

Elastic net 기반 특징 선택을 적용한 fNIRS 기반 뇌-컴퓨터 인터페이스 데이터셋 분류 정확도 평가

신재영

원광대학교 전자공학과

Assessment of Classification Accuracy of fNIRS-Based Brain-computer Interface Dataset Employing Elastic Net-Based Feature Selection

Jaeyoung Shin

Department of Electronic Engineering, Wonkwang University

(Manuscript received 23 July 2021 ; revised 11 December 2021 ; accepted 14 December 2021)

Abstract: Functional near-infrared spectroscopy-based brain-computer interface (fNIRS-based BCI) has been receiving much attention. However, we are practically constrained to obtain a lot of fNIRS data by inherent hemodynamic delay. For this reason, when employing machine learning techniques, a problem due to the high-dimensional feature vector may be encountered, such as deteriorated classification accuracy. In this study, we employ an elastic net-based feature selection which is one of the embedded methods and demonstrate the utility of which by analyzing the results. Using the fNIRS dataset obtained from 18 participants for classifying brain activation induced by mental arithmetic and idle state, we calculated classification accuracies after performing feature selection while changing the parameter α (weight of lasso vs. ridge regularization). Grand averages of classification accuracy are $80.0 \pm 9.4\%$, $79.3 \pm 9.6\%$, $79.0 \pm 9.2\%$, $79.7 \pm 10.1\%$, $77.6 \pm 10.3\%$, $79.2 \pm 8.9\%$, and $80.0 \pm 7.8\%$ for the various values of $\alpha = 0.001, 0.005, 0.01, 0.05, 0.1, 0.2, \text{ and } 0.5$, respectively, and are not statistically different from the grand average of classification accuracy estimated with all features ($80.1 \pm 9.5\%$). As a result, no difference in classification accuracy is revealed for all considered parameter α values. Especially for $\alpha = 0.5$, we are able to achieve the statistically same level of classification accuracy with even 16.4% features of the total features. Since elastic net-based feature selection can be easily applied to other cases without complicated initialization and parameter fine-tuning, we can be looking forward to seeing that the elastic-based feature selection can be actively applied to fNIRS data.

Keywords: Brain-computer interface, Elastic net, Feature selection, fNIRS, Regularization

1. 서 론

기능적 근적외선 분광법(functional near-infrared spectroscopy; fNIRS)은 혈액 속에 포함되어 있는 산화/환원 헤모글로빈의 농도를 추정하여 뇌의 활성화를 측정할 수 있는 비침습적인 뇌 이미징 기술이다. fNIRS 장비는 특별

한 사용 제한 조건이 없기 때문에 사용이 편리하여 최근 많은 연구 분야에 적용되어 활발히 사용되고 있다[1,2]. 다양한 분야 중 뇌-컴퓨터 인터페이스(brain-computer interface; BCI) 분야에서 fNIRS는 뇌파(electroencephalography; EEG) 및 기능적 자기 공명 영상(functional magnetic resonance imaging; fMRI)이 가지고 있는 단점을 보완할 수 있는 차세대 기술로 인정받고 있으며 많은 연구가 활발하게 이루어지고 있다[3].

fNIRS 기반 BCI 연구를 진행하기 위해서는 머신 러닝(machine learning) 기술이 필수적으로 적용되어야 하기

*Corresponding Author : Jaeyoung Shin
Iksan-daero 460, Iksan, 54538, Republic of Korea
Tel: +82-63-850-6744
E-mail: jyshin34@wku.ac.kr
이 논문은 2020년도 원광대학교 교비지원에 의해 수행됨.

때문에 다양한 fNIRS 전처리 기술, 분류기 및 특징 공학 기술들을 적용하여 fNIRS 기반 BCI 시스템 성능을 향상시키는 노력들이 이루어지고 있다[4-8]. 또한 최근 딥러닝 기술을 적용하여 fNIRS 기반 BCI 시스템 성능 향상에 대한 다양한 시도가 이루어지고 있다[9-11].

하지만, 머신 러닝 관점에서 보았을 때, fNIRS 기반 BCI 연구에 어려움이 존재한다. 일반적으로 높은 분류 정확도를 달성하기 위해서는 데이터셋의 크기가 큰 학습 데이터를 이용하여 분류기의 학습이 이루어져야 좋은 일반화된 분류기 성능을 비교적 용이하게 달성할 수 있다. EEG의 경우 자극에 대한 응답 지연 시간이 수 밀리초(millisecond) 단위에 지나지 않는다. 이와 달리 혈액학적 응답의 응답 지연 시간은 수 초 단위이며[12], 혈액학적 응답이 기저 상태로 돌아오기까지 돌아오는 시간도 EEG에 비하여 현저하게 오래 걸리기 때문에, 분류기 학습을 위하여 많은 fNIRS 데이터를 모으는 것은 쉽지 않다[13,14]. 따라서 학습 데이터 개수에 비하여 특징의 개수가 훨씬 더 많은 고차원 특징 벡터를 구성할 수밖에 없는 상황이 빈번하게 발생하여, 이른 바 차원의 저주(curse of dimensionality)로 인한 분류 정확도 저하 문제를 겪을 수 있다.

이러한 문제를 해결하기 위한 방법으로는 첫째로, 특징별 중요도를 계산하여 전체 특징 중에서 높은 중요도를 가지는 일부의 특징을 선택하는 특징 선택(feature selection)이 있고, 둘째로, 분류기가 가질 수 있는 모수에 제약을 부여하여 과적합(overfitting)을 피하고 및 강건성(robustness)을 높여 분류 정확도의 저하를 최대한 억제할 수 있는 정규화(regularization)가 있다[15]. 일반적으로 fNIRS 기반 BCI 데이터셋에 적용되는 특징 선택 방법 중 filter method로 피셔 점수(fisher score)가 있고[16], 최근 연구에는 Minimum Redundancy Maximum Relevance(mRMR) 특징 선택 알고리즘이 새롭게 적용되고 있다[17]. 이 mRMR 방법은 각 특징 간 및 특징과 클래스 간의 상호 정보량을 계산하여 redundancy와 relevance를 각각 정의하고, redundancy를 최소화하고, relevance를 최대화하는 특징들을 선택한다. 따라서 특징 선택을 위하여 효율적인 계산이 가능하지만, 특징들끼리 상호 작용을 통하여 중요성이 높아지는 특징을 제외할 수 있는 단점이 존재한다[18]. Wrapper method로는 대표적으로 sequential forward selection (SFS)/backward elimination(SBE)이 있다. 이 방법은 탐욕 알고리즘을 기반으로 suboptimal 특징을 선택할 수 있다는 장점이 있지만, 계산 시간이 굉장히 오래 걸리며, 지역 최적해에 빠지는 문제를 해결하지 못해 종종 낮은 성능을 보이는 단점이 존재한다. 이외에 자연의 진화 과정을 모방한 유전 알고리즘도 fNIRS 특징 선택에 적용되고 있다[19]. 전반적으로 filter method의 경우 가장 적합한 특징의 조합을 찾아내는 능력

에 한계점이 존재하여 선택된 특징 수가 줄어들어 따라서 분류 정확도가 현저하게 떨어지는 문제가 있으며, wrapper method 및 유전 알고리즘의 경우 계산 속도가 굉장히 느리며, 특히 SBS의 경우 특징 선택을 이용한 특징 벡터의 차원 축소에 큰 효과가 없을 수 있다.

따라서 본 연구에서는 분류 정확도의 저하를 방지하고, 높은 계산 복잡도를 줄이기 위하여 embedded method 특징 선택 방법을 사용한다. 여러 가지 embedded method 중에서 elastic net을 이용하여 분류 정확도 저하 없이 특징 벡터의 효과적인 차원 축소를 할 수 있는 지 살펴보고, 분류 결과를 mRMR, SFS를 적용한 결과와 비교하여 elastic net의 효용성에 대해서 논의한다.

II. 연구 방법

1. fNIRS 기반 BCI 데이터셋

본 연구는 신재영 외[20]에서 사용되었던 데이터셋을 사용하였다. 이 데이터셋에 대한 접근은 다음의 URL로 가능하다(<https://doi.org/10.6084/m9.figshare.9198932.v1>). 이 데이터셋은 그림 1에 나타난 이마에 위치한 16개의 채널에서 수집된 데이터를 포함한다. 18명의 피험자가 정신 산술(task 1: Mental Arithmetic), 움직임 상상(task 2: Motor Imagery)을 수행하거나, 유희 상태(task 3: Idle State)일 때 fNIRS 신호가 수집되었다. 피험자는 각 과제를 10초 동안 연속적으로 수행한 후, 30초의 과제 간 휴식(inter-task break)을 가졌다. 세 종류의 과제는 임의의 순서로 진행되었으며, 각 과제당 30개의 fNIRS 신호가 수집되었다. 전전두 피질(prefrontal cortex)에서 주로 관측되는 정신 산술에 의한 뇌활성화와 유희 상태를 분류하는 이진 분류를 수행하기 위하여, 정신 산술(task 1)과 유희 상태(task 3)에 해당하는 데이터만 선별적으로 추출하여 이진(binary) 분류

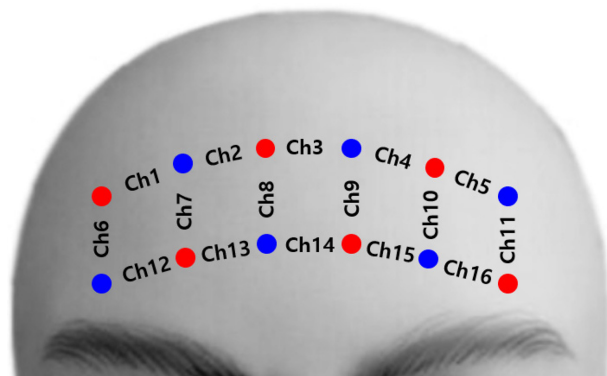


그림 1. 16개의 fNIRS 채널 구성 (광원: 빨간색, 광검출기: 파란색)
Fig. 1. Sixteen fNIRS channel configuration (source: red, detector: blue)

를 위한 데이터셋을 구성하였다. 따라서 포함된 데이터의 개수는 각 피험자당 60개이다($N = 60$). 데이터셋에 대한 추가적인 내용은 관련 연구에 상세히 기술되어 있다.

2. 전처리

본 연구에서 모든 신호 처리는 MATLAB R2020a (Mathworks, MA, USA)을 이용하여 수행되었다. 획득한 fNIRS 신호는 통과 대역 0.01–0.09 Hz를 가지는 3차 버터워스(Butterworth) 필터 기반 영위상 필터를 적용하여, 위상 지연 없이 fNIRS 신호에 포함되어 있는 다양한 생체 잡음, 저주파 드리프트 등을 제거하였다[21–25]. 필터링된 신호는 임무 시작 시간(0 초)을 기준으로 -1–0 초 구간의 각 채널의 신호 평균값을 이용하여 기준선 정렬을 수행하였다.

3. 특징 벡터

특징 벡터를 구성하기 위하여 fNIRS 기반 BCI에서 가장 많이 특징으로 사용되는 특정 시간 구간의 채널 별 신호 평균을 특징으로 선택하였다. 신호 평균을 계산하기 위한 시간 구간으로는 0–3, 3–6, 6–9 초 및 혈액학적 지연 시간을 고려하여 9–12, 12–15 초도 추가적으로 설정하였다. 즉, 5개의 시간 구간에서 각 채널 별 산소 헤모글로빈 농도의 변화(ΔHbO)와 환원 헤모글로빈 농도의 변화(ΔHbR)의 평균값을 계산하였다. 따라서 특징 벡터의 차원은 [16개의 채널] \times [2 종류의 fNIRS 신호] \times [5 개의 시간 구간] = 160이다 ($P = 160$). $N = 60$ 이므로 특징 벡터의 차원은 데이터의 개수보다 약 2.7배 크다.

4. Elastic net 기반 특징 선택

추출된 $P = 160$ 개의 특징 중에서 유의미한 특징을 선택하기 위하여 embedded method 중에서 ridge 회귀와 lasso 회귀를 결합한 elastic net을 사용하였다. 이 방식은 ridge 회귀의 단점인 유의하지 않은 변수의 제거 기능 부재와 lasso 회귀의 단점인 큰 정보 손실에 의한 분류 정확도 저하의 단점을 개선하는 방식이며, 각 특징끼리 상관 관계가 존재하는 데이터셋에 적용하기 유리하다. Elastic net은 식 (1)을 만족하는 회귀 계수 β 와 β_0 를 찾는 방법이다[26,27].

$$\arg \min_{\beta, \beta_0} \left(\frac{1}{2N} \sum_{i=1}^N (y_i - (x_i^T \beta + \beta_0))^2 + \lambda \left(\frac{1-\alpha}{2} \|\beta\|_1 + \alpha \|\beta\|_2 \right) \right) \quad (1)$$

x_i 와 y_i 는 각각 i 번째 데이터에 해당하는 특징 벡터와 클래스 레이블, α 는 L_1 -규제와 L_2 -규제의 적용 비율을 조절하는 모수($0 \leq \alpha \leq 1$)이다. $\alpha = 0$ 이면 ridge 회귀, $\alpha = 1$ 이면 lasso 회귀와 같아진다. λ 는 음이 아닌 정규화 모수이며, $\|\cdot\|_k$ 는 k 차 노름(norm)을 나타낸다. 특징 선택을 위해 학습 데이터 내에서 10-겹 교차 검증(k -fold cross validation)을

통하여 최소 교차 검증 평균 제곱 오차를 나타내는 특징들을 선택하였다. 대체로 모수 α 는 작을수록 L_2 -규제의 영향이 커서(ridge) 선택되는 특징의 개수가 많아지고, α 가 클수록 L_1 -규제의 영향이 커서(lasso) 선택되는 특징의 개수가 줄어든다. 따라서 본 연구는 모수 α 의 값이 1에 가까워질수록 선택되는 특징의 개수가 굉장히 적어지는 문제점을 고려하여 $\alpha = 0.001, 0.005, 0.01, 0.05, 0.1, 0.2$ 그리고 0.5까지만 적용하였다. λ 선형 회귀 모델이 null이 되지 않는 최댓값이 사용되었다.

5. Filter 및 wrapper 기반 특징 선택

Elastic net 기반 특징 선택 방법과의 특징 선택의 우수성을 비교하기 위하여 filter method와 wrapper method를 각각 한가지를 선정하였다. filter method로는 최근 fNIRS 연구에서 사용된 mRMR 방법을 선정하였다[28]. Wrapper method로는 목적 함수 값이 더 이상 감소하지 않을 때까지 가장 적절한 특징을 순차적으로 하나씩 추가하는 SFS를 선정하였다[29]. 본 연구에서 mRMR에 의하여 선택되는 특징은 가장 적은 수의 특징이 선택되는 elastic net 모수 $\alpha = 0.05$ 일 때 각 피험자에 해당하는 특징 개수만큼 선택하였다. (예: 피험자 1은 $160 \times 12.5\% = 20$ 개의 특징을 선택). SFS에 의하여 선택되는 특징은 선형 서포트 벡터 머신(linear support vector machine; linear SVM)을 이용하였을 때 오분류율이 더 이상 감소하지 않을 때까지 특징의 개수를 증가시키면서 선택하였다.

6. 교차 검증

일반적으로, linear SVM과 선형 판별 분석(linear discriminant analysis; LDA) 분류기가 빠른 계산 속도 및 높은 분류 성능을 나타내므로 fNIRS 기반 BCI 연구에 가장 많이 사용된다[30]. 이 중에서 LDA는 정규화 또는 특징 선택을 적용하지 않으면 고차원 특징 벡터를 이용한 분류 시 굉장히 많은 분류 성능 저하가 발생하기 때문에 이러한 점이 두드러지게 나타나지 않는 linear SVM을 사용하였다. 분류기 학습 시 학습의 효율성 높이기 위하여 특징 벡터의 표준화를 수행하였다. 일반화된 분류 정확도를 계산하기 위하여 leave-one-out 교차 검증(LOOCV)을 적용하였다. 피험자 당 60개의(정신 산술: 30개, 유희 상태: 30개) 데이터 샘플이 존재하기 때문에 60번의 교차 검증이 진행되었고, 테스트 샘플에 대한 분류 정확도의 평균 정확도로 일반화된 분류 정확도를 계산하였다. 그림 2는 본 연구에 적용된 LOOCV에 대한 설명을 나타낸다.

7. 통계 분석

데이터 분포의 정규성을 검증하기 위하여 Anderson-



그림 2. 일반화된 분류 정확도를 계산하기 위한 LOOCV
 Fig. 2. LOOCV for estimating generalized classification accuracy

Darling 검정을 사용하였다[31]. 데이터 표본 간의 평균의 차이를 확인하기 위하여 Levene 등분산 검정 후, 분류 정확도의 차이가 유의한 지 검증하기 위하여 일원배치 분산분석(one-way ANOVA)을 적용하였다. 사후 분석(post-hoc analysis)을 위하여 Tukey의 honestly significant difference (HSD) 검정 및 Duncan의 검정을 이용하였다[32]. 통계 분석은 MATLAB R2020a 및 SPSS 25(IBM, NY, USA)를 이용하여 수행되었다.

III. 연구 결과

1. 혈액학적 응답

그림 3은 과제 수행에 의하여 유도된 task-related 혈액학적 응답이 가장 잘 나타난 Ch15의 모든 피험자 평균이다. 정신 산술을 수행할 경우, ΔHbO 는 과제 수행 중 점차 감소하며, 과제 수행이 끝난 지 약 1초 이후 최저점이 도달한다. 그 이후 계속 과제 간 휴식 상태이므로 ΔHbO 는 기저 상태로 돌아온다. ΔHbR 은 과제 수행 중 점차 증가하며, 과제 수행이 끝난 지 약 1초 이후 최고점에 도달한다. 그 이후 과제 간 휴식 상태에 ΔHbR 은 기저 상태로 돌아온다. ΔHbO 와 ΔHbR 의 활성화 극성은 반대이며 ΔHbO 변화 폭은 ΔHbR 의 변화 폭보다 크다.

2. 특징 선택 및 분류 정확도

표 1은 특징 선택을 적용하지 않았을 때와 elastic net 기반 특징 선택을 적용하였을 때 계산된 분류 정확도이다. 특징 선택을 적용하지 않고 $P=160$ 개의 특징을 모두 사용하여 분류 정확도를 계산하였을 시(표 1에 n/a로 표시됨), $80.1 \pm 9.5\%$ (평균 \pm 표준 편차)의 분류 정확도를 얻을 수 있다. 모수 $\alpha=0.01$ 또는 0.1일 경우 분류 정확도는 각각, $79.0 \pm 10.3\%$ 과 $77.6 \pm 10.3\%$ 로 약간 낮은 수준이다. 하지만, 이외의 경우는 특

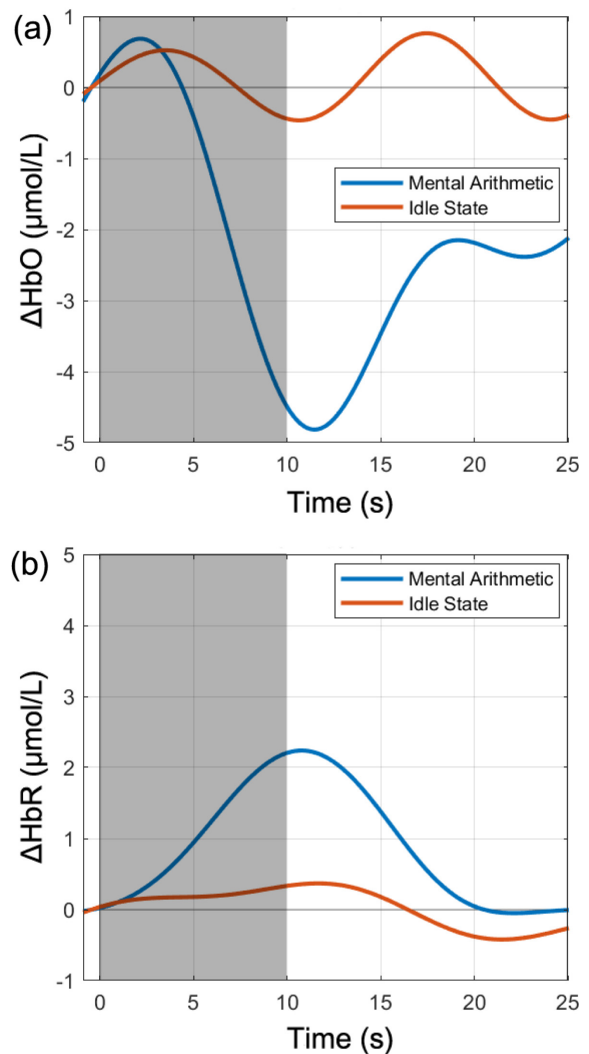


그림 3. Ch15의 과제 관련 (a) 산소 헤모글로빈(ΔHbO)과 (b) 환원 헤모글로빈(ΔHbR) 농도 변화의 피험자 전체 평균. 음영은 과제 수행 구간(0-10 초)를 나타냄
 Fig. 3. Grand average of task-related (a) ΔHbO and (b) ΔHbR in Ch15. Shades indicate a task period (0-10 s)

표 1. Elastic net 모수 α 의 변화에 따른 분류 정확도(단위: %)Table 1. Classification accuracies according to parameter α in elastic net (unit: %)

Participant	n/a*	0.001	0.005	0.01	0.05	0.1	0.2	0.5
1	80.0	80.0	83.3	80.0	80.0	76.7	81.7	86.7
2	83.3	83.3	83.3	85.0	85.0	78.3	78.3	81.7
3	75.0	75.0	73.3	71.7	75.0	65.0	66.7	78.3
4	93.3	93.3	91.7	91.7	95.0	91.7	93.3	93.3
5	68.3	70.0	70.0	70.0	71.7	73.3	70.0	71.7
6	83.3	83.3	85.0	83.3	81.7	83.3	81.7	80.0
7	63.3	63.3	63.3	63.3	65.0	61.7	63.3	66.7
8	76.7	78.3	75.0	78.3	85.0	83.3	86.7	85.0
9	80.0	80.0	76.7	76.7	75.0	70.0	73.3	71.7
10	73.3	71.7	66.7	65.0	65.0	61.7	71.7	76.7
11	81.7	80.0	81.7	80.0	78.3	76.7	75.0	78.3
12	86.7	86.7	85.0	80.0	85.0	83.3	83.3	76.7
13	63.3	63.3	63.3	66.7	61.7	63.3	75.0	71.7
14	95.0	95.0	95.0	95.0	95.0	95.0	93.3	88.3
15	78.3	78.3	78.3	80.0	80.0	83.3	85.0	85.0
16	96.7	96.7	95.0	93.3	95.0	91.7	93.3	95.0
17	83.3	81.7	81.7	83.3	86.7	81.7	75.0	73.
18	80.0	80.0	78.3	78.3	75.0	76.7	78.3	80.0
Mean	80.1	80.0	79.3	79.0	79.7	77.6	79.2	80.0
Std	9.5	9.4	9.6	9.2	10.1	10.3	8.9	7.8

*Feature selection was not employed

272

징 선택을 적용하지 않을 경우와 분류 정확도 차이가 매우 미미한 수준이다(평균 1% 차이 이내).

표 2는 모수 α 의 변화에 따라서 특징이 선택된 평균 비율을 나타낸다. $P = 160$ 개의 총 특징 개수를 기준으로 모수 $\alpha = 0.001$ 인 경우, 약 153개(96.7%의 특징이 선택되었고, 모수 α 의 값이 증가함에 따라서 131, 112, 64, 48, 36, 그리고 26개의 특징 평균적으로 선택되었다. 예상한대로 α 가 커질수록 lasso 회귀의 영향력이 증가하여 선택되는 특징의 개수가 감소하는 면을 보여준다.

IV. 고 찰

1. Elastic net 기반 특징 선택의 효용성

이전의 많은 연구에서 다양한 특징 선택 방법들을 fNIRS 기반 BCI 데이터셋에 적용하였다[33-35]. 특징 선택을 하였을 때 분류 정확도 관점에서 최고의 효율을 나타내는지는 검증되지 않은 경우가 많이 있고, 최적의 특징 선택을 위한 알고리즘을 다른 연구에 적용하기도 쉽지 않다. 하지만 본 연구에서는 모수 α 의 다양한 경우에 대하여 분류 정확도를

계산하였으며 분류 정확도의 차이가 크지 않다는 것을 확인하였다. 표 3과 그림 4에 나와 있듯이 일원배치 분산분석 결과, 본 연구에서 고려한 모든 경우의 모수 α 에 대하여 분류 정확도의 유의한 차이가 발견되지 않았다($F = 0.140$, $p = 0.995$). 결과적으로, elastic net 기반 특징 선택 방법을 적용하였을 때, 분류 정확도 측면에서 효과적인 특징이 올바르게 선택된다는 것을 알 수 있고, 고려된 모수 α 값의 범위 내에서는 모수 α 값의 변화에 분류 정확도가 큰 영향을 받지 않는다는 사실을 유추할 수 있다. 이는 다른 fNIRS 데이터셋에도 여러가지 고려사항 없이 적절한 수준의(극단적인 경우를 제외한) α 값을 사용하면 우수한 특징 선택 성능을 나타낼 수 있다는 사실로 귀결될 수 있다. 즉, 본 연구의 분석 결과는 elastic net 기반 특징 선택의 실용적 효용성을 입증한다.

2. 차원 축소

표 2에 나와 있듯이 모수 α 값이 커질수록 선택되는 특징의 비율은 95%대에서 16%대로 줄어들게 된다. 하지만, 분류 정확도의 차이는 없으므로($F = 0.140$, $p = 0.995$) 때

표 2. Elastic net 모수 α 의 변화에 따라 특징이 선택된 평균 비율(단위: %)Table 2. Average of feature selection ratio according to parameter α in elastic net(unit: %)

Participant	n/a*	0.001	0.005	0.01	0.05	0.1	0.2	0.5
1	100	97.4	82.1	69.3	37.1	26.4	17.5	12.5
2	100	97.5	89.8	80.4	55.0	43.4	31.0	23.1
3	100	96.7	81.6	66.8	32.9	23.3	16.2	10.1
4	100	95.5	82.3	72.6	48.4	40.0	32.5	24.4
5	100	95.5	82.6	72.0	40.5	30.3	23.4	16.2
6	100	96.6	84.1	73.4	38.9	27.1	19.6	11.6
7	100	94.0	74.6	58.4	31.5	22.5	17.4	11.7
8	100	95.5	81.3	66.5	29.8	19.0	14.1	9.5
9	100	97.7	89.0	80.9	51.0	35.5	23.2	14.0
10	100	94.1	76.4	63.9	41.2	30.1	24.3	14.7
11	100	94.8	80.2	69.4	40.6	31.5	22.8	16.3
12	100	96.0	83.4	72.1	41.0	29.8	21.4	15.1
13	100	93.6	76.2	64.2	32.5	22.4	16.2	9.0
14	100	98.0	90.4	81.2	57.8	48.4	38.7	28.9
15	100	93.3	72.0	59.3	30.4	21.3	17.9	13.6
16	100	93.5	77.9	66.2	35.6	29.7	23.0	17.0
17	100	95.9	79.5	67.8	35.9	27.9	19.4	15.7
18	100	96.7	85.3	76.0	42.8	35.8	30.0	25.8
Mean	100	95.7	81.6	70.0	40.2	30.2	22.7	16.1
Std	-	1.5	5.1	6.8	8.3	7.9	6.6	5.8

*Feature selection was not employed

표 3. 선택된 특징의 개수에 따른 분류 정확도 차이의 유의성을 확인하기 위한 일원배치 분산분석 결과표

Table 3. One-way ANOVA result table to test the significance of difference in classification accuracy according to the number of selected features

	ss	df	Mean Square	F	Significance
Between groups	.009	7	.001	.140	.995
Within groups	1.196	136	.009		
Total	1.205	143			

우 효율적으로 특징 선택이 이루어졌다는 사실을 알 수 있다. 이는 기존의 filter method나 wrapper method로는 달성하기 어려우며, 26개의 특징(전체 대비 약 16.1%만)으로 달성한 의미 있는 결과이다. 유전 알고리즘 같은 경우, 최적의 특징 선택을 위해서 매우 다양한 모수들의 상세한 초기

값 설정 및 최적 결과를 도출하기 위한 정교한 모수 미세 조정이 필요하는 등 기술적인 어려움이 존재한다. 더불어 차원 축소 관점에서 큰 효과가 없는 경우도 있다. 하지만 본 연구에서 얻어진 결과는 elastic net의 중요한 모수 중 하나인 α 값의 변화만으로 분류 정확도의 희생 없이 차원 축

표 4. 특징 선택 방법에 따른 분류 정확도 차이의 유의성을 확인하기 위한 일원배치 분산분석 결과표

Table 4. One-way ANOVA result table to test the significance of difference in classification accuracy according to the feature selection method

	ss	df	Mean Square	F	Significance
Between groups	.085	3	.028	3.103	.032
Within groups	.624	68	.009		
Total	.709	71			




그림 4. 모수 α 값에 대한 분류 정확도 상자 그림
 Fig. 4. Boxplot of classification accuracies according to parameter α value

소를 매우 효과적으로 달성할 수 있다. 따라서 elastic net 기반 특징 선택은 fNIRS 데이터셋에 매우 적합한 특징 선택 방법이다.

3. 특징 선택 방법에 따른 분류 정확도 비교 분석

그림 5는 특징 선택 방법에 따른 평균 분류 정확도를 나타낸다. 앞서 표 1에도 나와 있듯이 특징 선택을 하지 않을 경우 $80.1 \pm 9.5\%$, elastic net 기반 특징 선택을 적용할 경우 ($\alpha = 0.5$, $80.0 \pm 7.8\%$ 의 분류 정확도를 보여준다. SFS와 mRMR 기반 특징 선택을 적용할 경우 분류 정확도는 각각 $73.3 \pm 12.0\%$ 와 $73.0 \pm 8.5\%$ 이다. One-way ANOVA 분석 결과,

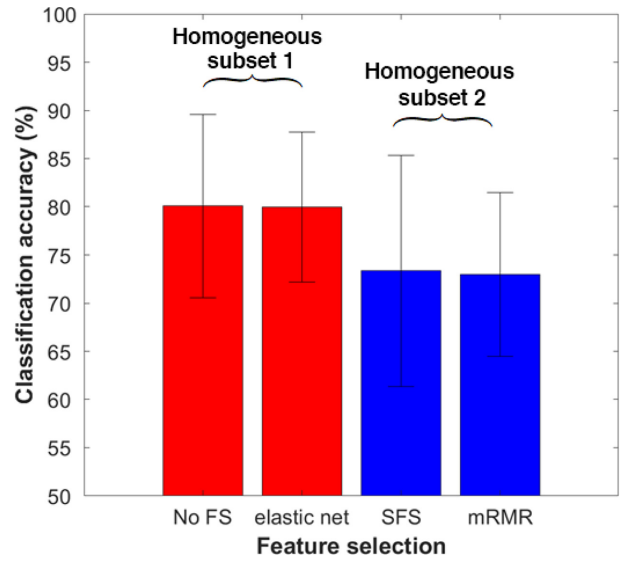


그림 5. 특징 선택 방법에 따른 분류 정확도 상자 그림
 Fig. 5. Boxplot of classification accuracies according to feature selection method

표 4와 같이 특징 선택 방법에 따른 분류 정확도의 유의한 차이가 있음이 확인되었지만 ($F = 3.103$, $p = 0.032$), 표 5와 같이 Tukey HSD 사후 분석 결과 유의한 차이가 확인되지 않았다. 하지만 표 6에 주어진 Duncan 사후 분석 결과 {모든 특징 선택, elastic net}과 {SFS, mRMR}은 유의 수준 $\alpha = 0.05$ 에서 분류 정확도가 같은 동질적 부분 집합(homogenous subset)인 subset 1과 subset 2로 구분되었다. 달리 말하면, 동일한 subset 내에서는 분류 정확도는 유의한 차이가 없고, subset 1과 subset 2은 통계적으로 유의한 분류 정확도의 차이가 존

274

표 5. Tukey HSD사후 분석 결과표(이상치 포함)

Table 5. Tukey HSD post-hoc analysis result table (with outlier results)

Multiple Comparisons				
Posthoc	(A) Method	(B) Method	Mean Difference (A-B)	Significance
Tukey HSD	No FS ^a	Elastic net	0.00	1.00
		SFS	0.07	0.16
		mRMR	0.07	0.13
	Elastic net	No FS ^a	0.00	1.00
		SFS	0.07	0.17
		mRMR	0.07	0.13
	SFS	No FS ^a	-0.07	0.16
		Elastic net	-0.07	0.17
		mRMR	0.00	1.00
	mRMR	No FS ^a	-0.07	0.13
		Elastic net	-0.07	0.13
		SFS	0.00	1.00

^aNo feature selection method was employed (i.e., all features were used)

표 6. Duncan 사후 검정 결과에 따른 동질적 부분 집합(이상치 포함)

Table 6. Homogeneous subsets according to Duncan post-hoc analysis result(with outlier results)

Homogeneous Subsets			
Feature selection	Number of participants	Subset for $\alpha = 0.05$	
		Subset 1	Subset 2
mRMR ^a	18	0.730	
SFS ^a	18	0.733	
Elastic net ^b	18		0.800
No FS ^b	18		0.801
Significance		0.91	0.98

^{a,b}The results are in homogeneous subsets

제한다.

Grubbs 검정을 이용해 분류 정확도 이상치(피험자 7 분류 정확도)를 제거 후[36], One-way ANOVA 분석 결과, 특징 선택 방법에 따른 분류 정확도의 유의한 차이가 있음이 확인되었고($p=0.020$), Tukey HSD 사후 분석 결과 ‘모든 특징 선택 vs. mRMR($p=0.055$)’, ‘elastic net 적용 vs. mRMR 적용($p=0.071$)’의 분류 정확도 사이에서 거의 유의한(marginally significant) 분류 정확도 차이가 확인되었다(논문에 제시하지는 않음). 종합하면, 통계적으로 다소 엄격하지는 않지만 분류 정확도 측면에서 elastic net은 mRMR과 SFS보다 우수한 특징 선택 성능을 나타낸다고 할 수 있다.

4. 한계점 및 의의

Elastic net 특징 선택은 분류 정확도의 저하 없이 유의미한 특징을 선택할 수 있다는 장점이 존재하지만, 특징 선택을 통하여 분류 정확도의 향상을 이루기 어렵다는 문제점이 있다. 즉, linear SVM 분류기를 사용하였을 경우, 고차원 특징 벡터로 인한 분류 정확도 저하의 문제점이 두드러지게 발생하지 않기 때문에 특징 선택 과정이 필요 없을 수도 있다. 하지만 고차원의 특징 벡터는 linear SVM 이외의 다양한 분류기의 적용시 분류 정확도 감소 등의 문제가 발생할 여지가 많다. 예를 들면, 특징 선택을 하지 않고 LDA 분류기 적용 시 평균 분류 정확도는 linear SVM 대비 약 7.5% 저하된다(자세한 결과는 주어지지 않음). 만약 linear SVM 이외의 더 적합한 분류 방법이 있다면 elastic net 특징 선택은 고차원 특징 벡터로 인하여 발생하는 문제에 대한 좋은 해결책이 될 수 있다.

V. 결 론

본 연구에서는 embedded method 중 하나인 elastic net 특징 선택을 적용하여 fNIRS 기반 BCI 데이터셋의 분류 정확도 계산 및 차원 축소 효율성에 대하여 알아보았다. 분석 결

과, 모수 α 값의 변화만으로 분류 정확도의 저하 없이 고차원의 특징 벡터의 차원 축소를 효율적으로 할 수 있었다. 따라서 elastic net 기반 특징 선택은 fNIRS 기반 BCI 데이터셋에 적용할 수 있는 우수한 특징 선택 방법이며 복잡한 초기값 설정 및 모수 미세 조정 없이 쉽게 적용할 수 있으므로, 앞으로 연구에 계속 적용하여 fNIRS 기반 BCI의 성능 향상을 도모할 수 있다.

References

- [1] Boas DA, Elwell CE, Ferrari M, Taga G. Twenty years of functional near-infrared spectroscopy: introduction for the special issue. 2014;85:Part 1:1-5.
- [2] Scholkmann F, Kleiser S, Metz AJ, Zimmermann R, Mata Pavia J, Wolf U, Wolf M. A review on continuous wave functional near-infrared spectroscopy and imaging instrumentation and methodology. 2014;85:Part 1:6-27.
- [3] Quaresima V, Ferrari M. A mini-review on functional near-infrared spectroscopy (fNIRS): where do we stand, and where should we go? 2019;6(3):87.
- [4] Nazeer H, Naseer N, Khan RA, Noori FM, Qureshi NK, Khan US, Khan MJ. Enhancing classification accuracy of fNIRS-BCI using features acquired from vector-based phase analysis. 2020;17(5):056025.
- [5] Qureshi NK, Naseer N, Noori FM, Nazeer H, Khan RA, Saleem S. Enhancing classification performance of functional near-infrared spectroscopy-brain-computer interface using adaptive estimation of general linear model coefficients. 2017; 11(33).
- [6] Nazeer H, Naseer N, Mehboob A, Khan MJ, Khan RA, Khan US, Ayaz Y. Enhancing classification performance of fNIRS-BCI by identifying cortically active channels using the z-score method. 2020;20(23):6995.
- [7] Shin J, Kwon J, Choi J, Im C-H. Performance enhancement of a brain-computer interface using high-density multi-distance NIRS. 2017;7:16545.
- [8] Shin J, Im C-H. Performance Improvement of Near-Infrared Spectroscopy-Based Brain-Computer Interface Using Regularized Linear Discriminant Analysis Ensemble Classifier Based on Bootstrap Aggregating. 2020;14(168).
- [9] Ma T, Wang S, Xia Y, Zhu X, Evans J, Sun Y, He S. CNN-

- based classification of fNIRS signals in motor imagery BCI system. 2021;18(5):056019.
- [10] Nagasawa T, Sato T, Nambu I, Wada Y. fNIRS-GANs: data augmentation using generative adversarial networks for classifying motor tasks from functional near-infrared spectroscopy. 2020;17(1):016068.
- [11] Sm JA, Chhabra H, Shajil N, Venkatasubramanian G. Investigation of deep convolutional neural network for classification of motor imagery fNIRS signals for BCI applications. 2020;62:102133.
- [12] Cui X, Bray S, Reiss AL. Speeded near infrared spectroscopy (NIRS) response detection. 2010;5(11):15474.
- [13] Shin J, von Lüthmann A, Kim D-W, Mehnert J, Hwang H-J, Müller K-R. Simultaneous acquisition of EEG and NIRS during cognitive tasks for an open access dataset. 2018;5:180003.
- [14] Shin J, von Lüthmann A, Blankertz B, Kim D-W, Jeong J, Hwang H-J, Müller K-R. Open access dataset for EEG+NIRS single-trial classification. 2017;25(10):1735-1745.
- [15] Shin J, Müller K-R, Hwang H-J. Near-infrared spectroscopy (NIRS) based eyes-closed brain-computer interface (BCI) using prefrontal cortex activation due to mental arithmetic. 2016;6(1):36203.
- [16] Hwang H-J, Choi H, Kim J-Y, Chang W-D, Kim D-W, Kim K, Jo S, Im C-H. Toward more intuitive brain-computer interfacing: classification of binary covert intentions using functional near-infrared spectroscopy. 2016;21(9):091303.
- [17] Hosseini R, Walsh B, Tian FH, Wang SY. An fNIRS-based Feature Learning and Classification Framework to Distinguish Hemodynamic Patterns in Children Who Stutter. 2018;26(6):1254-1263.
- [18] Radovic M, Ghalwash M, Filipovic N, Obradovic Z. Minimum redundancy maximum relevance feature selection approach for temporal gene expression data. 2017;18.
- [19] Noori FM, Naseer N, Qureshi NK, Nazeer H, Khan RA. Optimal feature selection from fNIRS signals using genetic algorithms for BCI. 2017;647:61-66.
- [20] Shin J, Kwon J, Im C-H. A Ternary Hybrid EEG-NIRS Brain-Computer Interface for the Classification of Brain Activation Patterns during Mental Arithmetic, Motor Imagery, and Idle State. 2018;23:5.
- [21] Zhang Q, Strangman GE, Ganis G. Adaptive filtering to reduce global interference in non-invasive NIRS measures of brain activation: How well and when does it work? 2009;45(3):788-794.
- [22] Falk TH, Guirgis M, Power S, Chau T. Taking NIRS-BCIs outside the lab: towards achieving robustness against environment noise. 2011;19(2):136-146.
- [23] Power SD, Kushki A, Chau T. Automatic single-trial discrimination of mental arithmetic, mental singing and the no-control state from prefrontal activity: toward a three-state NIRS-BCI. 2012;5(1):141.
- [24] Power SD, Kushki A, Chau T. Towards a system-paced near-infrared spectroscopy brain-computer interface: differentiating prefrontal activity due to mental arithmetic and mental singing from the no-control state. 2011;8(6):066004.
- [25] Schudlo LC, Chau T. Towards a ternary NIRS-BCI: single-trial classification of verbal fluency task, Stroop task and unconstrained rest. 2015;12(6):066008.
- [26] Tibshirani R. Regression shrinkage and selection via the lasso. 1996;58(1):267-288.
- [27] Zou H, Hastie T. Regularization and variable selection via the elastic net. 2005;67(2):301-320.
- [28] Svinkunaite L, Horschig J, Floor-Westerdijk, M. Employing cardiac and respiratory features extracted from fNIRS signals for mental workload classification. SPIE BiOS. online. 2021.
- [29] Guyon I, Elisseeff A. An introduction to variable and feature selection. 2003;3(Mar.):1157-1182.
- [30] Naseer N, Hong K-S. fNIRS-based brain-computer interfaces: a review. 2015;9(1):3.
- [31] Yap BW, Sim CH. Comparisons of various types of normality tests. 2011;81(12):2141-2155.
- [32] Hochberg Y, Tamhane AC. Multiple comparison procedures. John Wiley & Sons, Inc. 1987.
- [33] Fernandez Rojas R, Huang X, Ou K-L. A machine learning approach for the identification of a biomarker of human pain using fNIRS. 2019;9(1):5645.
- [34] Chen L, Li Q, Song H, Gao R, Yang J, Dong W, Dang W. Classification of schizophrenia using general linear model and support vector machine via fNIRS. 2020;43(4):1151-1160.
- [35] Herff C, Heger D, Fortmann O, Hennrich J, Putze F, Schultz T. Mental workload during n-back task—quantified in the prefrontal cortex using fNIRS. 2013;7(1):935.
- [36] Grubbs FE. Sample criteria for testing outlying observations. 1950;21(1):27-58.