





2019년 2월 석사학위논문

다선형 부분공간 학습방법을 이용한 ECG기반 생체인식

조선대학교 산업기술융합대학원

소프트웨어융합공학과

임 원 철



다선형 부분공간 학습방법을 이용한 ECG기반 생체인식

2019년 2월 25일

조선대학교 산업기술융합대학원

소프트웨어융합공학과

임 원 철





다선형 부분공간 학습방법을 이용한 ECG기반 생체인식

지도교수 곽 근 창

이 논문을 석사학위신청 논문으로 제출함.

2018 년 10월

조선대학교 산업기술융합대학원

소프트웨어융합공학과

임 원 철





임원철의 공학석사학위논문을 인준함 위원장 조선대학교 교수 반성범 위 원 조선대학교 교수 신주현 안 위 원 조선대학교 교수 곽근창

2018년 11월

조선대학교 산업기술융합대학원

Collection @ chosun



목 차

제1장 서론
제2장 관련 연구
제1절 심전도의 특성4
제2절 기존의 차원 축소 기법8
1. 주성분 분석8
2. 선형 판별 분석
제3장 다선형 부분공간 학습방법
제1절 선형 부분공간 학습 및 다선형 부분공간 학습13
1. 선형 부분공간 학습
2. 다선형 부분공간 학습14
제2절 다선형 주성분 분석16
제3절 다선형 판별 분석
제4절 전처리 과정 및 특징 분류
1. 전처리 과정
2. 특징 분류
제4장 실험 방법 및 결과 분석
제1절 심전도 데이터베이스
제2절 실험 방법
제3절 결과 분석
제5장 결론
참고문헌

Collection @ chosun



표 목차

표	2-1.	12 리드의 전극 위치 ~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~
표	4-1.	주성분 분석의 유사도별 인식률
표	4-2.	선형 판별 분석의 유사도별 인식률31
표	4-3.	다선형 판별 분석의 유사도별 인식률33
표	4-4.	주성분 분석, 선형 판별 분석, 다선형 판별 분석의 인식률 비교35





그림 목차

그림	2-1.	양극 표준 리드
그림	2-2.	전극의 위치(리드 V1 ~ V6) ~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~
그림	2-3.	심전도의 전기적 활성 단계
그림	2-4.	심전도의 파형
그림	2-5.	임의의 데이터의 주성분 벡터8
그림	2-6.	클래스 간 분산과 클래스 내 분산
그림	2-7.	주성분 분석과 선형 판별 분석의 구성도
그림	3-1.	선형 부분공간 학습과 다선형 부분공간 학습 방법의 비교15
그림	3-2.	텐서 데이터의 차원 감소 방법
그림	3-3.	n-mode의 표현
그림	3-4.	각 n-mode별 투영 과정18
그림	3-5.	1-mode 투영19
그림	3-6.	다선형 판별 분석의 구성도
그림	3-7.	다선형 판별 분석의 과정
그림	3-8.	심전도 신호의 전처리
그림	4-1.	실험에서 사용된 심전도 신호(Grid intervals: 0.2sec, 0.5mV)29
그림	4-2.	주성분 분석의 고유벡터에 대한 인식률31
그림	4-3.	선형 판별 분석의 고유벡터에 대한 인식률32
그림	4-4.	다선형 판별 분석의 특징차원의 수에 대한 인식률





ABSTRACT

ECG-based biometrics using multiliner subspace learning approach

Won-Cheol Lim Advisor : Prof. Keun-Chang Kwak, Ph. D. Department of Software Convergence Engineering Graduate School of Industry Technology Convergence, Chosun University

Biometric techniques using biometric information such as fingerprints, faces, and iris are widely used in everyday life. Biometrics using physical features are dangerous because of counterfeiting and tampering. Biological signals using electrical bio-signals are highly secure. In recent years, we are actively studying bio-signals using electrical bio-signals.

In this paper, we analyze the performance of biometrics using multilinear subspace learning from electrocardiogram information. We compare the performance using MPCA, MLDA in order to demonstrate superior performance over the existing subspace learning techniques such as principal component analysis and linear discriminant analysis. We confirmed that 97% recognition rate is obtained when applying the multilinear subspace learning by applying Physionet's MIT-BIH database.







제1장 서론

최근 개인 식별 방법 개발에 대한 요구가 늘어나고 있으며 신뢰할 수 있는 개 인 식별 방법의 새로운 접근 방법 중 하나는 생체인식이다. 생체인식은 인간의 고 유한 특성과 이 특성을 기반으로 사람을 식별하거나 인증하는 프로세스를 말한다 [1]. 생체인식 기술은 개인의 고유한 특징을 통해 당사자만을 인식하기 위해 이용 되는 기술이다. 생체인식을 위해 사용될 정보는 사람마다 고유하며, 변화시키기 어렵고, 정보 수집을 위한 정량화가 쉬운 특징을 가지고 있어야 하며 일반적으로 사용되는 생체부분은 지문, 얼굴, 음성, 정맥, 홍채인식, DNA, 귀 등을 사용하며 일반적으로 지문, 얼굴, 음성, 홍채인식을 통한 생체인식이 사용되고 있다. 지문 인식은 낮은 오류와 비교적 높은 인식률, 빠른 검증속도, 간단하게 측정할 수 있 지만 지문 손상, 잘리거나 굳은 피부의 손가락은 사용에 어려움이 따른다.

얼굴인식의 경우 특별한 행위나 동작을 요구하지 않고도 인식할 수 있으며 원 거리에서 측정이 가능하지만 조명의 변화 및 영상의 각도에 민감하고 변장이나 나 이가 들면서 얼굴의 변화, 성형수술 등의 문제로 인식률이 낮은 편이다. 음성인식 은 별도의 학습이 없어도 쉽게 사용가능하며 원격인증이 가능하지만 같은 사용자 라도 잡음에 따른 인식률 차이, 도용한 음성이 인식 되는 문제가 발생한다. 정맥 인식은 지문, 손가락이 없어도 사용할 수 있으며 외상에 따른 변형이 적고 복제가 불가능한 점이 있지만, 시스템의 크기가 크고 구축비용이 높은 문제가 있다. 마지 막으로 홍채인식은 복제가 불가능하고 렌즈나 안경을 착용하여도 인식이 가능하며 고유 패턴이 존재하여 인식률이 높은 점이 있지만 기계에 접촉하지는 않으나 인식 을 위해 얼굴 근접으로 거부감이 발생할 수 있으며 구축비용이 높다는 단점이 존 재한다[2].

이와 같이 생체정보를 이용한 지문, 얼굴, 목소리, 정맥 그리고 홍채 등은 여 러 장점들이 존재하지만 생체를 감지할 수 없는 문제가 있다. 즉, 생체정보를 이 용한 시스템이 생체정보를 정확히 인식한다고 해도 인식된 당사자가 실제로 있는 지 보장하기 어렵다. 기존의 생체인식 기술의 위변조가 취약한 실제 사례를 보면 2013년 아이폰의 화면에서 지문을 채취해 프린트한 후 손가락에 시트를 붙이고 잠 금을 해제한 사례와 사람의 얼굴을 촬영해 프린트하고 눈 부분에 콘택트렌즈를 올 려놓는 것만으로 홍채인식 스캐너를 통과한 사례 등을 통해 생체정보가 위변조에

- 1 -

취약하다는 것을 알 수 있다. 실제 사례를 통해 기존의 생체인식 기술이 쉽게 위 변조를 할 수 있기 때문에 생체인식 기술에 대한 신뢰성이 떨어진다. 기존의 생체 인식 기술에서 사용되는 신뢰성이 떨어지는 생체 정보를 대체하기 위해 심전도를 이용한 생체인식 방법이 제안되고 있다. 심전도는 심장의 전기적 전위를 측정하고 기록하는 방법이며 개인의 생체에서 고유한 심박패턴을 획득하여 이용하기 때문에 위변조하기가 어렵다. 즉, 기존의 일반적으로 사용되는 홍채인식, 지문인식, 음성 인식 등을 통한 개인 식별 방법 보다 개인만의 고유한 심장의 박동의 특징을 이용 하여 개인 식별을 할 수 있기 때문에 타인이 접근하기 어렵기 때문에 생체인식 기 술에 적용할 수 있다[3-5].

심전도를 이용한 생체인식을 위해 심전도 신호는 P, Q, R, S, T 파의 정확한 측정이 필요하며 이를 위해 전처리 과정을 거쳐 유용한 특징만을 사용하기 위해 특징 추출하여 신호를 분석한다. 심전도가 생체인식 기술에 적용되어 개인 식별의 타당성을 입증하기 위해 L.Biel[6]등은 SIEMENS ECG 장치를 통해 심전도를 얻어 P, Q, R, S, T파 및 ST간격에서의 진폭과 영역 등을 포함하는 여러 형태학적 특징 을 주성분 분석(PCA, Principal Component Analysis)을 통해 특징 추출하여 테스 트 객체와 클래스 간 유사성을 발견하는 SIMCA 모델 분류에 의한 개인 식별을 제 안했다. Shen[7]은 지문과 같은 2차원 생체인식과 달리 1리드 심전도의 1차원 저 주파 신호로 손에 전극에서 기록하여 개인 식별을 구현하기 위해 템플릿 매칭과 의사결정 기반 신경망(decision-based neural network) 두 가지 기법을 결합하여 좋은 성능을 보였다. M. Kyoso[8]은 2차 미분의 파형에 나타나는 특징점을 사용하 여 추출된 심전도 파형의 간격 및 지속 시간으로부터 샘플링하여 판별분석 (discriminant analysis)을 사용하여 정확도를 검증했다.

심전도 데이터를 차원축소 기법을 통해 특징 추출을 하여 개인 식별의 성능 비 교를 위해 R. J. Martis[9]는 부정맥의 유형 분석 및 차원축소(Dimensionality Reduction)를 위해 주성분 분석, 선형 판별 분석과 독립성분 분석을 수행하고 이 산 웨이블릿 변환을 통해 하위 대역에서 독립적으로 적용하고 서포트 벡터 머신 (Support Vector Machine), 신경망(Neural Network) 및 확률신경회로망 (Probabilistic Neural Network)분류기를 사용하여 성능 비교 및 정확도를 측정했 다[10-15].

심전도의 인식률 성능을 비교하기 위해 E. D. A. Botter[16]등은 심전도 신호 에서 P파의 특징 추출기로 비대칭 기초함수를 갖는 신경 네트워크를 사용하여 인

- 2 -





식률의 성능을 비교하여 제안하였고, J. Hwan[17]등은 심전도 신호에서 딥 러닝 (Deep Learning)모델인 역전오류전파(Back Propagation), 인공신경망(Artificial Neural Network)을 적용하여 비정상적인 파형을 평가하였다. 딥 러닝은 많은 양의 데이터가 필요하며 데이터의 양이 많을수록 더 좋은 성능을 낼 수 있으며 고사양 의 하드웨어가 필요하다. 본 실험에서 딥 러닝을 통해 실험을 수행하기에는 데이 터의 크기가 크지 않으며 그래픽카드, CPU등의 하드웨어 사양의 성능이 낮기 때문 에 적합하지 않다.

본 연구에서는 심전도를 이용하여 기존의 차원 축소 방법의 개인 식별 인식률 과 제안하는 방법의 인식률을 비교하여 효율성과 타당성을 검증한다. 제안하는 방 법은 다선형 부분공간 학습을 이용한 차원 축소에 대한 접근 방법이며 심전도 신 호는 전처리 과정을 거쳐 잡음을 제거 한 후 2 리드를 결합한다. 리드 신호들의 결합은 튀는 신호나 불안정한 신호의 효과적인 인식을 위해 시퀀스 형태로 나타낸 다. 결합된 신호를 텐서 데이터로 다시 구성하여 다선형 주성분 분석을 이용하여 얻은 최적화된 값을 선형 판별 분석을 통해 특징벡터를 얻어 인식률의 성능을 나 타낸다.

본 논문에서는 표준 데이터베이스인 MIT-BIH 부정맥 데이터베이스를 다선형 판 별 분석에 적용하여 텐서 기반 특징 추출을 및 다선형 투영을 통해 인식률을 나타 낸다. 주성분 분석에서 고유벡터의 수에 따른 인식률은 79.48%의 성능을 보였고 선형 판별 분석에서의 인식률은 87.91%의 성능을 보였다. 위의 기법들의 인식률 성능과 비교하기 위해 다선형 판별 분석에서 특징차원의 수에 따른 인식률은 97.87%의 성능을 보여 주었으며, 한 명당 인식되는 시간은 클래스마다 약 0.5ms에 서 0.12ms사이의 시간을 갖는 것을 확인하였다.

본 논문의 구성으로 2장에서는 심전도에 대한 설명과 주성분 분석, 선형 판별 분석 기법에 대해 설명한다. 3장은 제안하는 방법으로 텐서 기반의 다선형 부분공 간을 활용한 다선형 주성분 분석, 다선형 판별 분석과 전처리 과정 및 특징분류에 대해 설명하고, 4장에서는 실험에 사용된 심전도 데이터베이스와 실험 결과 및 분 석을 하며 마지막 5장에서는 실험 결과에 따른 향후 연구방향 및 결론으로 마무리 한다.





제2장 관련 연구

제1절 심전도의 특성

심전도는 심장의 수축에 따라 심장박동과 함께 동반하는 전위차를 신체표면을 통해 기록한 것이다. 즉 심방과 심실의 탈분극과 재분극에 의해 발생된 전기적 활 동이다. 심장의 수축을 일으키는 원동력인 심방의 동방결절에서 생기는 미세한 전 류의 크기와 방향을 그래프로 나타낸 기록이다. 심전도의 기록하는 장치는 심전도 계(Electrocardiography)이며, 장치를 통해 얻은 기록이 심전도(ECG, Electrocardiogram)이다. 심전도는 일반적으로 심장질환의 문제인 부정맥, 심근 경색 등을 진단하기 위해 사용되며 그 이외에도 감정, 정적 및 동적 상태의 스트 레스를 받는 상황에서 심전도를 측정하여 연구가 되고 있으며, 또한 심전도를 이 용하여 개인 식별을 위해 생체인식에 사용이 되고 있다[18].

심전도의 측정은 일반적으로 12 리드를 사용하여 기록되며 표 2-1은 신체에서 12 리드의 전극 위치를 나타낸다.

리드	전극 위치
I	왼손, 오른손
П	왼발, 오른손
III	왼발, 왼손
aVR	오른손
aVL	왼손
aVF	왼발
V1	제 4늑간 흉골 우측 위치
V2	제 4늑간 흉골 좌측 가장자리
V3	V2와 V4의 중간위치
V4	제 5늑간과 좌측 쇄골중앙선이 만나는 위치
V5	V4와 같이 수평이 되는 전액와부위
V6	V4와 같이 수평이 되는 액와 중앙선부위

표 2-1. 12 리드의 전극 위치



12 리드는 양극 표준 리드와 단극 사지리드로 나눌 수 있다. 양극 표준 리드는 리드 I, 리드 II, 리드 III이 포함되며 전극을 오른손, 왼손, 왼발에 연결 한 후 심 전도를 기록하고 오른발에 부착한 전극은 접지로 사용되고 리드 I은 왼손과 오른 손의 전위차이며 리드 II는 오른손과 왼발의 전위차, 리드 III은 왼발과 왼손의 전위 차를 통해 기록된다. 단극사지 리드는 aVR, aVL, aVF이 포함되며 전극을 오른손, 왼손, 왼발에 연결하여 기록하며 이 심전도의 파형의 크기가 작게 기록되기 때문 에 1.5배 증폭한 aVR, aVL, aVF를 사용하며 그림 2-1은 양극 표준 리드인 리드 I, 리드 II, 리드 III의 전극 위치를 나타낸다[19].

그림 2-2는 신체에서 흉부 리드 각각의 전극 위치를 보여주며 아래 그림과 같 이 흉부 리드는 심장에 가까운 부위에서 심전도를 기록할 수 있으며 V1, V2, V3, V4, V5, V6을 포함한다[20].



그림 2-1. 양극 표준 리드







그림 2-2. 전극의 위치(리드 V1 ~ V6)

심전도의 전기적 활성 단계는 심방 탈분극, 심실 탈분극, 심실 재분극 시기로 나눠지며 각 단계는 아래 그림 2-3과 같이 크게 P파, QRS 복합파형, T파의 형태로 나타낼 수 있다.



그림 2-3. 심전도의 전기적 활성 단계

심전도는 심박동의 한 주기가 지나는 동안에 P파, QRS복합파, T파가 차례로 나 타난다. 그림 2-4는 심전도의 한 주기의 전제척인 파형을 나타내며 각 파형의 의 미는 다음과 같다.





- (1) P 파 : 심박동 한 주기에서 처음 나타나는 P파는 심방탈분극시 나타나는 파형으로 오른쪽에서 왼쪽 방향 및 아랫방향으로의 전기적 자극의 전도를 통해 발생한다. 정상적인 P 파는 QRS 복합파형의 앞에 위치하며 2 ~ 3mm 정도의 높이로 나타나며 0.006 ~ 0.12초 동안 지속된다.
- (2) PR 구간 : P 파 다음으로 나오는 PR 간격은 심방과 심실의 수축 전도 시간 을 나타낸다.
- (3) QRS 복합파형 : QRS 복합파형 구간은 심실의 탈분극을 의미하는 것으로, 전기 자극이 없을 때를 나타내는 파형으로 Q파, R파, S파로 구성되어 나 타난다.
- (3) ST 구간 : ST 구간은 재탈분극의 시작점에서 나타나며 정상적인 ST 구간은 S파부터 T파의 시작점까지 연장된다.
- (4) T 파 : T파는 심실 탈분극때 나타나는 파형으로 절대적 및 상대적 불응기 라는 두 개의 구간에서 발생한다.
- (5) QT 구간 : QRS 복합파형에서 시작하여 T파의 끝부분까지를 나타낸다.



그림 2-4. 심전도의 파형

Collection @ chosun



제2절 기존의 차원 축소 기법

1. 주성분 분석(PCA : Principal Component Analysis)

주성분 분석은 데이터의 분산을 최대한 보존하면서 서로 직교하는 기저(축)를 찾아 고차원 공간의 표본들을 선형 연관성이 없는 저차원 공간으로 변환하는 기법 이다. 고차원 데이터에서 최대 분산의 방향을 찾고 새로운 부분공간에 원래보다 작은 차원으로 투영하는 것이다. 여기서 주성분 분석은 데이터 각각의 성분을 분 석하는 것이 아닌 여러 데이터들이 모여 하나의 분포를 이룰 때 이 분포의 주성분 을 분석해 주는 방법이며 주성분은 그 방향으로 데이터들의 분산이 가장 큰 방향 벡터를 의미한다. 그림 2-5는 2차원 데이터를 투영하며 하나의 주성분을 새로운 기저로 선형 변환된 것을 볼 수 있다. 대각선 축이 원 데이터가 가장 많이 흩뿌려 져 있는 기저를 가지며 차원 수만큼 주성분이 존재한다. PCA의 목적은 이러한 축 을 찾는데 있다. 첫 번째 주성분(PC1)은 가장 길게, 가장 퍼져있는 방향의 축. 즉, 그래프에서 가장 긴 선을 나타내며 두 번째 주성분(PC2)은 첫 번째 주성분이 아닌 축 중에서 가장 분산이 큰 축을 나타낸다.



그림 2-5. 임의의 데이터의 주성분 벡터

주성분 분석의 계산에는 공분산 행렬 계산, 고유값 분해, 고유값을 주성분 분석 의 차원축소를 위한 특징추출과 인식과정은 다음과 같다[21].





단계 1) 측정된 P개의 학습용 심전도 신호에 대한 평균을 구한다.

$$m = \frac{1}{P} \sum_{i=1}^{P} x_i, \ x_i \in \mathbb{R}^{1 \times n}, \ X = [x^1, x^2, \ \cdots, x^P]$$
(1.1)

단계 2) 학습용 심전도 신호에 대한 공분산 행렬을 구한다.

$$\Omega = \overline{XX^{T}}$$

$$\overline{X} = [\overline{x_{1}}, \overline{x_{2}}, \bullet \bullet \bullet, \overline{x_{p}}], \quad \overline{x} = x_{i} - m \qquad (1.3)$$

단계 3) 식 (1.3)을 통해 계산된 공분산행렬 Ω의 고유값 λ와 이에 대응되는 고유벡터 v_i 를 계산한다.

$$\Omega v_i = \lambda_i v_i \tag{1.4}$$

공분산행렬 Ω 에 의해 얻을 수 있는 고유값은 분산 최대치의 방향을 표현하며 고유치에 대응되는 고유벡터 v_i 는 특정한 방향의 변화를 나 타낸다.

단계 4) 심전도 신호 x_i 에 대한 특징벡터는 학습 벡터를 고유벡터 \overline{V} 에 투영시 켜 구한다.

$$\widetilde{x_i} = V^T \overline{x^i}$$
, $\overline{V} = [\overline{v^1}, \overline{v^2}, \cdots, \overline{v^P}]$ (1.5)

단계 5) 인식 할 심전도 신호를 주성분 분석을 통해 특징 추출한다.

$$\overline{y^i} = y^i - m, \quad \widetilde{y^i} = V^T \widetilde{y^i}$$
 (1.6)

단계 6) $\tilde{x^i}$ 과 가장 가까운 $\tilde{y^i}$ 을 구하여 인식값을 구한다.

Collection @ chosun

2. 선형 판별 분석(LDA : Linear Discriminant Analysis)

선형 판별 분석은 특징 공간상에서 클래스 분리를 최대화하는 주축으로 투영시 켜 선형 공간으로 차원을 축소하는 방법이다. 선형 판별 분석에서 클래스 간 분산 (between-class scatter)과 클래스 내 분산(within-class scatter)의 비율을 최대 화 하는 방식으로 데이터에 대한 특징 벡터의 차원을 축소한다. Fisher에 의해서 제안된 방법은 클래스 내(within-class)의 스캐터(scatter)로 정규화한 평균들 간 의 차이로 표현된 함수를 최대화시키는 것이다. 그림 2-6은 클래스 간 분산과 클 래스 내의 분산을 나타낸 것이다. 클래스 간 분산이 클수록, 클래스 내의 분산이 작을수록 판별하기가 좋아진다[22].



그림 2-6. 클래스 간 분산과 클래스 내 분산

선형 판별 분석을 사용한 차원축소를 위한 특징 추출과 인식과정은 다음과 같 다[10].

단계 1) 측정된 P개의 학습용 심전도 신호를 구한다.

$$x^{1}, x^{2}, \cdot \cdot \cdot , x^{p}, m = \frac{1}{p} \sum_{i=0}^{n_{i}} x_{i}$$
 (2.1)





단계 2) i번째 클래스 내의 분산 행렬을 구한다.

$$S_i = \sum_{x \in X_i} (x - m_i)(x - m_i)^T$$
(2.2)

단계 3) 전체 클래스 내의 분산 행렬을 구한다.

$$S_W = \sum_{i=1}^{c} S_i$$
, (S_W 는 클래스 내 분산) (2.3)

단계 4) 클래스 간 분산 행렬을 계산한다.

$$S_B = \sum_{i=1}^{c} n_i (m_i - m) (m_i - m)^T$$
, ($S_B \succeq = 래스 간 분산$) (2.4)

단계 5) 클래스 내의 분산 행렬과 클래스 간 분산 행렬의 비율이 최대가 되는 행렬을 찾는다. C-1개의 0이 아닌 고유치가 존재하며, 따라서 m의 상 한값은 C-1개가 존재한다.

$$W_{opt} = \arg \max \frac{|W^T S_B W|}{|W^T S_W W|} = [w_1, w_2, \cdot \cdot \cdot, w_m] : m 개의 고유백터 \quad (2.5)$$
$$S_B w_i = \lambda_i S_W w_i, \ i = 1, 2, \cdot \cdot \cdot, m \quad (2.6)$$

단계 6) 인식할 심전도 신호에 대해 평균값을 빼준다.

$$\overline{y_i} = y^i - m \tag{2.7}$$

단계 7) 인식대상에 투영한다.

$$\widetilde{y}^{i} = W_{opt} \overline{y}^{i}$$
(2.8)

단계 8) $\tilde{x^i}$ 과 가장 가까운 $\tilde{y^i}$ 을 구하여 인식값을 취한다.

Collection @ chosun

주성분 분석과 선형 판별 분석의 인식률 성능을 얻기 위해 전처리 과정, 특징 추출, 특징 분류를 통해 인식률을 나타낼 수 있다. 그림 2-7은 주성분 분석과 선 형 판별 분석의 구성을 나타낸다.



그림 2-7. 주성분 분석과 선형 판별 분석의 구성도





제3장 다선형 부분공간 학습방법

제1절 선형 부분공간 학습 및 다선형 부분공간 학습

1. 선형 부분공간 학습(LSL : Linear Subspace Learning)

차원 감소는 기본 구조 또는 실제 물리적 현상에 관한 대부분의 정보를 유지하 면서 고차원 데이터를 저차원으로 변환 하는 것이다. 차원 감소에서 고차원의 입 력 공간은 입력 공간의 부분공간인 저차원 출력 공간에서의 학습, 즉 부분공간 학 습을 수행하는 것이다. 저차원의 표현을 잠정적 변수로 간주하여 추정할 수 있으 며 특징 추출 과정 및 저차원 표현을 학습하는 특징으로 볼 수 있다.

기존의 부분공간 학습 알고리즘인 주성분 분석, 선형 판별 분석, 독립 성분 분 석은 벡터에서 동작하는 선형 공간 학습 알고리즘이다. 이 선형 부분공간 학습 방 법은 이미지나 비디오와 같이 1보다 큰 차수의 텐서 데이터에 적용하기 위해서 먼 저 벡터로 텐서를 재구성(벡터화) 해야 한다. 즉 N차원 배열(N>1)을 1차원 배열로 변환해야 한다. 따라서 선형 부분공간 학습은 부분적으로 차원의 저주를 완화시키 지만 재구성(벡터화)는 두 가지의 근본적 한계를 갖는다[23].

- (1) 벡터화는 원래 데이터의 자연스러운 구조와 상관관계를 깨뜨리고 원래 데 이터 집합에 있는 중복성 및 높은 차수 종속성을 줄이고 원본 텐서 형식 에서 얻을 수 있는 보다 작고 유용한 표현이 유실 될 수 있다.
- (2) 비디오 시퀀스와 같은 큰 크기의 고차 텐서 데이터의 경우 재구성된 벡터 는 매우 높은 차원을 갖는다. 이러한 벡터의 분석은 종종 높은 계산 및 메모리의 요구로 이어지며 많은 수의 매개 변수가 추정되기 때문에 작은 표본 크기(small sample size)문제가 발생한다.



2. 다선형 부분공간 학습(MSL : Multilinear Subspace Learning)

다선형 부분공간 학습은 입력 텐서 데이터를 동일하거나 낮은 차수의 저차원 텐서로 직접 변환하는 다선형 매핑을 해결한다. 선형 매핑과 다르게 다선형 매핑 은 텐서를 벡터로 재구성하지 않는다. 텐서 데이터의 선형 매핑에서 각 기준은 많 은 수를 매개변수로 지정된다. 즉, 각 mode에서 차원의 곱과 같은 많은 수의 매개 변수로 지정된다. 대조적으로 동일한 텐서 데이터의 다선형 매핑에서 각각의 기준 은 각 모드에서 차원의 합계와 동일한 매개변수 수에 의해 지정된다. 따라서 선형 매핑의 기본은 큰 자유도를 가지므로 다선형 매핑의 기준이 더 제한적이게 되어 학습된 표현이 더 많은 격자 모양의 구조 또는 규칙성이 더 줄어든다. 이를 통해 다선형 부분공간 학습에서 세가지 핵심 요소를 알 수 있다[24].

- (1) 텐서를 직접 입력으로 매핑하기 전에 데이터 구조를 보존한다.
- (2) 선형 부분공간 학습보다 더 작고 잠재적으로 더 유용한 표현을 얻을 수 있으며 같은 양의 데이터로 다선형 부분공간 학습은 선형 부분공간 학습보다 작은 샘플 크기(small sample size)에 대한 문제가 발생하지 않는다.
- (3) 선형 방법보다 훨씬 낮은 차원의 계산으로 더 큰 텐서 데이터를 보다 효과 적으로 처리 할 수 있다.

그림 3-1는 선형 부분공간 학습 방법과 다선형 부분공간 학습 방법을 비교한 그림이다. (a)는 텐서 데이터를 재형성하고 저차원 벡터에 선형 매핑을 하는 과정 인 선형 부분공간 학습 방법을 나타내고 (b)는 텐서 데이터에서 벡터로 구성하거 나 다른 차원의 저차원 벡터로 직접 다중 선형 매핑을 하여 나타내는 다선형 부분 공간 학습 방법을 나타낸다.







그림 3-1. 선형 부분공간 학습과 다선형 부분공간 학습 방법의 비교

선형 부분공간과 다선형 부분공간 학습을 통해 데이터를 텐서 기반으로 처리할 때 더 효율적인 것을 알 수 있다. 그림 3-2은 2차원 신호의 시퀀스를 나타내며 (a)는 크기가 128×88×20 인 3차원 텐서 데이터에서 벡터화 된 크기는 225280×1 로 표현하여 벡터화 후 공분산 행렬의 크기는 225280×225280로 매우 큰 데이터의 크기가 되어 사용하기에 제한적이 될 수 있지만 (b)의 텐서 데이터는 벡터화 없이 직접 처리되어 128×128, 88×88, 20×20인 세 가지 공분산 행렬을 유도하여 세 공분산 행렬의 전체크기를 줄여 처리할 수 있다. (a)와 동일한 3차원 객체에 대한 텐서 기반 분석이지만 벡터 기반의 처리는 텐서 기반의 처리보다 공분산 행렬에 대해 더 많은 양의 처리가 필요한 것을 알 수 있으며 텐서 기반으로 처리하는 것 이 더 효율적인 것을 알 수 있다.



(a) 벡터화 후 공분산 행렬 유도

- 15 -







3차원 텐서 : 128X88X20 벡터에 대한 통계 분석 (벡터화 하지 않음)

공분산 행렬 크기 : 128x128, 88x88, 20x20 Float형 데이터 (4bytes) : 6.6x10⁴bytes ≈ 64KB +3.3x10⁴bytes ≈ 30.3KB +1.6x10⁴bytes ≈ 1.6KB =9.8x10⁴bytes ≈ 95.8KB

> (b) 벡터화를 제외한 공분산 행렬 유도 그림 3-2. 텐서 데이터의 차원 감소 방법

제2절 다선형 주성분 분석(MPCA : Multilinear Principal Component Analysis)

다선형 주성분 분석(MPCA : Multilinear Principal Component Analysis)은 다 차원 객체에서 특징추출하는 다선형 부분공간 학습방법이다. 이 학습방법은 원래 구조를 유지하며 텐션을 표현하고 대용량 데이터를 처리하는데 유용하다. 다중 선 형에서 사용되는 다차원 데이터 배열인 텐서는 벡터 및 행렬을 고차원 데이터 형식 으로 확장한 것이다. 다차원 데이터 배열인 텐서를 이용하여 고차원 텐서 표현에 서 저차원의 벡터 · 텐서 표현으로 매핑 하는 것에 목적이 있다. 다차원 데이터는 수학의 텐서(Tensor)라고 불리는 다차원 배열로 표현 될 수 있다[25].

텐서들은 A로 표기하고 차원 수 N은 텐서 순서를 표기한다. 텐서 요소는 n개 의 인덱스로 나타내며 각 mode는 지수로 나타내며 그림 3-3과 같이 나타낼 수 있 다. 각 인덱스는 하나의 mode로 정의하며 스칼라는 0차 텐서, 벡터는 1차 텐서, 행렬은 2차 텐서, 3차 이상의 텐서는 고차 텐서라 한다[26]. 일반적으로 3차원은 x축, y축, z축으로 표현되지만 다선형 주성분 분석에서 사용되는 3차원 축은 각각 mode로 표현된다.







그림 3-3. n-mode의 표현

N차 텐서는 다음과 같이 나타 낼 수 있다.

$$A \in \mathbb{R}^{I_1 \times I_2 \times \ldots \times I_N} \tag{3.1}$$

N개의 지수는 i_n 이며, n = 1, • • •, N에서 N개의 인덱스에 의해 어드레싱 되며 각 A의 n-mode를 어드레싱 한다. 텐서 A와 행렬 $U \in R^{J_n \times I_n}$ 의 n-mode 곱은 $A \times_n U$ 으로 나타내며 다음과 같이 표현 한다.

$$(A \times_n U)(i_1, \dots, i_{n-1}, j_n, i_{n+1}, \dots, i_N) = \sum_{i_n} A(i_1, \dots, i_N) \bullet U(j_n, i_n)$$
(3.2)

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

$$\langle A, B \rangle = \sum_{i_1} \sum_{i_2} \cdots \sum_{i_N} A(i_1, i_2, \cdots, i_N) \bullet B(i_1, i_2, \cdots, i_N)$$
 (3.3)

텐서 A의 세트 $[X_{1,}X_{2,}\cdots X_{M}]$ 이 존재할 때 텐서의 객체는 $X_{m} \in R^{I_{1} \times I_{2} \times \cdots \times I_{N}}$ 으로 나타낸다. 이 후 각 텐서는 다음과 같이 펼쳐질 수 있다.

$$A = S \times_1 U^{(1)} \times_2 U^{(2)} \times \cdots \times_N U^{(N)}$$
(3.4)

U(n)은 직교행렬을 나타내고 행렬을 분해한 값을 얻을 수 있다.

- 17 -

Collection @ chosun



$$A_{(n)} = U^{(n)} \bullet S_{(n)} \bullet (U^{(n+1)\otimes} U^{(n+2)} \otimes \cdots \otimes U^{(N)} \otimes U^{(1)} \otimes U^{(2)} \otimes \cdots \otimes U^{(n-1)})^T$$
(3.5)

위의 식에 따라 텐서 부분공간에 텐서 객체를 투영하는 것은 다음과 같다

$$\psi = \chi \times_1 \overline{U}^{(1)^T} \times_2 \overline{U}^{(2)^T} \cdots \times_N \overline{U}^{(N)^T}$$
 (Y는 투영 후 텐서) (3.6)

텐서의 각 mode를 투영하여 최대 분산을 만족하는 저 차원의 텐서를 얻을 수 있으며 그림 3-4는 각 모드별 투영 과정을 나타내고 그림 3-5는 1-mode 벡터 공간 에서 다중 선형 투영 값을 얻는 것을 나타낸다[27].



그림 3-4. 각 n-mode별 투영 과정

- 18 -









그림 3-5. 1-mode 투영

이후 과정은 다음과 같이 나타낼 수 있다. 텐서 객체의 경우 투영 전의 분산을 다음과 같이 나타낸다.

$$arPsi_X = \sum_{m\,=\,1}^M \parallel X_m - \overline{X} \parallel _{F^{'}}^2$$
 ,

$$\overline{X} = \left(\frac{1}{M}\right) \sum_{m=1}^{M} X_{m'} (평 \overline{\mathcal{Z}} \mathbb{E})$$
(3.7)

투영 후의 텐서는 다음과 같이 나타난다.

$$\varPsi_Y = \sum_{m=1}^M \parallel Y_m imes \overline{Y} \parallel_F^2$$
 ,

$$\overline{Y} = \left(\frac{1}{M}\right) \sum_{m=1}^{M} Y_{m}$$
(3.8)

위의 두 식을 결합하여 최적화하여 결과값을 얻을 수 있다.





$$\Psi_{Y} = \sum_{m=1}^{M} \| X_{m} \times \widetilde{U}^{(1)^{T}} \times \widetilde{U}^{(2)^{T}} \times \cdots \times \widetilde{U}^{(N)^{T}} - \overline{x} \times \widetilde{U}^{(1)^{T}} \times \widetilde{U}^{(2)^{T}} \times \cdots \times \widetilde{U}^{(N)^{T}} \|_{F}^{2}$$

$$\therefore \operatorname{argmax} \sum_{m=1}^{M} \| \widetilde{U}^{(n)^{T}} Y_{m}^{(n)} - \widetilde{U}^{(n)^{T}} \overline{Y}^{(n)} \| \qquad (3.9)$$

다선형 주성분 분석은 다차원 객체를 처리 할 수 있으며, 계산을 아래 단계별 로 나타낼 수 있다[28].

단계 1) 샘플 데이터 $x_n \in R^{p_1 \times p_2}, n = 1, \dots, N$ 를 입력한다.

단계 2) 전체 분산 행렬의 고유분해를 얻는다.

단계 3) 고유 벡터와 이에 대응되는 고유값을 계산하여 $\widetilde{U}^{(n)}$ 의 값을 얻는다.

단계 4) 특징행렬을 구하기 위하여 다음 단계를 진행한다.

a) $\tilde{y}_n = \tilde{\boldsymbol{U}}^{(1)^T} \times \tilde{\boldsymbol{x}}_n \times \tilde{\boldsymbol{U}}^{(2)}, n = 1, \dots, N.$ 를 가져온다.

b)
$$\Psi_{Y_0} = \sum_{n=1}^{M} \| \tilde{y}_n \|_{F'}^2 \equiv 계산한다.$$

- c) k = 1 : K 일때
 - i) 모든 분산 행렬의 고유벡터 및 고유값을 계산하고 다음과 같이 결과는 j = 1,2 에 대해 $\widetilde{U}^{(j)}$ 이 출력된다.
 - ii) Ψ_{Y_i} 과 $\tilde{y}_n, n = 1, \dots, N$ 을 얻는다.

단계 5) 다음 식을 통해 특징 행렬을 계산 할 수 있다.

$$\boldsymbol{y}_n = \, \boldsymbol{\widetilde{\boldsymbol{U}}}^{(1)^T} \! \times \boldsymbol{\widetilde{\boldsymbol{x}}}_m \! \times \boldsymbol{\widetilde{\boldsymbol{U}}}^{(2)}, \, n = 1, \, \dots \, , N.$$







제3절 다선형 판별 분석(MLDA: Multilinear Discriminant Analysis)

다중 선형 판별 분석기법은 기존의 방법과 마찬가지로 차원축소의 방법이며 기 존 선형 판별 분석 기법 보다 더 낮은 차원의 특성 공간에서 적용될 수 있기 때문 에 고차 텐서 및 k개의 선형 최적화 접근법을 통해 차원성 딜레마에서 벗어날 수 있다. 기존의 선형 판별 분석 기법은 데이터의 클래스 수에 따라 사용 가능한 차 원이 제한되지만 다선형 판별 분석에서는 더 많은 차원을 사용하여 계산을 할 수 있으며 더 작은 크기의 공간에서 수행될 수 있기 때문에 계산에 따른 비용 측면에 서도 크게 감소 될 수 있다[29-30].

1절의 다선형 주성분 분석은 2차원 데이터를 기반으로 하는 기존의 방법을 무 시하고 벡터 대신 여러 이미지를 고차원 텐서로 통합하고 텐서 공간에서 데이터를 처리한다. 이 접근법은 데이터의 정보를 지속적으로 구성 할 수 있기 때문에 결과 적으로 픽셀 간의 공간 관계를 고려할 때 정확도가 향상된다. 다선형 판별 분석은 부분공간에서 표본을 모으고 인식률을 향상시킬 수 있기 때문에 다선형 주성분 분 석에 의해 처리 된 표본의 크기를 더욱 줄이기 위해 다선형 판별 분석으로 확장시 킬 수 있다. 그림 3-6는 다선형 판별 분석 알고리즘의 구성도를 나타내며 다선형 주성분 분석의 차원 감소를 통해 선형 판별 분석을 이용하여 다선형 투영을 통해 부분공간을 구성하고 최적의 인식률 성능을 얻을 수 있다.



그림 3-6. 다선형 판별 분석의 구성도

Collection @ chosun

다선형 판별 분석은 다선형 주성분 분석에서의 차원 축소를 수행 한 후 선형 판별 분석의 공간 투영을 통해 계산한다. 다선형 판별 분석의 수행 과정은 데이터 에 대한 전처리 과정을 수행하여 얻은 1차원 신호를 다선형 판별 분석에 적용시키 기 위해 1차원 신호 데이터를 3차원으로 재정렬하여 구성하고 이를 다선형 주성분 분석에서 처리하여 선형 판별 분석을 통해 특징벡터를 구하여 수행되며 표현식은 아래와 같이 나타낸다.

학습 샘플은 $\{X_i \in R^{m_1 \times m_2 \times \cdots \times m_n}, i = 1, \dots, N\}$ 로 n차 텐서로 나타낼 수 있으며, $X_i \models c_i \in \{1, 2, \dots, N_c\}$ 의 클래스에 포함 된다고 가정할 때 결과적으로 (n+1)차 텐서는 $\widetilde{X} \in R^{m_1 \times m_2 \cdots \times m_n \times N}$ 으로 표현 할 수 있다. 같은 차원의 두 개의 텐서 A와 B의 내적을 아래와 같이 정의 할 수 있다.

$$\langle A, B \rangle = \sum_{i=1, \dots, i_n=1}^{m_1, \dots, m_n} A_{i_1, \dots, i_n} B_{i_1, \dots, i_n}$$
 (3-10)

텐서 A의 놈(norm)은 ||A|| = √<A,A>로 정의하여 텐서 A와 B 사이의 거 리를 D(A,B) = ||A - B||으로 정의한다. 2차의 텐서와 같은 경우 일 때 프로베니우 스 놈(Frobenius Norm)은 ||A||_F로 정의되며. n-mode의 곱은 B = A×_nU로 정의 할 수 있다. n-mode의 최적화를 위해서 텐서를 한 방향으로 하는 목적 함수를 최 적화 하는 식은 아래와 같다[31].

$$(U_n^*) = \arg\max \frac{\sum_{C} n_c ||\overline{X_c} \times_n U_n - \overline{X} \times_n U_n||^2}{\sum_{i} ||X_i \times_n U_n - \overline{X}_{c_i} \times_n U_n||^2}$$
(3-11)

n-mode를 최적화 한 후 선형 판별 분석을 적용하여 식 (3-12)번과 같이 재구성 한다.

$$U_n^* = \arg\max\frac{Tr(U_n^T S_B U_n)}{Tr(U_n^T S_W U_n)}$$
(3-12)

클래스 간 분산 행렬과 클래스 내의 분산 행렬을 계산 하는 식은 아래와 같이

- 22 -

Collection @ chosun



정의 할 수 있다.

$$S_{B} = \sum_{j=1}^{\prod_{m_{0}}^{m_{0}}} S_{B}^{j}, S_{B}^{j} = \sum_{c=1}^{N_{c}} (\overline{X}_{c}^{n,j} - \overline{X}^{n,j})$$
$$(\overline{X}_{c}^{n,j} - \overline{X}^{n,j})^{T}$$
(3-13)

$$S_{W} = \sum_{j=1}^{\prod_{w \in n} m_{0}} S_{W}^{j}, S_{W}^{j} = \sum_{i=1}^{N} (X_{i}^{n,j} - \overline{X}_{ci}^{n,j})$$
$$(\overline{X}_{i}^{n,j} - \overline{X}_{ci}^{n,j})^{T}$$
(3-14)

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

$$S_B U_n^t = S_W U_n^t, \ U_n^t \in \mathbb{R}^{m_n \times m_n}$$
(3-15)

$$U_n = U_n^t \in R^{m_n \times m_n'} \tag{3-16}$$

n-mode의 최적화 한 후의 클래스 간 분산 행렬과 클래스 내의 분산 행렬을 식 (3-15)로 계산하고 식 (3-16)을 통해 투영된 결과를 얻을 수 있다[32].

그림 3-7은 1차원 신호의 전처리 과정에서부터 다선형 판별 분석의 처리과정을 나타낸다.







그림 3-7. 다선형 판별 분석의 과정

제 3절 전처리 과정 및 특징 분류

1. 전처리 과정

먼저, MIT-BIH 부정맥 데이터를 입력 데이터로 사용하기 위해 데이터의 전처리 를 수행한다. 데이터의 신호의 여러 잡음이나 원치 않는 신호를 제거하기 위하여 500크기의 평균 필터를 통해 정규화를 시킨다. 이 정규화 된 신호에서 안정되지 않은 신호나 스파이크를 제거하는 작업을 하여 스파이크가 제거된 신호에서 R피크 검출을 수행한다. 스파이크를 제거하여 검출된 유효한 신호를 통해 R피크 신호를 기준 전 후 400프레임에 대한 평균을 입력 데이터로 사용한다. 그림 3-8은 전처리 과정에서의 각각의 신호를 나타내며 a는 데이터의 원신호를 나타내며 b는 원신호 에 대해 정규화된 신호, c는 스파이크가 제거 된 신호 그리고 d는 R피크가 검출된 신호를 나타낸다.

















2. 특징 분류

특징 분류를 위해 거리 유사도 측정 기법을 통해 특징 분류를 수행하였다. 유 사도는 객체를 특징 벡터로 표현하는 것으로 시작한다. 특징을 정의하는 공간에서 두 객체가 가까울수록 두 객체는 비슷하다고 볼 수 있다. 거리가 가까우면 유사하 며 거리가 멀면 유사하지 않는다. 즉, 0에 가까울수록 유사하다고 볼 수 있고 1에 가까울수록 유사하지 않다고 볼 수 있지만 거리에 따라 1이라고 하더라도 가장 유 사한 결과가 나타날 수도 있다.

본 실험에서 특징 분류를 위해 사용한 거리 유사도 측정 기법은 맨하탄 거리 (L1), 유클리디안 거리(L2), 코사인 유사도(Cos: Cosine similarity), 마할라노비 스 거리(MAH: Mahalanobis)를 사용하여 분류하였다.

맨하탄 거리는 d_1 과 p, q사이에 차원 실수를 직교 좌표계에 일정한 좌표축의 점 위에 투영한 선분 길이의 합을 말하며 다음과 같이 나타낼 수 있다. $a = (a_1, a_2, \dots, a_n)$ 과 $b = (b_1, b_2, \dots b_n)$ 을 공간 벡터라고 할 때 식 (4.1)과 같이 표현 할 수 있다.

$$d_1(a,b) = ||a-b||_1 = \sum_{i=1}^n |a_i - b_i|$$
(4,1)

유클리드 거리는 두 점 사이의 거리를 계산 할 때 일반적으로 사용된다. 직교 좌표계로 나타낸 점 $a = (a_1, a_2, \dots, a_n)$ 와 $b = (b_1, b_2, \dots b_n)$ 가 존재할 때 두 유클리드 노름을 이용하여 두 점의 거리를 계산하면 식 (4.2)와 같이 나타낼 수 있다.

$$d(a,b) = \sqrt{(a_1 - b_1)^2 + (a_2 - b_2)^2 + \dots + (a_n - b_n)^2} = \sqrt{\sum_{i=1}^n (a_i - b_i)^2}$$
(4,2)

코사인 유사도는 내적공간의 두 벡터 사이 각도의 코사인값을 이용하여 측정된 벡터간의 유사한 정도를 의미한다. 각도가 0°일 때의 코사인값은 1이며, 다른 모 든 각도의 코사인값은 1보다 작다. 따라서 이 값은 벡터의 크기가 아닌 방향의 유 사도를 판단한다. 속성 *A*,*B*의 벡터값이 주어졌을 때 코사인 유사도는 벡터의 스 칼라곱과 크기로 식 (4.3)과 같이 나타낼 수 있다.





$$\cos(\theta) = \frac{A \cdot B}{||A|| ||B||} = \frac{\sum_{i=1}^{n} A_i \times B_i}{\sqrt{\sum_{i=1}^{n} (A_i)^2 \times \sum_{i=1}^{n} (B_i)^2}}$$
(4.3)

마할라노비스 거리는 두 점 사이의 거리를 계산할 때 데이터의 분포를 고려하 는 거리이다. 데이터의 분포 및 공분산을 사용하여 거리를 측정하며 식 (4.4)와 같이 나타낼 수 있다.

$$d(a,b) = \sqrt{(a_i - b_i)^T, S^{-1}(a_i - b_i)}$$
(4.4)





제4장 실험 및 결과 분석

제 1절 심전도 데이터베이스

MIT-BIH 부정맥 데이터베이스는 32-89세의 남성 25명, 23-89세의 여성 22명인 47명의 환자에게서 얻은 것이며 두 번에 걸쳐 48시간 동안 기록한 심전도 신호가 구성되어 있다. 4000개 이상의 Holter 테이프에서 무작위로 선택한 23개의 기록과 무작위 기록에서 잘 나타나지 않지만 부정맥의 중요한 부분을 포함하는 25개의 기 록으로 구성되어있다. 각 샘플링 속도는 초당 360Hz로 디지털화되며 10mV 범위에 서 11비트 해상도로 디지털화된다[33-36]. 이 데이터베이스는 42개는 리드 II와 V1 이며 나머지는 리드 I 및 V5, V2, V5, V4가 포함되며 신호의 파형은 그림 4-1과 같 다.



그림 4-1. 실험에서 사용된 심전도 신호(Grid intervals: 0.2sec, 0.5mV)

제 2절 실험 방법

본 절에서는 제안된 방법의 심전도 인식 성능을 평가하기 위해 기존의 기법과 제안하는 기법의 인식률을 비교하며 1차원 벡터 신호를 2차원 영상으로 변환하고 2차원 영상을 3차원 텐서로 변환하여 처리하는 방법 통해 심전도의 인식률 결과에 대한 분석을 한다.

본 실험에서 사용한 컴퓨터의 하드웨어 사양은 Intel 17-4790, 메모리 16GB,





NVIDA Geforce GTX 750 Ti이며 소프트웨어는 Matlab 2018a 버전을 사용하였다. 주성분 분석, 선형 판별 분석과 다선형 판별 분석의 심전도 인식률 성능을 비교하 기 위한 실험 데이터는 MIT-BIH 부정맥 데이터베이스가 사용되었고 2차원 영상을 3차원 텐서로 변환하여 인식률 성능을 나타내기 위해 데이터는 PTB 진단 데이터베 이스가 사용되었다.

MIT-BIH 부정맥 데이터베이스 47클래스에 대해 일정한 간격의 주기로 신호를 얻기 위해 3초간 30번의 샘플링을 하여 데이터를 구성한다. 샘플링을 거친 데이터 의 구성은 프레임, 채널, 레코드로 구성되고 3000×2×2350의 데이터 크기를 가지 며 이 데이터의 주성분 분석과 선형 판별 분석에서의 고유벡터의 개수를 조절하여 인식률을 나타낸다. 인식률을 나타내기 위해 고유벡터의 개수는 1개부터 1개씩 증 가시켜 100개까지의 인식률을 나타낸다. 이때 선형 판별 분석에서는 클래스 수에 서 하나를 뺀 값으로 고유벡터 수를 계산하여 처리한다. 인식률 성능을 나타내기 위해 거리 유사도 측정 기법 중 맨하탄 거리(L1), 유클리디안 거리(L2), 코사인 거리(Cos), 마할라노비스 거리(Mahal)를 사용하여 주성분 분석에서 인식률은 표 4-1과 같이 각각 79.23%, 78.97%, 79.48%, 77.95%의 인식률을 확인 할 수 있으며 그림 4-2는 주성분 분석의 고유벡터에 대한 인식률 성능을 나타낸다.

특징 추출	고유벡터 수	유사도	인식률
	- 1 ~ 100 -	L1	79.23%
DCA		L2	78.97%
FUA		Cos	79.48%
		Mahal	77.95%

표 4-1. 주성분 분석의 유사도별 인식률







그림 4-2. 주성분 분석의 고유벡터에 대한 인식률

주성분 분석과 동일한 거리 유사도 기법을 통해 선형 판별 분석에서 인식률은 표 4-2와 같이 각각 85.39%, 86.34%, 87.91%, 84.42%의 인식률을 확인 할 수 있으 며 그림 4-3는 선형 판별 분석의 고유벡터에 대한 인식률을 나타낸다.

특징 추출	고유벡터 수	유사도	인식률
	1 100	L1	85.39%
		L2	86.34%
LUA	1~100	Cos	87.91%
		Mahal	84.42%

표 4-2. 선형 판별 분석의 유사도별 인식률







그림 4-3. 선형 판별 분석의 고유벡터에 대한 인식률

다선형 판별 분석은 주성분 분석, 선형 판별 분석에서 사용한 것과 마찬가지로 동일한 MIT-BIH 부정맥 데이터베이스를 사용하여 47클래스에 대해 3초간 30개의 샘플링을 하여 데이터를 구성하여 다선형 판별 분석에서 텐서로 재정렬하여 적용 시킬 수 있도록 특징추출한 데이터를 사용한다. 한 클래스당 20개의 데이터가 존 재하여 학습 및 검증 데이터는 각각 940개로 구성한다. 그리고 전처리 과정을 통 해 구성되는 프레임의 수는 전후 400프레임으로 구성하면 801프레임을 구성할 수 있으며 두 개의 리드에 대해 두 번 처리하기 때문에 총 1602프레임을 구성할 수 있다. 학습데이터의 수는 940개와 1602프레임으로 학습 데이터는 940×1602크기가 되며 검증 데이터 또한 940×1602으로 구성된다.

다선형 판별 분석에 입력 데이터로 사용하기 위해 1차원 벡터 신호를 3차원 텐서로 재구성한다. 입력 데이터를 3차원 데이터로 재구성하기 위해 데이터를 4개 씩 묶어서 시퀀스 데이터로 구성하면 한 개당 1602×4의 크기가 된다. 이때 양 끝 1프레임씩을 제거한 후 텐서 데이터를 재정렬하여 40×40×4로 구성할 수 있으며 학습 데이터 수는 940개에서 4개씩 묶어서 구성되면 235개가 되기 때문에 텐서는 40×40×4×235크기를 가지며 검증 데이터 또한 같은 크기를 갖는다. 다선형 판별





분석에서는 다선형 주성분 분석의 기능을 갖는데, 여기서 특징차원은 다선형 판별 분석 내에서 다선형 주성분 분석의 차원축소 이후 선형 판별 분석을 수행할 수 있 는 값으로 인식률 성능은 특징차원의 값으로 결정된다. 특징차원의 수는 150으로 설정하였고 보존 에너지값인 Q는 기본적으로 사용되는 값인 97로 설정하였으며 최 대 반복수는 1로 설정하였다. 이 실험의 인식률 성능은 주성분 분석, 선형 판별 분석의 인식률 성능 비교하기 위해 거리 유사도 측정 기법 중 맨하탄 거리(L1), 유클리디안 거리(L2), 코사인 거리(Cos)를 사용하였다. 마할라노비스 거리의 경우 인식률이 0%에서 90%까지 반복되는 형태를 나타내고 있어 다선형 판별 분석에서는 제외하였다. 다선형 판별 분석에서 인식률은 표4-1과 같이 각각 97.87%, 97.44%, 97.44%의 인식률을 확인할 수 있으며 그림 4-4는 다선형 판별 분석의 특징차원의 수에 대한 인식률 성능을 나타낸다.

특징 추출	특징차원 수	유사도	인식률
		L1	97.87%
MLDA	1~100	L2	97.44%
		Cos	97.44%

표 4-3. 다선형 판별 분석의 유사도별 인식률







그림4-4. 다선형 판별 분석의 특징차원의 수에 대한 인식률

제 3절 결과 분석

심전도의 개인 인식 성능 검증을 위해 MIT-BIH 부정맥 데이터베이스를 사용하 여 주성분 분석, 선형 판별 분석에서 데이터의 인덱스 및 리드 데이터를 정리하여 저장하고 특징 추출하여 학습 및 검증 데이터를 구성하였다. 분류하고자하는 47를 래스에 대해 각각 한사람 당 20개의 학습 및 검증데이터를 사용하였으며 공분산 행렬에 대한 고유벡터 수를 통해 변환된 공간으로 투영하여 얻은 값을 통해 인식 률 성능을 나타내었으며 선형 판별 분석도 위와 마찬가지로 데이터를 구성하고 클 래스 내의 분산행렬, 클래스 간의 분산행렬을 통해 고유값에 대한 고유벡터를 선 택하여 투영행렬을 통해 얻은 값의 인식률을 성능을 볼 수 있다.

다선형 판별 분석에서도 위와 마찬가지로 같은 데이터베이스를 사용하여 심전 도 신호는 전처리 과정을 거쳐 신호의 잡음을 제거 한 후 1차원 벡터 신호를 3차 원 텐서로 구성하여 다선형 주성분 분석을 이용하여 mode투영 후 선형 판별 분석 을 통해 다선형 투영하여 얻어진 특징벡터를 통해 거리 유사도 기법을 통해 인식





률의 성능을 볼 수 있었다. 표 4-4는 주성분 분석, 선형 판별 분석, 다선형 판별 분석의 인식률을 비교한 것을 나타내었다.

	특징추출 / 인식률		
거리 유사도	PCA	LDA	MLDA
L1	79.23%	85.39%	97.87%
L2	78.97%	86.34%	97.44%
Cos	79.48%	87.91%	97.44%
Mah	77.95%	84.42%	_

표 4-4. 주성분 분석, 선형 판별 분석, 다선형 판별 분석의 인식률 비교

주성분 분석에서 행렬에 대한 고유벡터 수를 통해 변환된 공간으로 투영하여 얻은 값을 통해 얻은 인식률보다 선형 판별 분석에서 클래스 내의 분산행렬, 클래 스 간의 분산행렬을 통해 고유값에 대한 고유벡터를 선택하여 투영행렬을 통해 얻 은 값의 인식률을 성능이 더 좋은 인식률을 보였다.

다선형 판별 분석을 통해 얻은 인식률은 주성분 분석과 선형 판별 분석보다 높 은 인식률이 나타나는 것을 볼 수 있다. 선형 방법에서의 벡터화는 원래 구조와 상관관계가 깨져 원래의 정보가 없어지는 문제가 있지만, 다선형 방법에서는 텐서 를 직접 입력을 매핑하기 전에 데이터 구조를 보존하기 때문에 다선형 방법이 선 형 방법보다 원래의 구조, 상관관계 및 정보를 더 포함하여 처리되기 때문에 더 좋은 결과를 볼 수 있다. 다선형 판별 분석이 주성분 분석보다 평균 18%, 선형 판 별 분석을 통한 인식률보다 거리 유사도의 평균11% 더 좋은 결과를 보여준다.





제5장 결론 및 향후 연구과제

본 논문에서는 다선형 판별 분석 기법을 통해 다차원 데이터 배열인 3차원 텐 서 특성을 이용하여 기존의 차원 축소 방법인 주성분 분석, 선형 판별 분석 기법 의 차원보다 높은 차원의 특성 공간에서 얻은 값을 통해 인식률을 나타내었고 기 존의 차원 축소 기법인 주성분 분석, 선형 판별 분석 기법을 사용하여 얻은 인식 률과 선형 판별 분석 기법을 통해 얻은 인식률을 비교하는 실험을 수행하였다.

이 실험에서는 MIT-BIH 부정맥 데이터베이스가 사용되었으며 심전도 신호에서 정상적인 파형과 다르게 튀는 신호나 범위를 벗어나는 파형들을 효과적으로 인식 할 수 있도록 시퀀스 형태로 나타내어 텐서로 재구성하고 다선형 투영을 통해 얻 은 값을 특징차원의 수를 통해 인식률을 얻는다. 특징분류는 맨하탄 거리, 유클리 디안 거리, 코사인 유사도를 사용하였으며 최고 인식률은 각각 97.87%, 97.44%, 97.44%의 인식률을 얻을 수 있었다.

다선형 판별 분석의 인식률 결과와 비교하기 위해 주성분 분석과 선형 판별 분 석을 사용하였다. 주성분 분석에서는 공분산행렬을 통해 고유값에 대한 고유벡터 를 선택하여 투영행렬을 통해 대상에 투영하여 수행하였으며 특징분류는 맨하탄 거리, 유클리디안 거리, 코사인 유사도, 마할라노비스 거리를 사용하였으며 각각 79.23%, 78.97%, 79.48%, 77.95%의 인식률을 볼 수 있었다. 선형 판별 분석 기법 에서는 주성분 분석과 동일하게 데이터를 구성하고 클래스 내의 분산행렬, 클래스 간의 분산행렬을 통해 고유값에 대한 고유벡터를 선택하여 투영행렬을 통해 얻은 값의 인식률을 성능을 얻을 수 있었으며 거리 유사도 기법은 주성분 분석과 동일 하며 각각 85.39%, 86.34%, 87.91%, 84.42%의 인식률을 볼 수 있었다.

주성분 분석과 선형 판별 분석이 다선형 판별 분석을 사용한 결과보다 성능이 떨어지는 것을 볼 수가 있다. 주성분 분석과 선형 판별 분석을 통해 데이터를 재 구성할 때 데이터의 일부 정보가 유실되는 반면에 데이터를 재구성해도 대부분의 데이터가 보존되는 다선형 판별 분석보다 인식률이 떨어지며, 신호를 연속적인 시 퀀스 형태로 구성하고 텐서로 재구성하여 신호를 더 효과적으로 인식할 수 있기 때문에 다선형 판별 분석이 개인 식별에 높은 효율을 보인다.

향후 실험에서는 1차원 신호를 2차원 웨이블릿 변환을 통해 scalogram 이미지 로 구성하고 다시 3차원 텐서로 재구성하여 다선형 주성분 분석, 다선형 판별 분





석을 통해 심전도로부터 개인 식별의 타당성을 보이며 선형 부분공간 학습 방법과 성능 비교 연구를 할 예정이다.





참고문헌

- 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] 박범근, "생체인식 기술 및 시장동향," *연구성과실용화진흥원 S&T Market Report*, Vol.39, 2016.
- [3] 조주희, 조병준, 이대종, 전명근, "주성분 분석기법을 이용한 심전도 기 반 개인인증," 전기학회논문지, 제66권, 제4호, 258-262쪽, 2017.
- [4] 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, 2017.
- [5] S. C. Fang, H. L Chan, "Human identification by quantifying similarity and dissimilarity in electrocardiogram phase space," *Pattern Recognition*, Vol. 42, No. 9, pp. 1824-1831, 2009.
- [6] L.Biel, O. Pettersson, L. Philipson, P. Wide, "ECG analysis: a new approach in human identification," *IEEE Transactions on Instrumentation and Measurement*, Vol. 50, No. 3, pp. 808-812, 2001.
- [7] T. W. Shen, W.J. Tompkins, Y.H. Hu, "One-lead ECG for identity verification," *Proceedings of the Second Joint EMBS/BMES Conference*, pp. 62-63, 2002.
- [8] M. Kyoso, A. Uchiyama, "Development of an ECG identification system," Proceedings of the 23rd Annual EMBS International Conference, pp. 3721-3723, 2001.
- [9] R. J. Martis, U. R. Acharya, L. C. Min, "ECG beat classification using PCA, LDA, ICA and Discrete Wavelet Transform," *Biomedical Signal Processing and Control*, Vol. 8, No. 5, pp. 437-448, 2013.





- [10] H. Abdi, L. J. Williams, "Principal component analysis," WIREs Computational Statistics, Vol. 2, No. 4, pp. 433-459, 2010.
- [11] 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.
- [12] P. Comon, "Independent component analysis, A new concept?," Signal Processing, Vol. 36, No. 3, pp. 287-314, 1994.
- [13] M. A. Hearst, S.T. Dumais, E. Osuna, J. Platt, B. Scholkopf, "Support vector machines," *IEEE Intelligent Systems and their Applications*, Vol. 13, No. 4, pp. 18-28, 1998.
- [14] H. A. Rowley, S. Baluja, T. Kanade, "Neural network-based face detection," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 20, No, 1, pp.23-38, 1998.
- [15] D. F.Specht, "Probabilistic neural networks," Neural Networks, Vol. 3, No. 1, pp. 109-118, 1990.
- [16] E. D. A. Botter, C.L. Nascimento, T. Yoneyama, "A neural network with asymmetric basis functions for feature extraction of ECG P waves," *IEEE Transactions on Neural Networks*, Vol. 12, No. 5, pp.1252-1255, 2001.
- [18] P. Davey, D. Sharman, "The electrocardiogram", Medicine, Vol. 46, No. 8, pp. 443-452, 2018.
- [19] S. K. Berkaya, A. K. Uysal, E. S. Gunal, S. Ergin, S. Gunal, M. B. Gulmezoglu, "A survey on ECG analysis," *Biomedical Signal Processing and Control*, Vol. 43, pp. 216-235, 2018.
- [20] D. M. Schreck, R. D. Fishberg, "Derivation of the 12-lead electrocardiogram and 3-lead vectorcardiogram," *The American Journal of Emergency Medicine*, Vol. 31, No. 8, pp. 1183-1190, 2013.
- [21] Y. C. Yeh, T. C. Chiang, H. J. Lin, "Principal Component Analysis





Method for Detection and Classification of ECG Beat," 2011 IEEE 11th International Conference on Bioinformatics and Bioengineering, pp. 318-322, 2011.

- [22] W. K. Chinga, D. Chu, L. Z. Liao, X. Wang, "Regularized orthogonal linear discriminant analysis," *Pattern Recognition*, Vol. 45, No. 7, pp. 2719-2732, 2012.
- [23] D. S. Alexiadis, D. Glaroudis, "Color face recognition: A multilinear-PCA approach combined with Hidden Markov Models," *Proceedings of the International Conference on Signal Processing and Multimedia Applications*, pp. 1-7, 2011.
- [24] 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.
- [25] J. Shermina, "Face recognition system using Multilinear Principal Component Analysis and Locality Preserving Projection," 2011 IEEE GCC Conference and Exhibition, pp. 283-286, 2011.
- [26] 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.
- [27] J. Wu, S. Qiu, R. Zeng, Y. Kong, L. Senhadji, H. Shu, "Multilinear Principal Component Analysis Network for Tensor Object Classification," *IEEE Transactions on Neural Networks*, Vol. 19, No. 1, pp. 18-39, 2008.
- [28] C. M. Chen, Z. S. Qing, C, Y, Fen, "Face recognition based on MPCA," 2010 The 2nd International Conference on Industrial Mechatronics and Automation, Vol. 1, pp. 322-325, 2010.
- [29] 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.
- [30] 임원철, 곽근창, "ECG신호로부터 다선형 선형판별분석을 이용한 생체인 식," 한국정보기술학회, 19-20쪽, 2018년 6월.





- [31] H. Lu, K. N. Plataniotis. A .N. Venetsanopoulos, "Gait Recognition Through MPCA Plus LDA," 2006 Biometrics Symposium: Special Session on Research at the Biometric Consortium Conference, pp. 1-6, 2006.
- [32] 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. 1-5. 2011.
- [33] Moody GB, Mark RG. The impact of the MIT-BIH Arrhythmia Database. IEEE Eng in Med and Biol 20(3):45-50 (May-June 2001). (PMID: 11446209)
- [34] 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).
- [35] 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.
- [36] 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.



