

연속적인 뇌파 분류를 위한 비음수 텐서 분해

(Nonnegative Tensor Factorization for Continuous EEG Classification)

이혜경[†] 김용덕[†]

(Hyekyoung Lee) (Yong-Deok Kim)

Andrzej Cichocki^{††}

(Andrzej Cichocki)

최승진^{†††}

(Seungjin Choi)

요약 본 논문에서는 연속적인 뇌파 분류를 위해 비음수 텐서 분해를 이용한 특징 추출과 비터비 알고리즘을 이용한 연속적인 데이터의 클래스 분류를 결합한 새로운 알고리즘을 제시한다. 비음수 텐서 분해는 이미 스펙트럼 데이터에 대해 뇌파의 주요한 특징을 잘 추출한다고 알려진 비음수 행렬 분해의 확장으로써 행렬이라는 제한된 틀에서 벗어나 데이터가 가지는 다양한 차원으로의 확대가 가능하다. 뇌-컴퓨터 인터페이스 컴퓨터션을 통해 공개된 데이터를 이용한 실험을 통해 제안된 방법의 유용함을 증명하도록 하겠다.

키워드 : 뇌파, 특징 추출, 패턴 분류, 비음수 텐서 분해, 비터비 알고리즘, 뇌-컴퓨터 인터페이스

- 이 논문은 2007년도 정부(과학기술부)의 재원으로 한국과학재단의 지원을 받아 수행된 연구임(No.R01-2006-000-11142-0)
- 이 논문은 제34회 추계학술대회에서 '연속적인 뇌파 분류를 위한 비음수 텐서 분해'의 제목으로 발표된 논문을 확장한 것임

[†] 학생회원 : 포항공과대학교 컴퓨터공학과
leehk@postech.ac.kr
karma13@postech.ac.kr

^{††} 비회원 : Brain Science Institute, RIKEN, Japan Laboratory for Advanced Brain Signal Processing Lab Head
cia@brain.riken.jp

^{†††} 종신회원 : 포항공과대학교 컴퓨터공학과 교수
seungjin@postech.ac.kr

논문접수 : 2007년 12월 14일
심사완료 : 2008년 4월 24일

Copyright@2008 한국정보과학회 : 개인 목적이나 교육 목적인 경우, 이 저작물의 전체 또는 일부에 대한 복사본 혹은 디지털 사본의 제작을 허가합니다. 이 때, 사본은 상업적 수단으로 사용할 수 없으며 첫 페이지에 본 문구와 출처를 반드시 명시해야 합니다. 이 외의 목적으로 복제, 배포, 출판, 전송 등 모든 유형의 사용행위를 하는 경우에 대하여는 사전에 허가를 얻고 비용을 지불해야 합니다.

정보과학회논문지: 컴퓨팅의 실제 및 레터 제14권 제5호(2008.7)

Abstract In this paper we present a method for continuous EEG classification, where we employ nonnegative tensor factorization (NTF) to determine discriminative spectral features and use the Viterbi algorithm to continuously classify multiple mental tasks. This is an extension of our previous work on the use of nonnegative matrix factorization (NMF) for EEG classification. Numerical experiments with two data sets in BCI competition, confirm the useful behavior of the method for continuous EEG classification.

Key words : EEG, Feature extraction, Pattern classification, Nonnegative Tensor Factorization, Viterbi algorithm, Brain Computer Interface

1. 서론

뇌-컴퓨터 인터페이스(Brain Computer Interface, BCI)는 피험자가 사지를 움직이지 않고 생각 만으로 컴퓨터나 휠체어, 기타 의료보조기구 등을 직접 움직이게 하는 새로운 휴먼 컴퓨터 인터페이스 방식이다. 이는 사지를 사용할 수 없는 장애인을 위해 고안되었으며, 최근 가상 현실 등에 응용될 수 있는 가능성이 제시되고 있다[1].

뇌로부터 인간의 생각을 측정하는데 가장 널리 사용되고 있는 것이 바로 EEG이다. EEG는 다변량 시계열 데이터로써 뇌의 피질에서 발생하여 두피까지 전달된 전기적 신호들을 두피에 부착된 전극을 통해 측정된다. 뇌신호 정보는 주로 주파수 성분으로 표현되며 전극의 위치에 따라 뇌의 기능과 상관 관계를 갖게 된다.

대표적으로 알려진 주파수 특징으로 event-related synchronization(ERS)와 event-related desynchronization(ERD)라 불리는 움직임과 관련된 현상이 있다. ERD는 움직임을 준비하거나 움직임을 상상할 때 감각 운동피질(sensori-motor cortex)에서 일시적으로 mu rhythm(8-12 Hz)이 감쇠하는 현상이고, ERS는 움직임 후에 beta rhythm(18-25 Hz)이 일시적으로 증가하는 현상을 가리킨다[2]. 이러한 현상은 피험자에 따라 다른 주파수 영역에서 나타날 수 있으며, 실제로 어떤 피험자에게는 8-12 Hz가 아닌 16-20 Hz에서 ERD 현상이 발생했다는 실험 결과도 있다[3].

최근 움직임을 상상하는 것뿐만 아니라 단어 인지, 생성이나 수학 연산과 같은 인지 과정을 추가하려는 시도가 잇따르고 있다. 이러한 지각/인지와 관련되어 알려진 주파수 특징으로는 중앙과 뒤측 피질에서 발생하는 gamma rhythm(30-100 Hz)과 기억과도 관계있는 것으로 알려진 전두엽 부근의 theta rhythm(3-7 Hz)이 있다. 그러나 ERD/ERS와 같이 또렷하게 나타나는 현상이 아니며, 피험자에 따라 큰 반응의 편차가 있는 것으로 알려져 있다. 이를 추출하기 위해서는 이미 알려진

특징을 기본 자식으로 하되 해당 자극의 유효한 특징을 자동으로 찾아내는 알고리즘이 필요하다.

본 논문에서는 주파수 특징이 비음수라는데 차안하여 선형 데이터 모델에 비음수 조건이 추가된 비음수 행렬 분해(nonnegative matrix factorization, NMF) 방법과 이를 텐서로 확장한 비음수 텐서 분해(nonnegative tensor factorization, NTF) 방법을 뇌파의 특징 추출 알고리즘으로 제안하였으며, 연속적인 뇌파의 분류를 위해 비터비 알고리즘(Viterbi algorithm)을 적용한 패턴 분류 방법을 제안하였다. 2장에서는 NMF와 NTF에 대해 간략하게 설명하고, 3장에서는 이를 기반으로 한 특징 추출 방법을 제안하겠으며, 4장에서는 BCI competition에서 공개된 2개의 dataset을 이용하여 분류한 결과를 보이도록 하겠다. 5장에서는 결론으로 마치겠다.

2. 비음수 텐서 분해

선형 데이터 모델은 가장 널리 쓰이는 다변량 데이터 분석 방법으로써 $X \in \mathbb{R}^{d \times n}$ 를 n 개의 d -차원 관찰 벡터가 모인 행렬이라고 할 때, $X = AS$ 의 식으로 표현할 수 있다. X 를 구성하는 r 개의 기본 벡터 행렬을 $A \in \mathbb{R}^{d \times r}$ 이라 하고, 기본 벡터들의 구성 정도를 가중치로 갖는 행렬을 $S \in \mathbb{R}^{r \times n}$ 라고 한다.

NMF는 선형 데이터 모델에 비음수 조건($X, A, S > 0$)을 추가한 것이다[4,5]. A 의 비음수 기본 열벡터들에 S 에 속한 각각의 가중치가 항상 덧셈으로 곱해지기 때문에 기본 벡터들은 관찰 데이터들의 부분 성질을 잘 표현하는 듯성듬성한 성분을 갖고 있다. 뇌파에서 가장 널리 사용되는 웨이블릿 변환이나 원도우 푸리에 변환(short-time Fourier transform, STFT)을 통한 시간-주파수 표현은 모두 비음수 특징을 갖기 때문에 NMF를 이용한 특징 추출에 적합하다[6].

다원 분석(multi-way analysis)은 위에서 언급한 행렬의 선형 모델을 텐서로 확장한 것으로써 관찰 데이터가 $\mathbf{X} \in \mathbb{R}^{n_1 \times n_2 \cdots \times n_N}$ 의 N -way 텐서로 주어졌을 때 각 차원에 대한 컴포넌트 행렬 $A^{(1)}, A^{(2)} \dots A^{(N)}$ 을 이용하여 $\mathbf{X} = \mathbf{I} \times_1 A^{(1)} \times_2 \cdots \times_N A^{(N)}$ 으로 표현할 수 있다. (\times_n 은 mode n multiplication) 따라서 각 차원을 주파수, 채널, 시간, 클래스 등에 해당하는 것으로 지정한다면, 각각에 해당하는 주요한 컴포넌트를 구할 수 있다.

3. 제안된 알고리즘

뇌파 분류를 위해 제안된 알고리즘은 (1) 시간-주파수 표현으로 변환하는 전처리 과정, (2) NTF를 기반으로 하는 특징 추출 과정, (3) 패턴 분류 과정의 세 과정으로 나눌 수 있다.

3.1 데이터 설명

실험을 위해 사용한 데이터는 BCI competition II에 공개된 dataset III[7,8]와 BCI competition III에 공개된 dataset V이다[9]. 전자는 오스트리아의 Graz 공과대학 교에서, 후자는 스위스의 IDIAP research institute에서 측정되었으므로 편의상 각각 Graz dataset과 IDIAP dataset이라고 부르겠다.

Graz dataset의 경우 오른손과 왼손의 움직임을 상상하는 과제를 수행하여 C3, Cz, C4 3개의 채널에서 측정한 각 140개의 trial로 구성되어 있다. 본 실험에서는 C3, C4, 두 개의 채널만 사용할 것이다. IDIAP dataset의 경우 3명의 피험자로부터 오른손, 왼손의 움직임을 상상하는 태스크와 더불어 임의로 주어진 알파벳으로 시작하는 단어를 연상하는 태스크를 추가로 수행하였다. 본 dataset은 휴식-집중-태스크의 정형화된 실험을 수행하는 것이 아니라 임의의 길이로 태스크가 변경되는 연속적인 뇌파이다. 데이터는 2 Hz 해상도로 8-32 Hz 사이의 시간-주파수 표현으로 주어져있으며 C3, Cz, C4, CP1, CP2, P3, Pz, P4, 8개의 채널에서 측정되었다.

3.2 전처리 과정

여기서는 시계열 신호로 주어진 뇌파를 시간-주파수 표현으로 변환하고, 라벨이 주어진 데이터와 그렇지 않은 데이터를 이용하여 $\mathbf{X}_{train}, \mathbf{X}_{test}$ 텐서를 구성한다.

[Graz dataset] complex Morlet wavelet을 이용하여 시간-주파수 표현으로 변환한 후 데이터 텐서 $\mathbf{X} \in \mathbb{R}^{27 \times 2 \times 2 \times T \times K}$ 를 만든다. 각각의 성분은 $\mathbf{X}_{f,i,c,\tau,k} = x(f, i, c, \tau, k)$ 이고, $f \in \{4, 5, \dots, 30\}$ Hz, $i = 1, 2$ (각각 C3, C4 채널을 의미), 각 trial 안의 데이터 포인트를 뜻하는 $\tau = 1, \dots, T$ (T 는 한 trial 안의 데이터 개수), $c = 1, 2$ (각각 오른손/왼손의 움직임을 상상한 것을 의미하는 인덱스), trial을 가리키는 $k = 1, \dots, K$ (K 는 총 trial의 개수)를 뜻한다.

[IDIAP dataset] 이 경우에는 이미 시간-주파수 표현으로 변환된 데이터가 주어져있기 때문에 전처리 과정에서 normalization만 수행하고 텐서, $\mathbf{X} \in \mathbb{R}^{12 \times 8 \times 3 \times T}$ 를 구성한다. 이 때, 각 컴포넌트는 주어진 성분 $P_i(f, c, t)$ 을 이용하여 $\mathbf{X}_{f,i,c,t} = \frac{P_i(f, c, t)}{\sum_f P_i(f, c, t)}$ 로 구할 수 있다. 이 때,

$f \in \{8, 10, \dots, 28, 30\}$ Hz, 8개 채널을 의미하는 $i = 1, 2, \dots, 8$, 왼손, 오른손의 움직임을 상상하고, 단어 생성 태스크를 가리키는 $c = 1, 2, 3$, 각각의 time point를 의미하는 $t = 1, \dots, T$ (T 는 데이터 포인트의 개수)이다. 이 데이터 셋에는 trial 구조가 없어 이에 해당하는 인덱스는 없다.

3.3 특징 추출

현재 Graz dataset의 경우 $\mathbf{X} \in \mathbb{R}^{27 \times 2 \times 2 \times T \times K}$ 의

5-way로 구성되어 있고, IDIAP dataset의 경우 $\mathbf{X} \in \mathbb{R}^{12 \times 8 \times 3 \times T}$ 의 4-way로 구성되어 있다. 본 논문에서는 이를 변형하여 다양한 형태의 텐서를 구성할 것이며, NTF를 수행하였을 때의 결과를 관찰할 것이다.

[데이터 선택] training 과정에서는 정보가 없거나 잘못 측정된 데이터를 버리고, 각 클래스를 판별하는데 있어 더 효과적인 데이터를 선택하는 과정을 거친다. 이 때 텐서에 T 에 해당하는 인덱스가 있는, 즉, trial 구조가 있는 $\mathbf{X} \in \mathbb{R}^{27 \times 2 \times T \times 2K}$ 로 변형할 경우(표 1 참조) 데이터 선택의 과정을 거치면, T 의 개수가 일정치 못하므로 이 경우는 데이터 선택 과정을 거치지 않는다.

데이터 선택은 최근접이웃(the nearest neighbor) 방법을 사용하였다. 예를 들어, 텐서 $\mathbf{X} = [\mathbf{x}_{f,i,c,t,k}]$ 가 주어졌을

때 각각의 클래스 c 에 대한 평균값 $\bar{\mathbf{X}}_c$ 을 $\bar{\mathbf{X}}_c = \sum_{t=1}^T \sum_{k=1}^K \mathbf{x}_{\cdot,\cdot,c,t,k}$

로 구한다. Graz dataset의 경우, $\bar{\mathbf{X}}_c \in \mathbb{R}^{27 \times 2}$ ($c=1, 2$) 이 될 것이다. 데이터 선택의 과정은 각각의 클래스에 대해 평균값에 가장 근접하는 슬라이스, $\mathbf{x}_{\cdot,\cdot,c,t,k}$, T_s 개를 뽑는 것으로 이루어진다. 본 논문에서는 Graz dataset의 경우 TK 개의 슬라이스 중 43%를 넘지 않는 개수를 선택하였으며, IDIAP dataset의 경우 7개의 슬라이스 중 95%를 넘지 않는 개수를 선택하였다. Graz dataset을 적게 선택한 것은 단어 생성의 클래스가 추가됨에 따라 클래스 판별이 분명치 않음을 의미한다. 최근접이웃 방법을 이용한 데이터 선택 과정은 태스크의 주파수 특성이 잘 알려져 있지 않을 때 매우 유용하다.

[NTF를 기반으로 한 특징 추출] 표 1과 같이 다양한 형태의 데이터 텐서를 구성하였다. 예를 들어, Graz dataset에서 2-way 텐서를 구성할 경우, 데이터 선택의 과정에서 선택된 데이터 T_s 개를 주파수와 채널에 해당하는 차원을 하나로 합쳐 텐서 $\mathbf{X} \in \mathbb{R}^{54 \times 2T_s}$ 를 구성한다. 표 1에 나타난 각각의 텐서에 NTF를 적용하면, 컴포넌트 행렬 $A^{(n)}$ 를 구할 수 있다. 이 때, N -way 텐서일 때 $n=1, \dots, N$ 의 컴포넌트 행렬이 존재한다. NMF의 경우 $\mathbf{X} = \mathbf{AS}$ 이므로 기본 행렬은 $A^{(1)} = \mathbf{A}$, 특징 행렬(feature matrix)은 $A^{(2)} = \mathbf{S}^T$ 이 된다. 이와 마찬가지의

방법으로 NTF에 적용해보면, N 번째 컴포넌트 행렬 $A^{(N)}$ 이 바로 특정 행렬이 된다는 것을 알 수 있다. 테스트 데이터 \mathbf{X}_{test} 가 주어져 있을 때, \mathbf{X}_{test} 을 모드- N 행렬화하여 $[\mathbf{X}_{test}]_{(N)}$ 을 구하고, training 과정에서 구한 $S_A^{(N)}$ 을 이용하여 NMF와 같이 $\mathbf{A}^{(N)} \mathbf{S}_A^{(N)} = [\mathbf{X}_{test}]_{(N)}$ 와 같은 식을 구성할 수 있다. 특정 행렬 $S_A^{(N)}$ 은 두 가지 방법으로 구할 수 있다. (1) 의사역행렬을 이용하여 $[\mathbf{X}_{test}]_{(N)} [S_A^{(N)}]^\dagger$ 을 구하는 방법이다. 이런 경우 $A^{(N)}$ 의 비음수 조건을 보장할 수는 없지만 특정 추출 과정에서는 이를 허용하여 널리 사용하고 있다. (2) NTF 알고리즘 중에 다른 컴포넌트 행렬 $A^{(n)}$ ($n=1, \dots, N-1$)의 값을 고정시키고 $A^{(N)}$ 만 학습시키는 방법이다.

실제로 두 가지 방법을 적용했을 때 첫 번째 방법의 결과가 1-2% 정도 나아졌으므로 의사역행렬을 이용한 방법을 사용하도록 하겠다. 테스트 데이터의 경우 클래스에 대한 정보가 주어져있지 않기 때문에 표 1의 4-way 텐서(클래스)를 구성하기 어렵다. 이 경우에는 클래스 라벨에 해당하는 3번째 차원에 대해서 클래스 개수만큼 반복하여 채워 넣은 텐서를 구성하였다.

[패턴 분류] Graz dataset의 경우 각 trial에 대한 실시간 분류 방법으로 [8]에 제안된 방법을 사용하였다. 이는 가우시안 확률 모델을 trial 내의 각 time point마다 구하고, 매 time point의 가우시안 확률 모델의 분류 결과에 따라 각 시간별 분류 모델의 신뢰도를 정한다. 시간 t 에서 분류는 $1, \dots, t$ 에서의 가우시안 분류 모델들에 각각 신뢰도를 곱하여 합한 결과에 의해 결정하게 된다. 그러나 표 1에서 4-way 텐서(time)의 경우 시간에 따른 의존도 역시 하나의 컴포넌트 행렬로 구할 수 있기 때문에 신뢰도 계산이 불필요하다. 이런 경우 테스트 데이터 $\mathbf{X} \in \mathbb{R}^{27 \times 2 \times t \times 1}$ 를 모드-4 행렬화한 $\mathbf{X}_{(4)} \in \mathbb{R}^{1 \times 54t}$ 와 컴포넌트 행렬 $A^{(1)} \in \mathbb{R}^{27 \times R}, A^{(2)} \in \mathbb{R}^{2 \times R}, A_{(1:t,:)}^{(3)} \in \mathbb{R}^{t \times R}$ 를 이용하여 기본 행렬 $S_A^{(4)} \in \mathbb{R}^{R \times 54t}$ ($S_A^{(4)} = A^{(3)} \odot A^{(2)} \odot A^{(1)}$)을 구하고, 이를 이용하여 특징 행렬을 구하면 신뢰도 계산 없이 바로 가우시안 확률 모델을 구함으로써 분류기를 구성할 수 있다. (○는 Khatri-Rao products)

IDIAP dataset의 경우 trial 구조를 갖지 않은 연속적인 데이터가 주어져있으므로 위와 같은 분류는 적합하지 않다. 본 논문에서는 이러한 경우에 비터비 알고리즘(Viterbi algorithm [10], 그림 1)을 분류기로 사용할 것을 제안한다. 비터비 알고리즘은 관찰된 데이터가 온닉 상태에 의해 생성된 것이고, 이 온닉 상태가 시간에 대해 의존적이라는 것을 가정한 모델로 시계열 데이터의 분석에 널리 사용되고 있다. 우리의 경우에는 온닉 상태

표 1 NTF에 사용될 N-way 텐서의 구성

N -way 텐서	Graz	IDIAP
2	$\mathbf{X} \in \mathbb{R}^{54 \times 2T_s}$	$\mathbf{X} \in \mathbb{R}^{96 \times 3T_s}$
3	$\mathbf{X} \in \mathbb{R}^{27 \times 2 \times 2T_s}$	$\mathbf{X} \in \mathbb{R}^{12 \times 8 \times 3T_s}$
4 (시간)	$\mathbf{X} \in \mathbb{R}^{27 \times 2 \times T \times 2K}$	
4 (클래스)	$\mathbf{X} \in \mathbb{R}^{27 \times 2 \times 2 \times T_s}$	$\mathbf{X} \in \mathbb{R}^{12 \times 8 \times 3 \times T_s}$

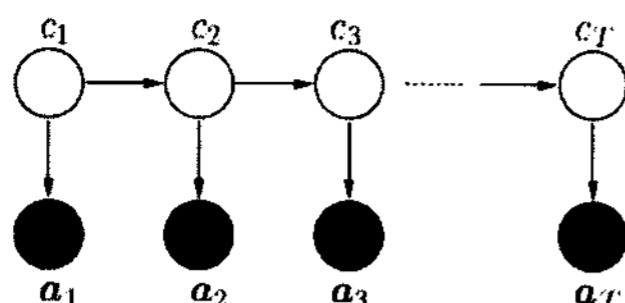


그림 1 비터비 알고리즘

가 바로 클래스 정보라고 가정하고 ($c_t \in \{1, 2, 3\}$), 시간에 대해 의존적인 클래스 정보에 의해 특징 벡터(특징 행렬의 열벡터)가 관찰된다고 가정하였다.

4. 실험결과

4.1 NMF와 NTF의 비교

그림 2는 기본 행렬 $S_A^{(N)}$ 의 열벡터를 그린 것이다. 첫 번째 줄부터 NMF, 3-way 텐서, 4-way 텐서(클래스)를 수행하였을 때의 결과를 나타내며, 좌로부터 기본 벡터의 개수를 2, 4, 5, 6개로 각각 늘렸을 때를 그린 것이다. 각각의 그림은 위와 아래 두 개로 분리하여 생각할 수 있으며, 상단은 C3 채널의, 하단은 C4 채널의 기본 성분들을 의미한다. (a)부터 (d)까지의 그림은 각각 기본 벡터의 개수를 2, 4, 5, 6 개로 늘렸을 때 NMF의 결과이고, 하얀색 일수록 큰값을, 검은색 일수록 0에 가까운 값을 갖는다. 기본 벡터의 개수가 2개일 경우 (a) mu rhythm에 해당되는 8-12 Hz 부근이 C3, C4 채널에 대해 각각 붉게 나타나는 기본 벡터가 추출되었고, 4 개일 경우 (b) 여기에 beta rhythm(18-22 Hz)이 추가되며, 6개의 경우 (d) 감각 운동 리듬(sensori-motor rhythm, 12-16 Hz)이 이어서 추출됨을 알 수 있다. (e)에서 (f)까지는 주어진 데이터 텐서가 $\mathbf{X} \in \mathbb{R}^{freq. \times channel \times trial}$ 일 때 3-way 텐서, $S_A^{(3)}$ 의 결과를 보여주는 것이다. (e)의 경우 8-12 Hz의 mu rhythm 이 첫 벡터에 동시에 나타나고, 다음 벡터에는 18-22 Hz의 beta rhythm 이 역시 C3, C4 채널에 동시에 출현한다. 주요한 특징이 추출된 순서는 NMF의 경우와 같다. (i)부터 (l)까지는 4-way 텐서(클래스), $\mathbf{X} \in \mathbb{R}^{freq. \times channel \times class \times trial}$ 의 NTF 결과를 그린 것이다. 두 줄로 구성되어 있는 것은 상단이 원손 클래스, 하단이 오른손 클래스에 해당하는 것이기 때문이다. 각각의 작은 그림들에 대한 설명은 위와 동일하며, 원손의 경우 C3 채널 쪽이, 오른손의 경우 C4 채널 쪽이 더 활성화된 기본 벡터가 추출되었다.

4.2 분류 결과

Graz data의 경우 4-way NTF를 적용했을 때 5.36 초에서 88.57%의 NMF와 같은 최대 분류 결과를 보였고, 3-way NTF는 같은 시간에 81.51%의 상대적으로 작은 분류 결과를 보였다. 이는 그림 2에서 본 것과 같이 좀더 성기고, 직교성이 있는 기본 벡터에 대해 더 좋

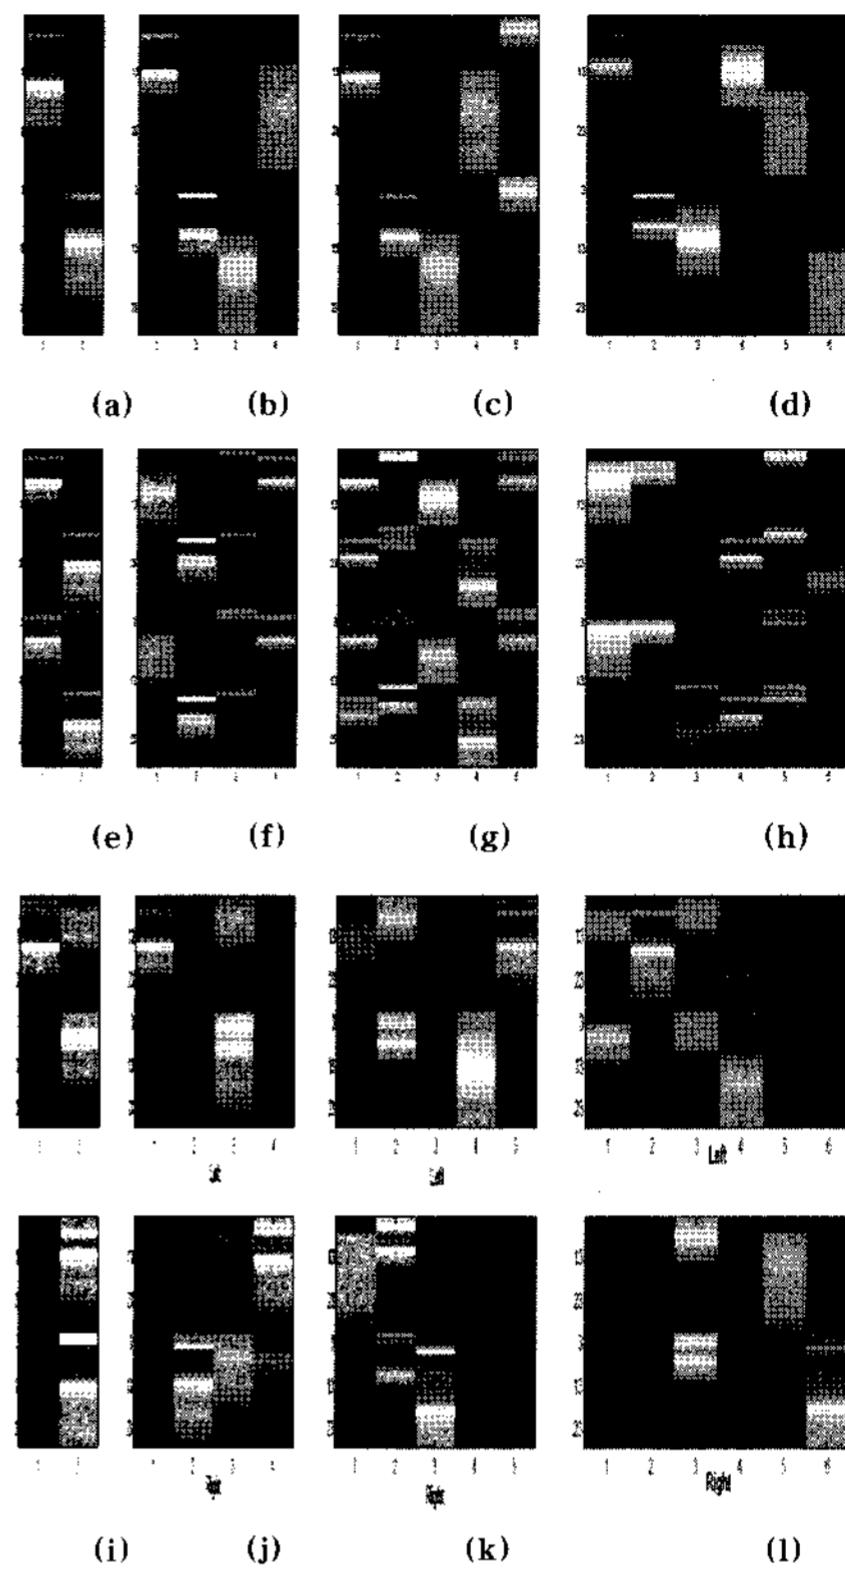


그림 2 기본 벡터들

은 특징 벡터가 추출되었기 때문인 것으로 보인다. 그림 3은 4-way NTF(시간)에서 시간에 따른 기본 벡터를 NTF를 통해 자동으로 구한 결과(푸른선)와 가우시안 확률 분포 모델의 분류 결과를 통해 시간에 따른 분류 신뢰도를 구하고 이를 이용하여 분류한 결과(붉은점선)를 보여주는 그림이다. NMF의 최대 결과보다는 1% 정도 낮지만 클래스 정보 없이 NTF를 통해 자동으로 구한 시간에 따른 중요도가 어느 정도 신뢰할만한 것임을 알 수 있다. 표 2는 IDIAP data에 대한 분류 결과를 보여준 것이다. 상단의 'without Viterbi'는 시간 의존도를 고려하지 않은 가우시안 확률 모델을 이용하여 분류한 결과이고, 'with Viterbi'는 비터비 알고리즘을 이용한 결과이다. 그리고 맨 하단의 'BCI Comp. winner'는 BCI competition III에서 해당 데이터에 대해 우승한 팀의 분류 결과를 보여준 것이다. 이를 통해 비터비 알고리즘을 사용한 경우 결과가 확실히 나아짐을 확인할 수 있다. 그림 4는 첫 번째 피험자의 시간에 따른 분류 결과를 보여준 그림이다. x축은 시간을 의미하며, y축은 클래스를 의미한다. 검은실선은 실제 클래스이고, 초록색 채워진 원, 붉은색 X, 푸른색 빙은 원은 각각 단어 생성과 오른손, 원손의 움직임을 상상한 것에 대한 분류

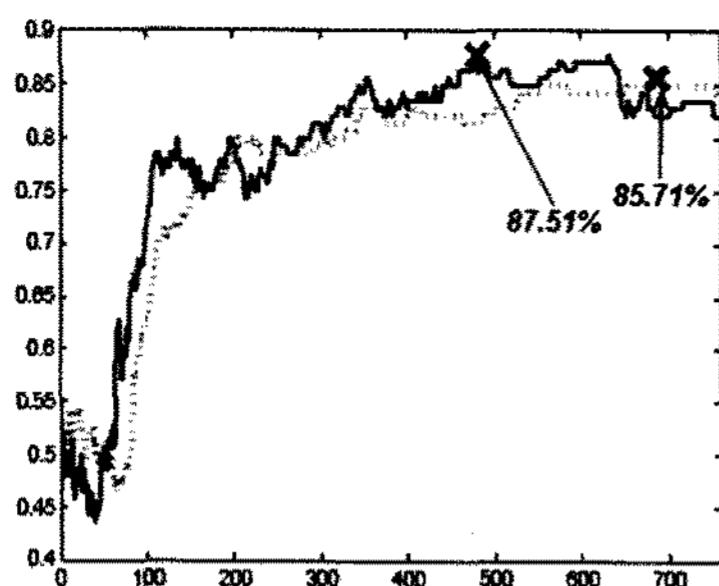


그림 3 시간에 따른 4-way NTF (시간)의 분류 결과

결과를 보여준다. 실선과 같은 라인에 위치한 것이 맞게 분류된 것이고, 그렇지 않은 것은 잘못 분류된 것이다. 피험자 1의 결과가 좋은 것은 피험자 1에 더 많은 정보량이 포함되었기 때문이다. NTF가 NMF보다 더 좋은 결과를 갖는 것을 통해 정보량이 적은 데이터에 대해 유효한 특징을 더 잘 추출하는 것으로 추측할 수 있다.

5. 결 론

본 논문에서는 NTF를 기반으로 한 특징 추출 방법과 비터비 알고리즘을 이용한 연속적인 뇌파 분류 방법을 소개하였다. 선형 데이터 모델을 이용함으로써 데이터 모델로부터 여러 차례의 실험에 의한 비교가 아니라 자동으로 주요한 성분을 추출할 수 있게 되었다. NMF는 이러한 선형 모델에 비음수 조건을 추가한 것으로 시간-주파수로 표현 가능한 데이터에 대해 좋은 특징 추출 방법으로 사용되고 있다. 본 논문에서는 이를 확장시킨 NTF 방법을 뇌파에 특징 추출에 적용함으로써 주파수, 시간, 채널에 대해서 각각 유효한 기본 성분들을 추출할 수 있음을 보였다. trial 구조는 실제 인간의 인지과정은 휴식-집중-태스크 순으로 발생하지 않으므로 뇌파 측정 실험에 있어 제한적인 요건 중에 하나이다. 본 논문에서는 이에 적합한 분류 알고리즘으로 은닉 상태에 클래스 정보를 대입한 비터비 알고리즘을 제안함으로써 연속적인 뇌파 분류에 희망적인 결과를 보여주었다.

표 2 IDIAP 데이터의 분류 결과

	sub1	sub2	sub3	avg
without Viterbi				
NMF ($\alpha = 0$)	75.34	39.63	38.53	51.17
NTF (3-way)	75.57	62.67	50.69	62.98
NTF (4-way)	77.63	65.67	52.52	65.27
with Viterbi				
NMF ($\alpha = 0$)	86.07	67.97	51.61	68.55
NTF (3-way)	85.62	69.35	53.44	69.47
NTF (4-way)	85.62	71.66	53.44	70.24
BCI comp. winner	79.60	70.31	56.02	68.65

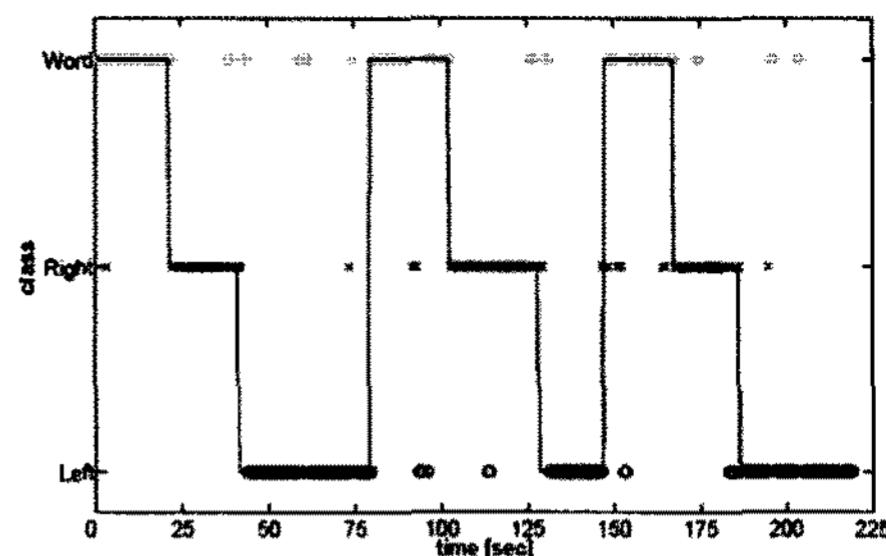


그림 4 IDIAP 데이터의 시간에 따른 분류 결과

참 고 문 헌

- [1] T. Ebrahimi, J.-F. Vesin, and G. Garcia, "Brain Computer interface in multimedia communication," IEEE Signal Processing Magazine, 20(1):14–24, 2003.
- [2] J.R. Wolpaw, N. Birbaumer, D.J. McFarland, G. Pfurtscheller, and T.M. Vaughan, "Brain-computer interfaces for communication and control," Clinical Neurophysiology, 113:767–791, 2002.
- [3] T.N. Lal, M. Schroder, T. Hinterberger, J. Weston, M. Bogdan, N. Birbaumer, and B. Scholkopf, "Support vector channel selection in BCI," Technical Report 120, Max Planck Institute for Biological Cybernetics, 2003.
- [4] D.D. Lee and H.S. Seung, "Learning the parts of objects by non-negative matrix factorization," Nature, 401:788–791, 1999.
- [5] D.D. Lee and H.S. Seung, "Algorithms for non-negative matrix factorization," Advances in Neural Information Processing Systems, 2001.
- [6] H. Lee, A. Cichocki, and S. Choi, "Nonnegative matrix factorization for motor imagery EEG classification," Proc. Int'l Conf. Artificial Neural Networks, 2006.
- [7] B. Blankertz, K.-R. Muller, G. Curio, T.M. Vaughan, G. Schalk, J.R. Wolpaw, A. Schlogl, C. Neuper, G. Pfurtscheller, T. Hinterberger, M. Schroder, and N. Birbaumer, "The BCI competition 2003: Progress and perspectives in detection and discrimination of EEG single trials," IEEE Trans. Biomedical Engineering, 51(6), 2004.
- [8] S. Lemm, C. Schafer, and G. Curio, "BCI competition 2003-data set III: Probabilistic modeling of sensorimotor mu rhythms for classification of imaginary hand movements," IEEE Trans. Biomedical Engineering, 51(6), 2004.
- [9] J. del R. Millan, "On the need for on-line learning in brain-computer interfaces," Proc. Int'l Joint Conf. Neural Networks, 2004.
- [10] G.D. Forney, "The Viterbi algorithm," Proc. of the IEEE, 61:268–278, 1973.