

시계열 학습 알고리즘을 이용한 뇌파 자동 분류

김중환*, 남상하**, 김인철***

*경기대학교 컴퓨터과학과 학부생

**경기대학교 컴퓨터과학과 석사과정

***경기대학교 컴퓨터과학과 교수

e-mail:{click7254, namsh, kic}@kgu.ac.kr

EEG Classification using Time-series Learning Algorithm

Jong-Hwan Kim*, Sang-Ha Nam**, In-Cheol Kim***

*Undergraduate Course, Dept of Computer Science, Kyonggi University

**Master Course, Dept of Computer Science, Kyonggi University

***Faculty, Dept of Computer Science, Kyonggi University

요 약

본 논문에서는 로봇 제어 목적의 응용을 위해 SVM 알고리즘과 HMM 알고리즘을 근간으로 하는 효과적인 뇌파 데이터 자동 분류 방법을 제안한다. Emotive Epoc 헤드셋 뇌파 측정 장비를 이용하여 뇌파 데이터를 수집하고, 수집된 뇌파 데이터로부터 FFT 알고리즘을 이용하여 특징 추출을 수행한다. 그리고 SVM 알고리즘을 이용한 1단계 분류 방법과 SVM 알고리즘의 분류 결과를 다시 입력 시퀀스로 삼아 시계열 학습 알고리즘인 HMM에 적용하는 2단계 분류 방법의 실험 결과를 소개한다.

1. 서론

뇌파는 사람 또는 동물의 대뇌에서 일어나는 전기적 신호이다. 이러한 전기적 신호를 이용하여 사용자의 의도를 추정하고 이해한다면 사용자에게 다양한 분야에서 유용한 서비스를 제공할 수 있다. 신체적으로 결함이 있는 사용자 뿐만 아니라 뇌파를 이용한 학습 능력 검사 및 향상을 위한 소프트웨어도 개발되고 있으며 이를 위한 연구도 활발히 진행 중이다. 뇌파 신호를 측정하는 방법은 침습식과 비 침습식이 있다. 침습식 방법은 대뇌 피질에 직접 전극을 부착하여 전기적 신호를 측정하는 방법이다. 그렇기 때문에 눈의 깜박임 등과 같은 동작을 잡음 없이 선명하게 감지할 수 있다. 하지만 이와 같은 방식은 대뇌 피질에 직접 전극을 부착해야하기 때문에 일상생활에 적용하기에는 어려움이 있다. 반면 비 침습식 방법은 두피에 부착한 전극을 통해 전기적 신호를 측정하는 방법이다. 비 침습식 방법은 침습식 방법과 다르게 신호자체도 약하고, 잡음이 매우 심하다는 단점이 있다. 하지만 침습식 방법 보다 일상생활에 적용하기 간편해서 일반 사용자에게 쉽게 적용할 수 있다.

본 논문에서는 효과적인 뇌파 데이터 인식 방법으로 SVM(Support Vector Machine) 알고리즘과 HMM(Hidden Markov Model) 알고리즘을 근간으로 하는 2단계 분류 방법을 제안한다. 본 논문에서 제안하는 2단계 분류 방법의 성능 분석을 위해 Emotive Epoc API를 이용해서 PC에서 동작하는 데이터 수집 및 특징 추출 프로그램을 개발하였다. 이를 바탕으로 SVM 알고리즘만을 이용한 1단계 분류

방법과 시계열 학습 알고리즘인 HMM을 함께 적용한 2단계 분류 방법의 실험 결과를 소개한다.

2. 관련 연구

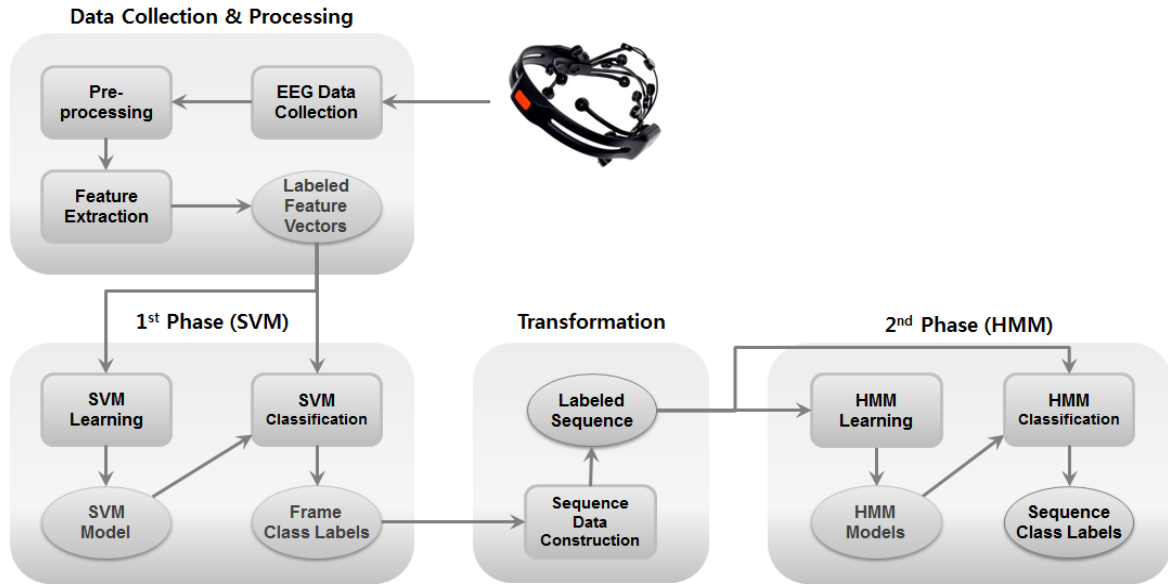
연구 [1]에서는 뮤 리듬(Mu Rhythm)을 이용하여 게임 속 캐릭터의 움직임 제어 한다. 뮤 리듬은 감각 운동 결절 부근에서 측정할 수 있는 8~12HZ 주파수 범위의 뇌파를 말한다. 좌뇌, 우뇌 피질의 비슷한 뇌 활동을 보일 경우 낮은 뮤(Low Mu)가 생성되고, 반대일 경우에는 높은 뮤(High Mu)를 생성한다. 뮤 파워(Mu Power)가 높고 낮음에 따라 게임 속 캐릭터의 움직임을 제어한다. 이 연구에서는 실험자의 이전 경험이나 적극적인 참여와 충분한 자극 등에 따라 뮤(Mu) 레벨 조절을 효율적으로 할 수 있다고 한다.

연구 [2]에서는 뇌파를 이용하여 온라인 3D 자동차 시뮬레이터를 제어하는 BCI(Brain Computer Interface)환경을 구축하였다. 명령 패러다임으로 감각운동리듬(SMR)방식을 사용하여 사용자로부터 왼손, 오른손, 양손에 대한 뇌파를 추출하였다. 이 연구에서는 감각운동리듬의 경우 사용자로부터 얻을 수 있는 정보에 한계가 있다고 밝혔다. 그렇기 때문에 사용자에게 원활하고 정교한 제어환경을 제공하기 위해서 보조 제어 모듈을 사용하였다.

연구 [3]은 뇌파를 기반으로 MDC(Movement Direction Classifier)와 IAC(Intentional Activity Classifier)를 이용해서 미로 탐색을 위한 인간형 로봇 제어를 하였다.

연구 [4]에서는 NeuroSky 헤드셋과 Emotive Epoc 헤드셋을 이용한 간단한 레고 로봇 제어 시스템을 제안하였다.

※ 본 연구는 경기도의 경기도지역협력연구센터사업의 일환으로 수행하였음



(그림 1) 전체 시스템 구성

3. 뇌파 분류 시스템


3.1 시스템 개요

본 논문에서는 로봇 제어 목적의 응용을 위해 분류 알고리즘인 SVM과 시계열 데이터 학습 알고리즘인 HMM을 이용하여 뇌파를 효과적으로 자동 분류 하는 방법을 제안한다. <표 1>은 ERST(Emotive Research SDK Tool)를 사용하여 뇌파 데이터를 수집한 환경을 나타낸다. 실험자가 Emotive Epoc 헤드셋을 착용한 상태에서 중앙에 위치한 상자를 각각 왼쪽과 오른쪽으로 보내기 위해 생각할 때 발생하는 뇌파 데이터를 수집한다. <표 2>는 인식하고자 하는 뇌파 종류 별 전기 기록도인 뇌전도 패턴을 나타낸 것이다. 이를 통해 뇌파가 종류별로 서로 다른 패턴을 보임을 알 수 있다.

<표 1> 데이터 수집 환경



<표 2> 뇌전도 패턴




뇌파 자동 분류를 위한 전체 시스템 구성은 (그림 1)과 같다. Emotive Epoc 헤드셋을 통해 각 종류 별 뇌파 데이터를 수집(EEG Data Collection)하고, 전 처리(Preprocessing)

단계를 수행한다. 그리고 시간 영역 분해 방식 기반의 FFT 알고리즘을 이용하여 특징 추출(Feature Extraction) 단계를 거쳐 특징 벡터(Labeled Feature Vector)를 만든다. 위 단계를 통해 만들어진 특징 벡터를 SVM 알고리즘을 기반으로 1단계 분류기 학습(1st Phase)을 수행한다. 그러나 뇌파와 같이 데이터 간에 시간 관계가 존재하는 경우, 분류 알고리즘인 SVM 만을 이용하여 자동 분류 하는 것은 적합하지 않다. 따라서 1단계 분류 결과(Frame Class Labels)를 일정한 고정 길이만큼 잘라서 시퀀스 데이터로 만들고 (Sequence Data Construction) 각 시퀀스 마다 라벨을 부착한다. 이 시퀀스(Labeled Sequence)를 입력 데이터로 삼아 시계열 학습 알고리즘인 HMM을 적용하는 2단계 분류기 학습(2nd Phase)을 수행한다. 위와 같은 과정을 통해 시퀀스 분류 결과(Sequence Class Labels)를 구한다.

3.2 데이터 수집 및 전 처리

실험자의 뇌파를 측정 하여 데이터를 수집하기 위해 Emotive사의 Epoc 헤드셋과 ERST를 사용하였다.

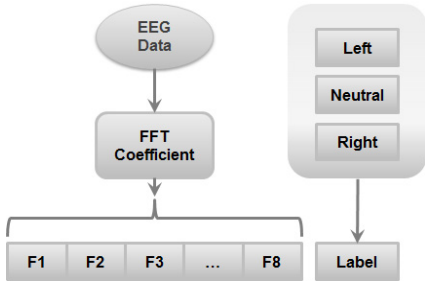


(그림 2) 사용 전극 및 채널

사람마다 측정되는 뇌파 데이터가 다르다. 그렇기 때문에 각 실험자는 ERST에 내장된 기능을 이용하여 실험자마다 선-훈련을 진행한다. 그 다음 (그림 2)에서 보는 바와 같이 Emotive Epoc 헤드셋의 총 14개 채널에서 발

생하는 뇌파 데이터를 수집한다.

전 처리 단계는 앞서 수집한 14개의 채널에서 발생한 뇌파 데이터 중 일부를 삭제하는 과정이다. 그 결과 (그림 2)에서 음영으로 표시된 8개 채널만 남겨서 8차원 데이터를 수집한다. 14개 채널에서 얻어진 데이터를 모두 사용하지 않고 8개 채널의 데이터만 사용하는 이유는 노이즈가 심한 채널을 제외하여 성능을 향상시키기 위함이다.




(그림 3) 특징 추출 과정

3.3 분류기 학습

분류기 학습 단계는 다시 SVM 알고리즘을 이용한 1단계 분류기 학습과 HMM 알고리즘을 이용한 2단계 시계열 분류기 학습으로 나누어 볼 수 있다. 먼저 앞선 단계에서 수집한 뇌파 데이터로부터 의미 있는 값을 추출하기 위한 특징 추출 단계가 수행된다. (그림 3)과 같이 FFT 알고리즘 중 시간 영역 분해 방식인 DIT(Decimation - in - time) Radix-2 FFT 방법으로 특징을 추출한다. 이를 통해 각 데이터 마다 8개의 특징과 실험자가 입력한 라벨이 포함된 특징 벡터를 만든다.

그 다음 위 단계에서 만든 특징 벡터 중 10%를 훈련 데이터, 90%를 테스트 데이터로 나누어 SVM 알고리즘을 이용한 1단계 분류기 학습을 수행한다. SVM 알고리즘은 분류(Classification)와 회귀(Regression)에 응용될 수 있는 지도학습(Supervised Learning)의 일종이다. 또한 이 알고리즘을 이용하면 분류 문제를 해결하기 위한 최적의 분류 경계면(Hyperplane)을 제공한다. 이처럼 분류 문제에 있어서 일반화 기능이 높기 때문에 많은 분야에서 응용되고 있다. 그러나 잡음(Noise) 또는 이상치(Outlier)로 인한 영향을 많이 받고, 데이터끼리 시간 관계가 존재하는 시계열 데이터와 같은 경우에 이 알고리즘을 사용하는 것은 적절하지 않다.


반면에 HMM 알고리즘은 시계열 데이터의 패턴을 인식하기 적절한 알고리즘이다. 또한 확률 이론을 바탕으로 두고 있어서 SVM 알고리즘과 신경망에 비해 수학적 기반이 탄탄한 장점이 있다. 이러한 장점 때문에 음성 인식, 온라인 필기체 인식, 제스처 인식 등에 이용된다. 또한 뇌파 데이터를 분류함에 있어서 HMM 알고리즘만을 이용할 경우 다차원 정규분포를 기반으로 하는 HMM 모델을 이용해야 한다. 이와 같은 경우 HMM 알고리즘의 학습 양이 폭발적으로 증가한다. 따라서 SVM 알고리즘 분류 결과를 HMM 알고리즘의 입력 데이터로 사용하면 일반화된 라벨을 구함과 동시에 차원 축소의 효과도 얻을 수 있다. 위와 같은 이유로 본 논문에서는 시계열 데이터의 일종인 뇌파를 효과적으로 분류하기 위해 SVM 알고리즘을 이용한 1단계 분류기 학습과 HMM 알고리즘을 이용한 2단계 시계열 분류기 학습 방법을 제안한다.



(그림 4) 시퀀스 데이터 형태

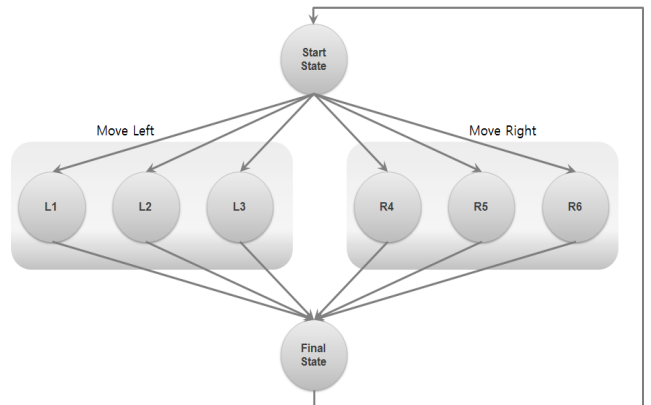
시퀀스 데이터는 (그림 4)와 같다. SVM 알고리즘을 통해 분류된 결과를 180개씩 고정 길이로 잘라서 시퀀스 데이터로 만들고 해당 라벨을 부착한다.

(그림 5)는 왼쪽(LEFT) 및 오른쪽(RIGHT) HMM 모델을 나타낸다. 상태 개수가 3개이고 관측 개수가 3개인 두 어고딕(Ergodic) 모델은 초기 파라미터를 랜덤하게 설정한다. 그리고 위에서 만든 시퀀스 데이터 중 10%를 훈련 데이터로 삼아 HMM 학습 단계를 수행한다.



(그림 5) 왼쪽(LEFT) 및 오른쪽(RIGHT) HMM 모델

(그림 6)은 중립 HMM 모델을 나타낸다. 이 모델은 학습 과정 없이 만든 모델이고 왼쪽과 오른쪽이 아닌 뇌파 데이터를 분류하기 위해 만든 모델이다. 이 모델은 시작 상태(Start State)와 끝 상태(End State)를 비롯하여 왼쪽 HMM 모델의 상태 3개와 오른쪽 HMM 모델의 상태 3개를 포함하여 총 8개의 상태와 3개의 관측을 가지는 모델이다[5]. 중립 HMM 모델의 확률 값은 각각 왼쪽 HMM 모델, 오른쪽 HMM 모델의 학습 과정을 통해서 얻어진 확률 값을 토대로 만들었다.



(그림 6) 중립(NEUTRAL) HMM 모델

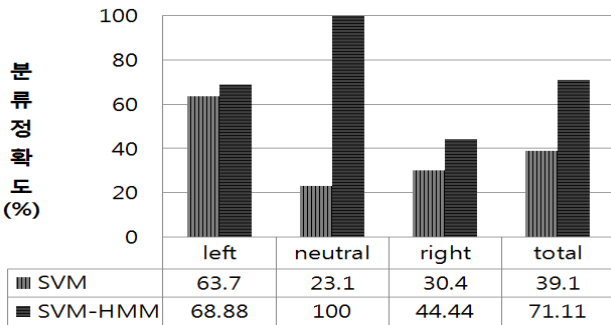
4. 실험 및 평가

본 논문에서 성능 평가를 위해 수집한 데이터 개수는 <표 3>과 같다. 인식 하고자 하는 뇌파 패턴의 종류는 3개이고 각 종류별로 54000개씩 총 151200개의 데이터를 수집하였다.

<표 3> 수집한 데이터 개수

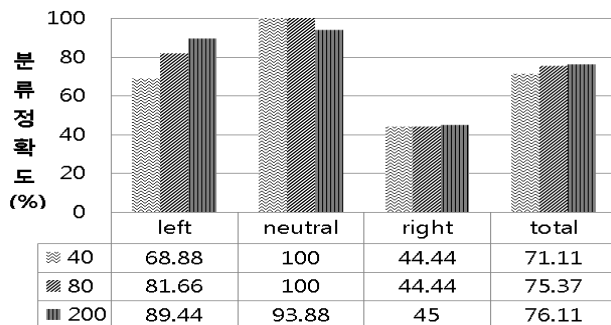
뇌파 패턴 종류	훈련 데이터 수	테스트 데이터 수	총 데이터 수
3 개	54000 개	97200 개	151200 개

앞서 제시한 뇌파 자동분류 방법을 이용하여 두 가지 실험을 수행하였다. 첫 번째 실험은 SVM 알고리즘을 이용한 1단계 분류 방법의 성능과 SVM 알고리즘과 HMM 알고리즘을 동시에 적용한 2단계 분류 방법의 성능 비교 실험이다. 먼저 10800개의 훈련 데이터와 97200개의 테스트 데이터를 가지고 SVM 알고리즘을 이용하여 성능 평가를 수행하였다. 그 다음 SVM 알고리즘 분류 결과를 다시 입력 시퀀스로 삼아 HMM 알고리즘에 적용하여 성능 평가를 하였다. HMM의 학습과 테스트를 위해 각각 180개의 라벨로 구성된 580개의 시퀀스 데이터를 생성하여 40개의 훈련 시퀀스 데이터와 540개의 테스트 시퀀스 데이터를 생성하였다.



(그림 7) 알고리즘 별 성능 평가

(그림 7)은 첫 번째 실험 결과를 나타낸다. 그래프에서 볼 수 있듯이 1단계 분류 방법은 평균 39.1%의 성능을 보였고, HMM을 함께 적용한 2단계 분류 방법은 1단계 분류 방법보다 약 32% 향상된 71.11%의 성능을 보였다. 중립에 대해서는 급격한 성능 향상을 보이고 왼쪽과 오른쪽 역시 소폭 상승한 모습을 보인다. 위의 결과에서 알 수 있듯이 SVM 알고리즘이 분류 문제에 있어서 일반화 기능이 높지만, 뇌파와 같은 시계열 데이터를 분류하기에는 적절하지 않다.



(그림 8) 훈련 데이터 수에 따른 성능 평가

두 번째 실험은 훈련 데이터 개수를 증가시키면서 2단

계 분류 방법을 수행한 실험 결과이다. SVM 알고리즘을 이용해 분류를 한 다음 분류 결과를 다시 입력 시퀀스 데이터로 삼아 HMM 알고리즘을 적용하는 2단계 분류 방법을 사용한다. 앞선 실험에서 사용한 훈련 시퀀스 데이터 40개를 80개, 200개까지 증가 시키며 성능 분석을 수행하였다. 테스트 데이터 수는 540개로 동일하다.

(그림 8)은 두 번째 실험 결과를 나타낸다. 그래프에서 볼 수 있듯이 훈련 개수가 증가함에 따라 분류 성능도 증가한 것을 볼 수 있다. 40개의 훈련 시퀀스 데이터를 사용했을 때 보다 200개로 증가시켰을 때 5%정도 향상된 성능을 보였다. 중립의 성능은 약 6% 정도 하락하고 오른쪽의 성능은 약 0.5% 소폭 증가 하였지만 왼쪽의 성능이 대폭 상승하였다. 기존의 68.88%에서 약 21% 증가한 89.44%의 성능을 보였다. 훈련 데이터 수의 증가가 성능 향상의 영향을 끼친다는 것을 알 수 있다.

5. 결론

본 논문에서는 Emotive Eloc 헤드셋 뇌파 측정 장비를 이용하여 뇌파 데이터를 수집하고, SVM 알고리즘과 HMM 알고리즘을 근간으로 하는 효과적인 뇌파 데이터 인식 방법을 제안하였다. 그리고 SVM 알고리즘만을 이용하여 분류하는 1단계 분류 방법과 SVM 알고리즘의 분류 결과를 다시 입력 시퀀스로 삼아 HMM 알고리즘을 적용하는 2단계 분류 방법을 소개하였다.

그 결과 1단계 분류 방법 보다 2단계 분류 방법이 71.11%로 약 32%의 성능 향상을 보였다. 또한 훈련 데이터 개수를 증가시키면서 성능 분석을 한 결과 기존보다 5% 정도의 성능 향상을 보였다. 본 논문에서는 왼쪽, 오른쪽, 중립 3가지 종류만 분류 하였기 때문에 로봇 제어를 하는데 부족함이 있다. 향후에는 위의 3가지뿐만 아니라 위(Up), 아래(Down)을 추가하여 NXT Lego Robot을 제어할 예정이다.

참고문헌

- [1] J. A. Pineda, D. S. Silverman, A. Vankov, and J. Hestenes, "Learning to Control Brain Rhythms: Making a Brain-computer Interface Possible," IEEE Trans. on Neural Systems and Rehabilitation Engineering, vol. 11, no. 2, pp. 181-184, 2003.
- [2] 이명춘, 조성배, "뇌전도 기반 3D 자동차 시뮬레이터 제어를 위한 뇌-컴퓨터 인터페이스 구현", 2012년 가을 학술발표논문집, vol. 39, No. 2(B), 2012
- [3] Chae, Y and Jeong, J, "Toward Brain-Actuated Humanoid Robots: Asynchronous Direct Control Using an EEG-Based BCI", IEEE Trans. on Robotics, vol 28, no. 5, Oct 2012
- [4] A. Vourvopoulos and F. Liarokapis, "Brain-controlled NXT Robot: Tele-operating a Robot through Brain Electrical Activity," Proceedings of the 3rd International Conference on Games and Virtual Worlds for Serious Applications, London, 2011.
- [5] H.K. Lee and J.H. Kim, "An HMM-Based Threshold Model Approach for Gesture Recognition," IEEE Trans. Pattern Analysis and Machine Intelligence, vol. 21, no. 10, pp. 961-973, Oct. 1999.