIT-BIH 부정맥 데이터베이스를 사용하였다. MIT-BIH 부정맥 데이터는 2개 리드 심전도 레코드를 포함하는 48개의 파트가 포함되어 있다. 다양한 연령의 입원환자 및 외래환자 남자 25명, 여자 22명인 총 47명으로부터 측정되었고, 심전도 기록은 48시간의 시간을 두고 기록되었다. 이 데이터베이스의 기록은 채널당 초당 360 샘플링 속도로 10mV 범위의 11비트 해상도로 디지털화 되었다[22-25]. MIT-BIH 데이터베이스 47명의 레코드 중 2개 리드 사용하여 3초간 30개의 샘플링을 하고 데이터를 추출하여 각각 한명 당 20개를 학습으로, 20개를 검증으로 사용한다. 전체 47명으로 사람당 20개의 데이터를 가지기 때문에 전체 학습 및 검증 데이터 수는 각각 940개이다.

다선형 판별 분석은 3차원의 텐서를 입력으로 적용하여 처리해야하기 때문에 1차원 벡터를 3차원의 텐서로 변경하여 입력한다. 3차원 텐서로 데이터를 만들기 위해 1차원 벡터를 재정렬하여 3차원 텐서로 구성한다. 진처리 과정을 통해 신호를 정규화 시킨 후 스파이크를 제거하고 R피크를 검출하여 얻어진 프레임은 앞 뒤 400프레임에 대해 2개 리드를 사용하기 때문에 두 번 처리 하면 801개의 총 1602프레임을 얻고 2프레임을 삭제하여 텐서 데이터를 구성하였다. 얻어진 학습 데이터와 검증 데이터는 940×1602으로 구성되며 구성된 3차원 텐서 데이터는 4개로 묶어서 구성하여 수행하였다. 1602개의 데이터에서 4개씩 묶어 구성하면 40×40×4×235이며 학습 데이터의 수는 235개이다. 다선형 판별 분석에서 다선형 주성분 분석의 기능의 특징차원은 선형 판별분석을 위한 값으로 150으로 설정하였으며 보존 에너지인 Q값은 97, 반복의 최대 수는 1로 설정하여 실험을 진행 하였다. 그림 7은 클래스의 수 - 1개까지의 판별 특징 벡터수를 증가해가며 실험을 수행하였으며 0부터 150까지 수행하였을 때의 인식률을 보여준다. 그림 8은 PCA와 LDA에 고유 벡터수를 1부터 100까지 1개씩 증가해 가면서 인식률 실험을 수행한 것을 보여주며 각 실험의 유사도 측정은 L2를 이용하였다. 표 1은 PCA, LDA, MLDA의 인식률을 나타내며 PCA의 인식률은 평균 76.7%, 최고 인식률은 78.9%를 보였으며 LDA의 평균 인식률은 81%, 최고 인식률은 86.1%를 보였다. MLDA의 인식률은 평균 93.5%, 최고 인식률은 97.4%이다. MLDA의 인식률 성능은 PCA, LDA의 성능에 비해 18.5%, 11.3% 향상됨을 확인하였다.

## V. 결론 및 향후 과제

본 논문에서는 MLDA방법을 통해 다차원 데이터 배열인 텐

서 특성을 이용하여 기존의 차원 축소 방법인 PCA, LDA보다 더 높은 차원의 특성 공간에서 심전도 신호의 향상된 개인 식별의 인식률에 대해 기존 PCA, LDA와 MLDA의 성능 비교 실험을 하였다. MLDA는 데이터의 클래스 수에 따라 차원이 제한되지 않으며 더 많은 차원을 사용하여 계산을 할 수 있고 더 작은 크기의 공간에서 수행할 수 있어 빅 데이터에서 효율적으로 사용될 수 있지만 LDA를 위해 선택된 주요 구성 요소의 수에 따라 성능에 영향을 받습니다. 즉, MPCA 특징값에 따른 LDA에 공급되는 주요 구성 요소의 수에 따라 성능의 차이를 보일 수 있습니다. 실험 결과를 통해 MLDA는 PCA, LDA보다 데이터의 구조를 잘 보존하며 같은 양의 데이터로 작은 샘플 크기 문제가 발생하지 않기 때문에 기존 방법보다 낮은 차원의 텐서 데이터 최적화를 통해 효율적이며 효과적으로 처리하기 때문에 기존 방법 보다 우수한 방법임을 알 수 있다.

본 연구를 통해 얼굴인식, 걸음새 인식 등에서 사용된 MLDA를 심전도 개인 식별 연구에 적용하여 효과적인 인식률과 성능 분석에 대해서도 적용 할 수 있는 것을 확인 할 수 있었다.

향후 MIT-BIH 부정맥 데이터베이스 이외의 PTB 진단 데이터베이스를 통해 심전도 1차원 벡터 신호를 웨이블릿 방법을 이용한 2차원 이미지 scalogram으로 구성하고 이를 다시 3차원 텐서로 재구성하여 MPCA, MLDA를 통해 개인 식별 성능 분석에 대한 연구할 예정이다.

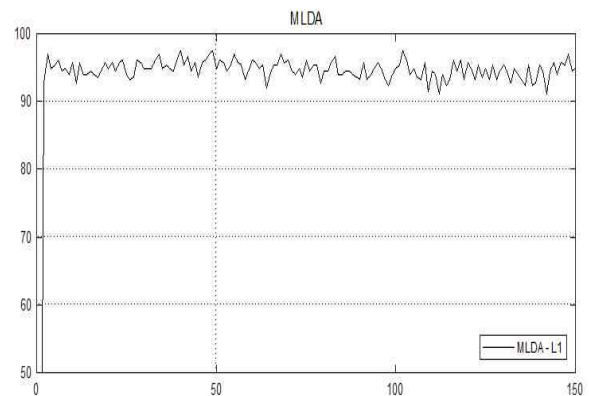


그림 7. MLDA 인식률

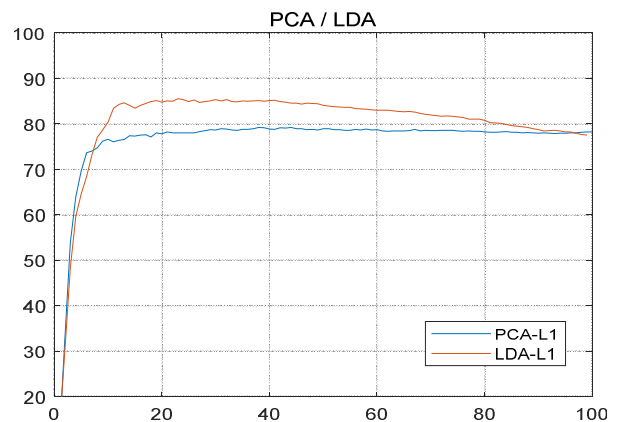


그림 8. PCA, LDA 인식률



표 1. MLDA와 PCA, LDA의 인식률

특징추출 방법	유사도	인식률 (%)
PCA	L2	78.9 %
LDA		86.1 %
MLDA		97.4 %

## REFERENCES

- [1] S. Gutta, Q. Cheng, "Joint Feature Extraction and Classifier Design for ECG-Based Biometric Recognition," *IEEE Journal of Biomedical and Health Informatics*, vol. 20, no. 2, pp. 460-468, 2015.
- [2] S. I. Safie, J. J. Soraghan, L. Petropoulakis, "ECG biometric authentication using Pulse Active Width (PAW)," *Biometric Measurements and Systems for Security and Medical Applications(BIOMS)*, pp. 1-6, Nov. 2011.
- [3] S. Y. Kim, S. J. Kim, I. J. Joe, "Enhanced Password Based User Authentication Mechanism Using Mobile Storage Medium/Channel," *Journal of the Korea Contents Association*, vol. 6, no.1, pp. 144-151, Jan. 2006.
- [4] 조주희, 조병준, 이대중, 진명근, "주성분 분석기법을 이용한 심전도 기반 개인인증," *전기학회논문지*, 제66권, 제4호, 258-262쪽, 2017년 12월
- [5] F. G. S. Teodoro, S. M. Peres. C. A. M. Lima, "Feature selection for biometric recognition based on electrocardiogram signals," *2017 International Joint Conference on Neural Networks(IJCNN)*, pp.14-19, May 2017.
- [6] J. J. Wu, Y. Zhang, "ECG identification based on neural networks," *2014 11th International Computer Conference on Wavelet Active Media Technology and Information Processing(ICCWAMTIP)*, pp. 92-96, Dec. 2014.
- [7] I. Daubechies, "The wavelet transform, time-frequency localization and signal analysis," *IEEE Transactions on Information Theory*, vol. 36, no. 5, pp. 961-1005, 1990.
- [8] H. Abdi, L. J. Williams, "Principal component analysis," *WIREs Computational Statistics*, vol. 2, no. 4, pp. 433-459, 2010.
- [9] T. Alaaa, G. Tarekc, I. Abdelhameed, H. A. Ellae, "Linear discriminant analysis: A detailed tutorial," *AI Communications*, vol. 30, no. 2, pp. 169-190, 2017.
- [10] JG. Dy, CE, Brodley, "Feature Selection for Unsupervised Learning," *Journal of Machine Learning Research*, vol. 5, pp.845 - 889, 2004.
- [11] R. R. Perez, A. Marques, F. Mohammadi, "The application of supervised learning through feed-forward neural networks for ECG signal classification," *Electrical and Computer Engineering*, pp. 15-18, 2016.
- [12] 오강한, 김수형, 나인섭, 김영철, 문창협, "스마트 장치에서 비접촉식 전위계차 센서 신호를 이용한 동작 인식 기법," *스마트미디어저널*, 제3권, 제2호, 14-19쪽, 2014년 6월
- [13] H. Lu, K. N. Plataniotis, A. N. Venetsanopoulos, "A survey of multilinear subspace learning for tensor data," *Pattern Recognition*, vol. 44, no. 7, pp. 1540-1551, 2011.
- [14] H. Lu, K. N. Plataniotis, A.N. Venetsanopoulos, "Boosting LDA with Regularization on MPCA atures for Gait Recognition," *2007 Biometrics Symposium*, pp. 1-6, Sept. 2017.
- [15] S. M. Hosseyninia, F. Roosta, A. A. S. Baboli. G. R. Rad, "Improving the performance of MPCA+MDA for face recognition," *2011 19th Iranian Conference on Electrical Engineering*, pp.17-19, May 2011.
- [16] S. Yan, D. Xu, Q. Yang, L. Zhang, X. Tang, H. J. Zhang, "Multilinear Discriminant Analysis for Face Recognition," *IEEE Transactions on Image Processing*, vol. 16, no. 1, pp. 212-220, 2007.
- [17] 문해민, 박진원, 반성범, "역전과가 제거된 CNN과 LDA를 이용한 얼굴 영상 해상도별 얼굴 인식률 분석, LDA, CNN," *스마트미디어저널*, 제5권, 제1호, 1-6쪽, 2016년 3월
- [18] P. Comon, "Independent component analysis, A new concept?," *Signal Processing*, vol. 36, no. 3, pp. 287-314, 1994.
- [19] S. Ji, J. Ye, "Generalized Linear Discriminant Analysis: A Unified Framework and Efficient Model Selection," *IEEE Transactions on Neural Networks*, vol. 19, no. 10, pp. 1768-1782, 2008.
- [20] J. Huang, K. Su, J. El-Den, T. Hu, J. Li, "An MPCA/LDA Based Dimensionality Reduction Algorithm for Face Recognition," *Mathematical Problems in Engineering*, pp. 1-12, 2014.
- [21] H. Lu ; K. N. Plataniotis, A. N. Venetsanopoulos, "MPCA: Multilinear Principal Component Analysis of Tensor Objects," *IEEE Transactions on Neural Networks*, vol. 19, no. 1, pp. 18-39, 2008.
- [22] G.B. Moody. R.G. Mark, "The impact of the MIT-BIH Arrhythmia Database," *IEEE*



*Engineering in Medicine and Biology Magazine*, vol. 20, no. 3, pp. 45-50, May-June, 2001.

- [23] Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng C-K, Stanley HE. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* 101(23):e215-e220 [Circulation Electronic Pages; <http://circ.ahajournals.org/content/101/23/e215.full>]; 2000 (accessed 11, 07, 2018).
- [24] H. Abbaspour, S. M. Razavi, N. Mehrshad, "Electrocardiogram Based Identification using a New Effective Intelligent Selection of Fused Features," *Journal of Medical Signal and Sensors*, vol. 5, pp. 30-39, 2015.
- [25] M. M. Bassiouni, E. S. A. E. Dahshan, W. Khalefa, A. M. Salem, "Intelligent hybrid approaches for human ECG signals identification," *Signal, Image and Video Processing-Springer*, vol. 12, no. 5, pp. 941-949, 2018.

---

저 자 소 개

---



**임원철(학생회원)**

2017년 조선대학교대학교 전자공학과 학사 졸업.

2017년~현재 조선대학교 소프트웨어융합공학과 석사과정.

<주관심분야 : 심전도 생체인식, 머신러닝, 차원축소>



**곽근창(정회원)**

2002년 충북대학교 전기공학과 공학박사 졸업.

2003년~2005년 캐나다 Alberta대학교 전기 및 컴퓨터공학과, 박사후과정.

2005년~2007년 한국전자통신연구원 지능형로봇연구단 선임연구원

2014년~2015년 미국 캘리포니아 주립대학교 플러튼, 방문교수

2007년~현재 조선대학교 전자공학부 교수.

<주관심분야 : 인간-로봇상호작용, 인체모션분석, 계산지능, 생체인식>