

EEG 기반 SPD-Net에서 리만 프로크루스테스 분석에 대한 연구

방윤석 · 김병형*

인하대학교 전기컴퓨터공학과

Research of Riemannian Procrustes Analysis on EEG Based SPD-Net

Isaac Yoon Seock Bang and Byung Hyung Kim*

Department of Electrical Computer Engineering, Inha University

(Manuscript received 1 July 2024 ; revised 13 August 2024 ; accepted 14 August 2024)

Abstract: This paper investigates the impact of Riemannian Procrustes Analysis (RPA) on enhancing the classification performance of SPD-Net when applied to EEG signals across different sessions and subjects. EEG signals, known for their inherent individual variability, are initially transformed into Symmetric Positive Definite (SPD) matrices, which are naturally represented on a Riemannian manifold. To mitigate the variability between sessions and subjects, we employ RPA, a method that geometrically aligns the statistical distributions of these matrices on the manifold. This alignment is designed to reduce individual differences and improve the accuracy of EEG signal classification. SPD-Net, a deep learning architecture that maintains the Riemannian structure of the data, is then used for classification. We compare its performance with the Minimum Distance to Mean (MDM) classifier, a conventional method rooted in Riemannian geometry. The experimental results demonstrate that incorporating RPA as a preprocessing step enhances the classification accuracy of SPD-Net, validating that the alignment of statistical distributions on the Riemannian manifold is an effective strategy for improving EEG-based BCI systems. These findings suggest that RPA can play a role in addressing individual variability, thereby increasing the robustness and generalization capability of EEG signal classification in practical BCI applications.

Key words: Riemannian Procrustes Analysis, EEG Classification, Riemannian manifold, SPD-Net

1. 서 론

뇌-컴퓨터 인터페이스(Brain-Computer Interface; BCI)에서 뇌전도 신호(Electroencephalogram; EEG)는 인간의 뇌 신호 활동을 실시간으로 모니터링할 수 있는 강력한 도구로, 감정 인식 및 상상 운동 등 다양한 응용 분야에서 활용되고 있다[1]. 그러나 EEG 데이터의 개인별 특징 차이는 BCI의 주요 문제점 중 하나로, 특히 감정 인식과 같은 응용 분야

에서 모델의 일반화 성능을 저하시킨다. 본 연구는 이러한 문제를 해결하기 위해 EEG 신호를 공분산행렬로 변환한 후 리만 기하학(Riemannian Geometry)의 특성을 유지하며[2,3], EEG 데이터의 공분산 행렬을 리만 다양체(Riemannian Manifold)상에서 기하학적으로 정렬하는 리만 프로크루스테스 분석(Riemannian Procrustes Analysis; RPA)[4]을 도입하여 EEG 데이터에서 개인간의 차이를 줄여 대칭 양의 정부호 행렬(Symmetric Positive Definite Matrix)을 입력으로 받는 SPD-Net[5]의 성능을 탐구하였다. 본 연구의 목표는 RPA를 통해 EEG 데이터에서 개인간의 차이를 줄이면서도 리만 기하학의 특성을 유지하는 방법이 SPD-Net의 학습 성능을 향상시킬 수 있는지 연구하는 것이다. 게다가, 리만 프로크루스테스 분석은 상상 운동 데이터나 P300 등에서 성능을 입증한 바 있으나, 감정 데이터에 적용된 사례는 없었으며

*Corresponding Author : Byung Hyung Kim
5S136, Inha University 100 Inha-Ro, Incheon, Korea
Tel: +82-032-860-7114

E-mail: bhyung@inha.ac.kr
본 연구는 인하대학교의 지원과 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(No. 2021R1C1C2012437)과 정보통신기획평가원의 지원(RS-2023-00229074)을 받아 수행된 연구임.

로 본 연구에서는 이를 감정 데이터에 적용하고, SPD-Net의 전처리 단계로 활용하여 그 효과를 검증하고자 한다.

본 연구의 주요 기여는 다음과 같다. 첫째, EEG 데이터에서 RPA를 통해 데이터를 정렬 및 정규화 하여 개인 차이를 줄이는 방법을 SPD-Net에 적용하고 그 성능을 평가한다. 둘째, 감정 데이터셋에 RPA를 적용한 방법과 적용하지 않은 방법을 비교하여, RPA의 효과를 실험적 데이터로 입증하였다. 이와 같이, 본 연구는 EEG 데이터의 정렬 및 정규화, 리만 기하학적 특성 유지, 그리고 개인 차이 제거를 통해 SPD-Net의 성능을 향상시키는 새로운 접근법을 제시한다.

II. 연구 방법

본 연구는 리만 프로크루스테스 분석을 기반으로 한 전처리를 통해 SPD-Net의 효용성을 향상시키는데 초점을 맞추고 있으며, 이를 위해 필요한 선행연구를 설명하고 연구 방법을 서술한다.

1. 양의 정 부호 다양체(Symmetric Positive Definite Manifold)

EEG 데이터가 n개의 채널을 갖고 있을 때 공분산행렬로 변환하면 해당 행렬은 다음 조건 $P(n) = \{C \in \mathbb{R}^{n \times n} \mid C^T = C, x^T C x > 0, \forall x \in \mathbb{R}^n\}$ 을 만족하는 리만다양체(Riemannian Manifold)의 부분공간인 양의 정 부호 다양체(Symmetric Positive Definite Manifold; SPD Manifold) $P(n)$ 에 속하게 된다. SPD 다양체는 국소적으로는 유클리드 공간과 유사하지만, 전체적으로는 곡률을 가지는 형태의 다양체이다. 이 다양체에서 공분산 행렬은 자연스럽게 표현되며, 행렬은 하나의 점으로 취급된다. SPD 다양체에서는 몫 기하학(quotient geometry)을 사용하여 점들 사이의 거리를 계산하며, 이는 아핀 불변 리만 거리(Affine-Invariance Riemannian distance; AIRM)를 통해 정의된다[6].

2. 프로크루스테스 분석(Procrustes Analysis)

프로크루스테스 분석(Procrustes Analysis)[7]은 주어진 데이터셋 간의 차이를 최소화하기 위해 선형 변환(회전, 이동, 정규화)을 적용하는 방법이다. 이 방법은 기하학적 관점에서 주어진 데이터셋의 분포를 최대한 일치시키는 과정으로 해석될 수 있다. 각 k개의 랜드마크를 가지고 있는 두 집합 $X = \{x_i \in \mathbb{R}^n\}_{i=1}^k, \tilde{X} = \{\tilde{x}_i \in \mathbb{R}^n\}_{i=1}^k$ 이 있을 때, 프로크루스테스 분석은 다음과 같은 단계로 수행된다:

- 1) 각 집합에서 평균에 해당하는 m과 m을 구하여 데이터의 평균을 0으로 이동시킨다.
- 2) 두 집합의 크기를 같게 하기 위해 적절한 스칼라 값 s를 곱하여 정규화 한다.
- 3) 회전행렬 U를 통해 두 집합의 방향을 일치시킨다. 위의 과정을 통해 두 집합 간의 분포 차이를 최소화하는 s와 U를 구할 수 있으며 이를 통해 아래의 식을 만족하는 새로운 집합 X^{PA} 을 얻는 것을 목표로 한다.

$$X^{PA} = sU(X - m) \tag{1}$$

3. 리만 프로크루스테스 분석(Riemannian Procrustes Analysis; RPA)

리만 프로크루스테스 분석은 리만 공간에서 프로크루스테스 분석을 적용하여 전이학습(Transfer Learning)을 수행하는 방법론이다. 본 연구에서는 각 레이블의 평균점을 랜드마크로 설정하여 데이터셋의 분포를 맞추기 위해 1) 재중심화(Recentering), 2) 정규화(Stretch), 3) 회전(Rotation)의 연산을 수행한다. 이 과정은 다음과 같이 구체적으로 적용된다. 우선, 모델이 학습에 사용하는 subject들로 구성된 데이터 Source(S)와 전이학습을 적용하고자 하는 subject의 데이터인 Target(T)을 설정한다. 이는 아래와 같은 수식으로 표현한다.

180

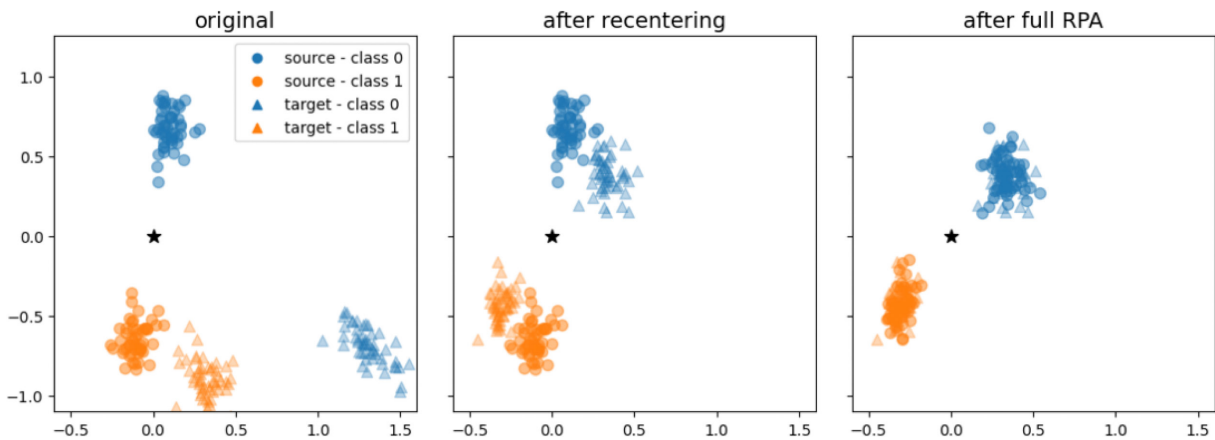


그림 1. 2*2 터미 행렬에 적용한 RPA의 수행과정
Fig. 1. RPA process applied on 2*2 dummy matrices

$$S = (C_i, y_i) \text{ for } i = 1, \dots, K_S \quad (2)$$

$$T = (\tilde{C}_i, \tilde{y}_i) \text{ for } i = 1, \dots, K_T \quad (3)$$

$C_i, \tilde{C}_i \in \mathbb{R}^{n \times n}$ 인 Source와 Target의 데이터 행렬이고, y_i, \tilde{y}_i 는 각 데이터가 갖고 있는 레이블 값이다. 이 때 레이블을 알고 있는 Target 집합(Labeled Target)은 T_L 로 표기하고 레이블을 모르는 Target의 집합(Unlabeled Target)은 T_U 로 표기하며, 다음의 관계가 성립한다.

$$T = T_L \cup T_U, T_L \cap T_U = \emptyset \quad (4)$$

리만 프로크루스테스 분석은 레이블을 알고 있는 T_L 을 활용하여 Source 데이터셋에 Target 데이터의 분포를 맞춰주는 작업을 수행한다. 이를 통해 레이블이 없는 T_U 에 대한 예측 성능을 향상시키는 것이 목표이다.

(1) 재중심화(Recentering; RCT)

SPD 다양체에서의 원점에 해당하는 공간은 I_n 인 단위 행렬이다. 재중심화 과정에서는 각 대상(Subject)별로 중심을 I_n 으로 이동시키는 연산을 진행한다. 이때 C_i 는 각 Source subject의 집합이며, M_i 는 각 subject의 리만 평균을 의미한다. 재중심화가 완료된 subject의 행렬은 $C_i^{(rect)}$ 로 표기하며 식 (5)를 따른다.

$$C_i^{(rect)} = M_i^{-1/2} C_i M_i^{1/2} \quad (5)$$

Target의 경우, 레이블을 알고 있는 T_L 의 평균 \tilde{M} 을 구해 전체 Target 데이터셋 \tilde{C} 에 적용시켜 식 (6)을 만족시키는 $\tilde{C}_i^{(rect)}$ 를 구한다.

$$\tilde{C}_i^{(rect)} = \tilde{M}^{-1/2} \tilde{C}_i \tilde{M}^{1/2} \quad (6)$$

이 연산을 통해 Target의 중심을 I_n 에 근사 시킬 수 있으며, 데이터의 수가 많아질수록 더 근사하게 된다.

(2) 정규화 (Stretching; STR)

데이터의 분포의 크기를 맞추기 위해 진행되는 작업으로, 선택한 대상(Target subject)의 집합 \tilde{C} 의 크기를 Source 집합의 분포 크기와 맞춰주는 과정이다. 정규화가 진행된 집합은 $\tilde{C}_i^{(str)}$ 로 표기하며 식 (7)의 관계가 성립한다.

$$\tilde{C}_i^{(str)} = (\tilde{C}_i^{(rect)})^s \quad (7)$$

이때의 s 는 $s \in \mathbb{R}$ 로, \tilde{d} 가 \tilde{C}_i 의 크기이고, d 가 C_i 의 크기일 때, $s^2 = d / \tilde{d}$ 를 만족한다.

(3) 회전 (Rotation; ROT)

회전시키는 과정은 중심과 크기를 맞춘 데이터가 최대한 겹치도록 데이터셋을 회전시키는 과정을 의미한다. Source

데이터와 Target 데이터의 분포 차이가 최소가 되는 U 를 찾는 것이다. 이 때의 U 는 행렬을 양의 정부호 다양체 안에 존재시키기 위해 $U^T U = I_n$ 를 만족하는 직교 행렬이어야 하며 회전이 적용된 Target 집합은 $\tilde{C}_i^{(rot)}$ 로 표기하며 식 (8)을 만족시킨다.

4. 사용 데이터셋

본 연구에서는 공개 감정 데이터인 SEED[8], DEAP[9], 그리고 상상운동 데이터인 Cho2017[10]을 이용하여 연구를 진행한다.

(1) SEED 데이터셋

SEED 데이터셋은 15명의 피실험자가 긍정, 부정, 중립의 3개의 레이블이 부여된 15개의 영상을 보고 그 뇌파를 3회 측정된 데이터로, 62-channel international 10-20 system을 이용하여 200Hz의 샘플링 헤르츠를 가진 데이터를 이용하였다. 각 영상의 길이는 4분 정도이며 각 피실험자에게서 총 45 개의 데이터를 수집할 수 있다(15개 영상 \times 3회 측정).

(2) DEAP 데이터셋

DEAP 데이터셋은 32명의 피실험자가 40개의 1분짜리 뮤직비디오를 시청한 후 감정 반응을 평가한 데이터셋이다. 피실험자들은 감정의 긍정-부정 정도를 나타내는 valence, 감정이 얼마나 강하게 작용했는지를 나타내는 arousal, 감정 상황에서 자신이 얼마나 통제력을 느끼는지를 측정하는 dominance 그리고 실험 음악에 대한 친숙도를 나타내는 familiarity를 평가하였다. 본 연구에서는 감정에 대한 분석 기법의 효용성을 알아보기 위해 valence만을 사용하여 연구를 진행하였다. Valence는 0~9의 0에서 9까지의 연속적 척도로 평가되었으며, 이를 이분법적으로 나누기 위해 4.5를 기준으로 삼아, 4.5 이상은 긍정적, 4.5 미만은 부정적 감정으로 분류하였다. 이때의 EEG 측정은 International 10-20 시스템의 32 채널을 이용하였고 128 Hz로 샘플링 된 데이터를 사용하였다.

(3) Cho2017 데이터셋

Cho2017 데이터셋은 52명의 피실험자가 상상운동을 통해 왼손과 오른손을 움직이는 실험으로, 64채널 EEG International 10-10 시스템으로 측정되었으며 피실험자당 3.5초씩 100 trial (50회 왼손, 50회 오른손)을 실행한다. 512Hz로 샘플링한 데이터를 이용하였다.

5. 모델 설정

(1) SPD-Net

SPD-Net은 리만기하학의 특성을 유지시키면서 기존 신경

망의 장점을 보존할 수 있는 네트워크의 한 종류로, Manifold Learning의 관점에서 가장 널리 쓰이는 네트워크다. 본 연구는 RPA를 통한 전처리를 했을 때 SPD-Net에서도 성능을 발휘하는지 확인해보고자 한다.

(2) MDM(Minimum Distance to Mean)

SPD-Net과의 비교 실험을 위해 설정한 모델은 MDM[11]이다. MDM은 학습된 클래스의 평균과 가장 가까운 데이터에 레이블을 부여하는 방식으로 기하학적으로 타당한 결론을 도출할 수 있다. MDM은 기존 RPA의 성능을 평가하기 위해 사용된 방법으로 이를 통해 SPD-Net과 비교하는 것이 적절하며 기존 방법대로 연구를 진행했을 때 감정 데이터에 RPA가 영향을 미치는지 또한 확인 할 수 있다.

6. 연구 방법

본 연구는 기존 리만 프로크루스테스 분석(RPA)의 방법론이 SPD-Net에서도 영향을 끼치는지 확인해보기 위한 연구로, RPA를 적용하기 위한 샘플 데이터 T_L (label을 알고 있는 Target의 일부분)을 전체 Target 데이터의 20%로 정하였다. 이 샘플데이터 T_L 을 Source 데이터와 합쳐($S \cup T_L$) train 데이터셋을 구축한 뒤, T_L 에서 얻을 수 있는 정보들을 바탕으로 RPA를 단계적으로 수행하여 각 단계별로 모델을 통해 평가한다(그림 2).

또한, 선행연구에서 "RPA가 자기 분간성(self-discriminancy)이 높은 상태에서만 효과적으로 작동한다[12]"는 점에 주목하여, Source와 Target의 자기 분간성 수준에 따라 연구를 진행하였다. 이를 위해, Source의 자기 분간성이 미치는 영향을 고려하여 선택하는 Source의 개수를 상위 n개로 값들로 설정하였고, Target의 자기 분간성이 미치는 영향을 분석하기 위해 상위 k개의 Target 을 설정하였다. Target을

설정하였다. 자기 분간성의 척도는 subject별 intra-score로 측정되었으며, 이는 각 subject별로 20%의 데이터를 떼어내 train 데이터로 삼고, 이를 기반으로 모델을 훈련한 후 나머지 80%를 대상으로 테스트했을 때의 정확도로 정의된다. SPD-Net 기반의 intra-score는 batch size 30, epoch 100으로 설정하여 측정하였으며, MDM 기반의 intra-score는 5-fold cross-validation을 사용하여 측정하였다. 이후, 원본 데이터(Original; ORG), 재중심화 과정이 완료된 데이터(Recentering; RCT), RPA가 적용된 데이터(RPA)에 대해 MDM 및 SPD-Net을 적용하여 실험을 수행하고 정확도(accuracy)를 통해 분석하였다. 연구 결과 stretching 과정이 정확도에 미치는 영향은 크지 않아 본 연구의 분석에서는 제외하였다.

III. 연구 결과

본 연구에서는 각 모델과 RPA 단계에 따라 원본데이터(ORG)를 입력으로 받은 ORG-MDM, ORG-SPD-Net, 재중심화를 거친(RCT) RCT-MDM, RCT-SPD-Net, 전체 과정(RPA)을 거친 RPA-MDM, RPA-SPD-Net으로 구별하였다. 이를 토대로 각 데이터셋 별 Source의 개수와 Target의 개수를 조절하여 실험을 진행한 결과는 다음과 같다. 본 단락의 표에서 *는 ORG와 비교 시 정확도를 기준으로 $p < 0.05$, **는 $p < 0.01$ 을 나타낸다.

표 1의 결과에 의하면 DEAP 데이터셋을 사용하여 MDM 방식으로 평가한 결과, 대체로 재중심화(RCT) 단계에서 가장 높은 정확도를 나타냈으며, RPA 단계에서 RCT보다 높은 정확도를 보인 경우는 없었다. 그러나 RPA 또한 DEAP 데이터셋의 Source 개수 10, Target의 개수 $k = 32$ 인 경우를 제외하고는 원본 데이터(ORG)보다 더 높은 정확도를 기록하였다. Source 개수를 조절한 경우 DEAP 데이터셋에서는 큰 차이를 보이지 않았으며, Target의 개수를 조절할 때는 k 값이 줄어들수록 성능이 향상되는 경향을 확인할 수 있었다. SPD-Net으로 평가한 경우, 원본 데이터(ORG)가 이미 MDM 방식의 어떤 형태보다도 높은 정확도를 나타냈으며, RCT와 RPA에서는 ORG에 비해 정확도가 소폭 상승하는 모습을 보였다. Source 개수를 조절한 경우, 재중심화(RCT) 단계에서만 정확도가 상승하였고, Target의 개수를 조절할 때는 ORG, RCT, RPA 모두 이전보다 정확도가 상승하였다. 그러나 SPD-Net에서 자기 분간성이 높은 대상 5명만을 평가했을 때, RPA의 방법에 따른 차이는 명확하게 드러나지 않았다.

표 2의 결과를 보면 Cho2017 데이터셋을 MDM 방식으로 평가한 결과, 재중심화(RCT)와 리만 프로크루스테스 분석(RPA)이 원본 데이터(ORG)보다 유의미하게 정확도가 향

182

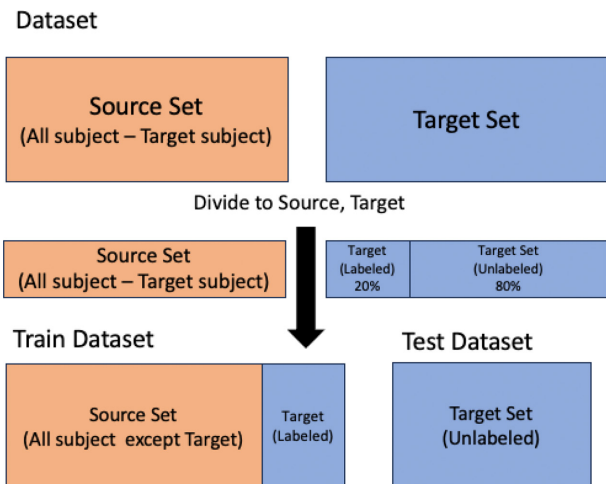


그림 2. 데이터 분리과정
Fig. 2. Data splitting process

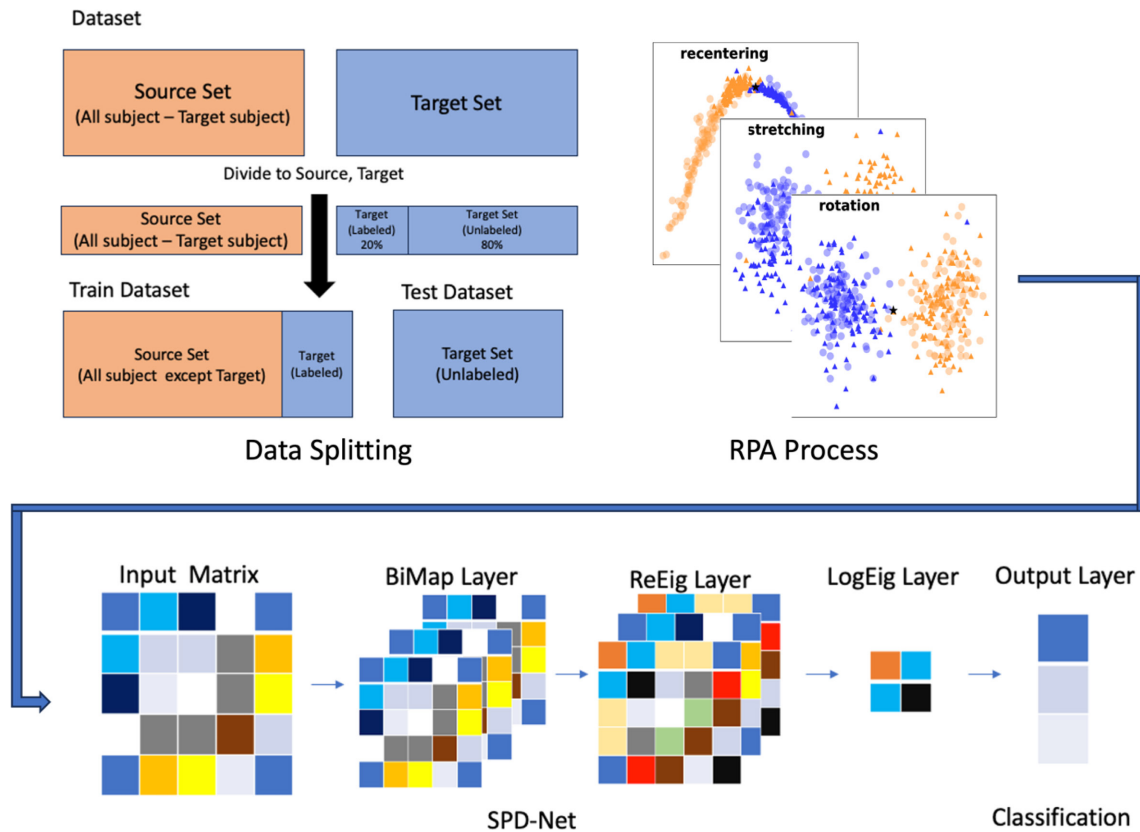


그림 3. 연구과정의 전체적인 모식도
Fig. 3. Overall process of research

표 1. DEAP 데이터셋의 방법 별 정확도
Table 1. Accuracy result of DEAP on each method

Average accuracy	MDM based			SPD-Net based		
	ORG	RCT	RPA	ORG	RCT	RPA
DEAP 20 Source(k=32)	0.529	0.617**	0.586**	0.616	0.626	0.630
DEAP 20 Source(k=20)	0.528	0.623**	0.589*	0.646	0.658	0.658
DEAP 20 Source (k=10)	0.525	0.633**	0.617*	0.663	0.663	0.663
DEAP 20 Source (k=5)	0.537	0.642	0.628	0.760	0.760	0.760
DEAP 10 Source(k=32)	0.571	0.558	0.546	0.608	0.630	0.625
DEAP 10 Source (k=20)	0.528	0.623	0.589	0.626	0.664	0.650
DEAP 10 Source (k=10)	0.525	0.633	0.617	0.667	0.675	0.663
DEAP 10 Source (k=5)	0.537	0.642	0.628	0.760	0.760	0.760

상되는 모습을 보였다. Cho2017 데이터셋에서는 Source의 변화에 따른 성능 차이는 미미하였으나, Target의 개수를 줄일수록 RPA가 RCT보다 더 나은 성능을 보였다. SPD-Net으로 평가했을 때도, 전처리를 거친 데이터는 대체로 원본 데이터(ORG)보다 성능이 향상되는 경향을 보였다. 특히, Cho2017 데이터셋의 Source 개수 40, Target의 개수 k = 52인 경우를 제외하고는 RCT와 RPA 모두에서 ORG보다 높은 정확도를 나타냈다. Source의 개수 변화에 따른 성능 차이는 크지 않았으며, Target의 개수를 줄일수록 모든 전처리 방법에서 성능이 향상되는 경향이 관찰되었다.

표 3의 결과를 보면 SEED 데이터셋을 MDM 방식으로 평가한 결과, 전처리 방법에 따른 명확한 추세가 나타나지 않았다. Source의 개수를 조절한 경우, 10개의 Source를 사용했을 때 재중심화(RCT)에서 정확도가 향상된 반면, 리만 프로크루스테스 분석(RPA)에서는 원본 데이터(ORG)보다 성능이 감소하였다. 또한, 5개의 Source를 선택하여 평가했을 때는 RCT와 RPA 모두에서 ORG보다 성능이 저하되는 경향을 보였다. SPD-Net으로 평가한 결과에서는, ORG와 RCT는 유사한 성능을 보였으나 RPA는 ORG와 RCT에 비해 성능이 떨어졌다. Source의 차이에 따른 성능 변동은 명확하지




그림 4. DEAP 20 Source에서 k = 20,10,5 일 때의 SPD-Net의 boxplot
 Fig. 4. Boxplot of SPD-Net on DEAP 20 Source where k= 20,10,5

표 2. Cho2017 데이터셋의 방법 별 정확도

Table 2. Accuracy result of Cho2017 on each method

Average accuracy	MDM based			SPD-Net based		
	ORG	RCT	RPA	ORG	RCT	RPA
Cho2017 40 Source(k=52)	0.543	0.634**	0.589**	0.598	0.643*	0.595
Cho2017 40 Source(k=20)	0.579	0.677**	0.656*	0.619	0.674	0.638
Cho2017 40 Source (k=10)	0.586	0.712	0.726*	0.685	0.74	0.706
Cho2017 40 Source (k=5)	0.538	0.683	0.749*	0.757	0.769	0.818
Cho2017 20 Source(k=52)	0.536	0.620**	0.591**	0.579	0.630**	0.581
Cho2017 20 Source(k=20)	0.572	0.663**	0.66**	0.612	0.655	0.638
Cho2017 20 Source(k=10)	0.569	0.687*	0.726**	0.676	0.726	0.729
Cho2017 20 Source (k=5)	0.526	0.649	0.749**	0.725	0.784	0.810

184




그림 5. Cho2017 40 Source에서 k = 20,10,5 일 때 SPD-Net의 boxplot
 Fig. 5. Boxplot of SPD-Net on Cho2017 40 Source where k= 20,10,5

않았으며, Target의 개수 변화에 따른 성능 차이도 두드러지지 않았다.

이 연구 결과는 RPA와 RCT가 데이터 전처리에 미치는 영향이 데이터셋의 특성 및 분석 방식에 따라 다르게 나타날 수 있음을 시사한다. DEAP 데이터셋의 경우, MDM을 사용할 경우 RCT가 RPA보다 더 효과적이었으며, SPD-Net을 사용할 경우 원본 데이터(ORG) 상태에서 이미 높은 성능을 보여

데이터 전처리 방법의 효과가 상대적으로 덜 나타났다. 이는 데이터셋의 연속적인 감정평가를 단순한 긍정/부정으로 나눔에 따라 데이터의 특징들이 충분히 반영되지 않았을 수도 있다. 그럼에도 DEAP 데이터셋은 개인별로 충분한 양의 데이터가 제공되어 이런 전처리 방법이 성능 향상에 의미가 있었다. Cho2017 데이터셋에서 MDM은 전처리를 통해 얻을 수 있는 정보가 많았으며, 특히 Target 데이터의 규모가 작아

표 3. SEED 데이터셋의 방법 별 정확도

Table 3. Accuracy result of SEED on each method

Average accuracy	MDM based			SPD-Net based		
	ORG	RCT	RPA	ORG	RCT	RPA
SEED 10 Source(k=15)	0.438	0.504	0.380	0.691	0.691	0.578
SEED 10 Source(k=10)	0.450	0.533*	0.416	0.670	0.679	0.566
SEED 10 Source (k=5)	0.446	0.559	0.433	0.666	0.666	0.533
SEED 5 Source(k=15)	0.658	0.584	0.489	0.673	0.642	0.516
SEED 5 Source(k=10)	0.676	0.606	0.566	0.630	0.613	0.533
SEED 5 Source (k=5)	0.693	0.560	0.533	0.626	0.693	0.600

질수록 RPA가 데이터 간의 분포 차이를 효과적으로 조정하여 성능을 향상시킬 수 있었다. SPD-Net에서도 전처리 과정이 모델 성능에 긍정적인 영향을 미쳤다. 이러한 결과는 상상운동(Motor Imagery)의 특성상 데이터에 명확한 특징이 존재하며[13], 이러한 특징이 RPA와 같은 기하학적 전처리 기법이 더욱 효과적으로 작용했음을 시사한다. 반면, SEED 데이터셋의 경우 상대적으로 긴 영상 시간으로 인해 노이즈가 많이 포함될 가능성이 높으며, 데이터의 수가 부족하여 안정적인 학습을 보장하기 어려웠다는 점이 전처리 기법들이 기대한 만큼의 성능 향상을 보여주지 못한 원인 중 하나로 작용했을 수 있다. 종합적으로 정리하면, SPD-Net에서는 전처리에 따른 결과가 MDM처럼 눈에 띄는 향상은 보여주지 못했지만, SPD-Net이 일반적으로 더 높은 정확도를 보임으로써, EEG 분석 방법이 기존의 MDM과 같은 전통적인 기계학습 측면에서 네트워크 기반으로 점점 이동하고 있음을 타당하게 보여주고[14], 이는 SPD-Net의 구조가 데이터의 복잡한 패턴을 더 잘 학습할 수 있음을 시사하며, 전처리가 이러한 네트워크 기반 접근법에서도 여전히 중요한 역할을 할 수 있음을 나타낸다.

IV. 고찰 및 결론

본 연구는 테스트 데이터의 일부를 훈련 데이터에 추가하여 전처리를 진행한 후, 이러한 전처리가 MDM과 SPD-Net에서 어떻게 영향을 미치는지 분석하였다. 연구 결과, 기하학적인 변환을 통한 전처리가 MDM과 SPD-Net 모두에서 성능 향상에 기여하는 경향이 있음을 확인하였다. 이는 감정 데이터에도 이러한 전처리가 긍정적인 영향을 미칠 수 있음을 시사한다. 특히, 데이터에 재중심화(RCT) 과정을 적용했을 때 대부분의 경우 성능이 향상되었으며, 이는 기존 연구에서도 유사한 결과가 보고된 바 있다[15,16]. 그러나, 회전(Rotation)을 추가 적용한 경우 일부 데이터셋에서 성능이 저하되는 경우도 있었다. 이는 Target subject의 자기 분간성이 충분히 높을 경우에만 회전 변환이 효과적일 수 있다

는 점을 시사한다. 이 연구는 RPA와 같은 기하학적 변환을 통해 EEG 데이터의 전처리를 수행할 때, 충분한 수의 데이터가 필요하며, 각 subject의 자기 분간성을 사전에 파악하는 것이 중요함을 강조한다. 이러한 요인들은 RPA가 EEG 데이터 전처리 방법으로서의 활용에 있어 제약이 될 수 있다. 그럼에도 불구하고, 재중심화와 같은 전처리 과정은 충분히 EEG 데이터의 전처리로서의 의미가 있음을 본 연구를 통해 확인하였다. 다만, 회전 변환의 효과를 극대화하기 위해서는 subject의 자기 분간성을 어떻게 향상시킬 것인지와, 회전 변환에서 발생하는 연산량을 효율적으로 처리할 방법에 대한 추가 연구가 필요하다.

References

- [1] Kothe CA, Makeig S. BCILAB: a platform for brain-computer interface development. *Journal of Neural Engineering*. 2013;10(5):056014.
- [2] Yger F, Berar M, Lotte F. Riemannian approaches in brain-computer interfaces: a review. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2016;25(10):1753-62.
- [3] Congedo M, Barachant A, Bhatia R. Riemannian geometry for EEG-based brain-computer interfaces; a primer and a review. *Brain-Computer Interfaces*. 2017;4(3):155-74.
- [4] Rodrigues PLC, Jutten C, Congedo M. Riemannian Procrustes analysis: transfer learning for brain-computer interfaces. *IEEE Transactions on Biomedical Engineering*. 2018;66(8):2390-2401.
- [5] Huang Z, Van Gool L. A Riemannian network for SPD matrix learning. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2017;31(1):1-10.
- [6] Bhatia R. *Positive definite matrices*. Princeton: Princeton University Press; 2009. pp. 1-200.
- [7] Gower JC, Dijksterhuis GB. *Procrustes problems*. Oxford: Oxford University Press; 2004. pp. 1-10.
- [8] Duan RN, Zhu JY, Lu BL. Differential entropy feature for EEG-based emotion classification. *Proceedings of the 6th International IEEE EMBS Conference on Neural Engineering*. 2013;81-84.
- [9] Koelstra S, Muehl C, Soleymani M, Lee JS, Yazdani A, Ebrahimi T, Pun T, Nijholt A, Patras I. DEAP: A database for emo-

- tion analysis using physiological signals. *IEEE Transactions on Affective Computing*, 2011;3(1):18-31.
- [10] Cho H, Ahn M, Ahn S, Kwon M, Jun SC. EEG datasets for motor imagery brain-computer interface. *GigaScience*. 2017;6(7):gix034.
- [11] Graf AB, Bousquet O, Rätsch G, Schölkopf B. Prototype classification: insights from machine learning. *Neural Computation*. 2009;21(1):272-300.
- [12] Rodrigues PLC, Congedo M, Jutten C. "When does it work?": An exploratory analysis of transfer learning for BCI. *Proceedings of the BCI 2019-8th International Brain-Computer Interface Conference*. 2019;1-6.
- [13] Gwon D, Hwang MJ, Kwon JH, Shin Y, Ahn MK. A Comparative Analysis of Motor Imagery, Execution, and Observation for Motor Imagery-based Brain-Computer Interface. *Journal of Biomedical Engineering Research*, 2022;43(6):375-381.
- [14] Kim BH, Choi JW, Lee H, Jo S. A discriminative SPD feature learning approach on Riemannian manifolds for EEG classification. *Pattern Recognition*. 2023;143:109751.
- [15] Brooks D, Schwander O, Barbaresco F, Schneider JY, Cord M. Riemannian batch normalization for SPD neural networks. *Advances in Neural Information Processing Systems*. 2019;32:1-10.
- [16] Flamary R, Courty N, Tuia D, Rakotomamonjy A. Optimal transport for domain adaptation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2016;39(9):1853-65