

# fMRI를 이용한 맛의 입력패턴벡터 추출 및 패턴인식

## — Input Pattern Vector Extraction and Pattern Recognition of Taste using fMRI —

한림성심대학 방사선과 · 강원대학교 산업공학과<sup>1)</sup>

이선엽 · 이용구 · 김기동<sup>1)</sup>

### — 국문초록 —

본 논문에서는 맛 인식을 위한 입력패턴벡터를 추출하고 패턴인식을 위한 맛(쓴맛, 단맛, 신맛, 짠맛) 학습 알고리즘을 설계하였다. 입력패턴벡터의 구성을 위해 맛 활성화 신호의 세기가 사용되었고, 맛 패턴인식을 위한 알고리즘은 초기 참조벡터의 학습을 위해 SOM을 이용하였고, 종속 부류층의 출력뉴런의 부류지정을 위하여 out-star 학습법을 사용하였다. 제안된 알고리즘의 입력 층과 종속 클래스 층 사이의 연결강도는 SOM과 LVQ 알고리즘을 이용하여 초기 참조벡터의 설정 및 학습이 가능하게 하였다. 패턴벡터는 종속 부류층의 뉴런에 의해 종속 클래스로 분류하고, 종속 클래스 층과 출력 층 사이의 연결강도는 분류된 종속 부류를 클래스로 지정하는 학습을 하게 하였다. 패턴 분류를 위하여 제안된 학습알고리즘을 이용하여 시뮬레이션 되었고 기존의 LVQ 학습방식보다 우수한 분류성공률을 확인하였다.

중심 단어 : 맛 활성화, 패턴벡터추출, 학습벡터양자화(LVQ), 패턴분류

## I. 서 론

1946년에 Felix Bloch와 Purcell 등이 독립적으로 NMR 현상을 발견함으로써 NMR(Nuclear Magnetic Resonance)에 대한 기초가 형성되었고, 1950년대에 들어서면서 이론에 대한 실험적 검증이 실시되고, 이를 검증한 공로로 1952년 Felix Bloch와 Edward M. Purcell이 노벨 물리학상을 수상하였다. 이를 기반으로 1960년대에는 NMR Spectroscopy(NMR 물질 분석 장치)라는 장비를 개발하여 Bloch 이론에 대한 실험적 검증이 이루어졌다.

1967년에는 Jasper Jackson이 핵 자기공명현상을 인체에 적용해 보자는 이론을 제시하였으며, 같은 시기에

미국의 공학자이며 물리학자인 Raymond Damadian이 “악성조직과 정상조직의 분석 Spectrum이 다르다”는 것을 발표하였다. 또한 쥐의 뇌를 Scan하여 얻은 영상을 Science 잡지에 발표하였다. 이러한 노력으로 MRI (Magnetic Resonance Imaging)의 임상이용기초가 되었다<sup>1)</sup>.

그 후 컴퓨터 산업의 발달로 1980년대에 들어와서 급속히 MRI 장치의 하드웨어 및 소프트웨어의 발전을 가져와 의학영상 진단의 발전과 함께 자기공명영상은 눈부시게 발전하였으며, 최근에는 뇌 질환과 혈관질환 등 치매 분야 뿐만 아니라 의료영상분야에서의 최고 기능인 기능적 자기공명영상인 fMRI(functional Magnetic Resonance Imaging)까지 가능하게 되었다<sup>2,3)</sup>.

fMRI는 운동이나 감각, 시각, 청각 및 언어증추의 연구, 그리고 고위 인지기능에 이르기까지 활발한 연구가 이루어져 왔다<sup>4)</sup>.

fMRI는 일정한 자극을 주거나 특정한 영역의 과제를

\* 이 논문은 2007년 9월 13일 접수되어 2007년 10월 1일 채택 됨.  
책임저자: 이선엽, (200-853) 강원도 춘천시 동면 장하리 790번지  
한림성심대학 방사선과, TEL: 033-240-9351  
C.P.: 010-6382-7917, FAX: 033-240-9354  
E-mail: sunyeob@hanmail.net & leesunyeob@nate.com

수행할 때 활성화되는 뇌기능을 영상화하는 방법으로 비 침습적이고 반복적으로 뇌기능을 검사할 수 있는 장점을 가지고 있다.

fMRI에 가장 널리 사용되고 있는 BOLD(Blood Oxygenation Level Dependent)기법의 원리는 대뇌피질의 활성화에 동반된 deoxyhemoglobin의 농도변화를 이용하여 활성화된 대뇌피질을 영상으로 보여주는 기법이다<sup>6)</sup>.

이러한 경향에 발맞추어 최근에는 신경회로망과 같은 인공지능 알고리즘을 사용하여 생체신호에 대한 첨단 신호처리 및 패턴인식 기법의 연구가 진행되고 있다. 또한 대부분의 생체신호 패턴인식에 LVQ(Learning Vector Quantization)가 많이 사용되고 있으나 학습하는 동안 참조벡터의 안정성과 출력뉴런의 부류지정에 어려움이 있다<sup>6-8)</sup>.

본 논문에서는 SOM(Self Organizing Maps), LVQ 알고리즘을 혼합으로 사용한 LVQ 네트워크를 설계하여 측정된 fMRI에 대한 패턴분류를 시도하였다. 제안된 알고리즘에서 SOM을 이용하여 LVQ의 초기 참조벡터를 학습 시켜서 학습의 안정도를 가지게 하였다. LVQ의 출력뉴런이 속해야 할 클래스의 지정을 위하여 out-star 학습규칙을 사용하였다. fMRI를 이용하여 외부 자극 맛(taste)에 대한 뇌의 신호를 획득하기 위하여 Philips Intera 1.5 T fMRI 장비를 사용하였고, 맛 자극으로 얻은 데이터는 MATLAB & SPM 소프트웨어 상에서 측정된 뇌의 좌표를 이용하여 감각중추의 활성화 신호의 세기를 측정하여 특징벡터를 추출하였다.

혀(tongue)에서 느끼는 맛의 감각은 매운 맛을 제외하고는 대뇌 피질에서 맛의 영역이 중복되어 구분이 안 되고 같은 sensory 영역에 표지되는 것으로 알려져 있다.

본 연구에서는 4가지 맛의 감각영역이 분명 차이가 있다고 가설을 세우고 인공지능 알고리즘을 이용하여 감각기능의 분류에 대한 적용가능성을 진단하기 위하여 쓴맛, 단맛, 신맛 및 짠맛에 반응하는 대뇌 피질의 활성화 신호의 세기를 패턴벡터로 사용하여 새로 설계한 학습알고리즘과 기존의 클러스터링 학습알고리즘과의 패턴인식 분류성능을 비교 분석하고 같은 위치의 감각영역에 있는 네 가지 맛의 차이가 분류 가능한 지를 확인하는데 그 목적이 있다.

이러한 연구를 수행하기 위하여 fMRI의 특징과 신호 획득방법을 기술하고, fMRI를 이용한 맛의 분류 알고리즘을 제안하였으며, fMRI와 SPM을 사용한 데이터획득과 특징벡터추출 및 패턴분류실험을 하였고, 이를 기반으로 새로 제안된 방식(변형된 학습알고리즘)의 의학영상에 적용 가능한지를 확인하였다.

## II. 재료 및 실험방법

본 연구에서는 fMRI를 이용하여 감각 중추신경의 활성화 신호의 획득을 위하여 Philips사 Intera 1.5 T fMRI system의 sence head coil을 사용하였으며, 자극을 주기 위한 stimulator는 이 실험에 적합 하도록 직접 제작하여 사용하였다. GE-EPI 기법(TR/TE/Matrix/Flip angle /Slice thickness /FOV/NEX-2000 /30 /80×79 /90°/2 mm /220 /1)를 이용하여 영상을 얻었다(Fig. 1). 4가지 맛에 대한 자극을 주기 위한 도구는 자체 제작한 실험기구를 이용하여 뇌의 fMRI 영상을 획득할 수 있도록 자극하였다(Fig. 2). 패턴인식에 필요한 모듈은 분류 학습 네트워크를 이용하였다(Fig. 3). 맛 영역의 패턴 분류와 기존 알고리즘과의 성능을 비교 · 분석하기 위해 변형된 LVQ 알고리즘을 사용하였으며, 맛 감각영역 활성화 자극신호의 크기를 측정하는 data처리는 MATLAB & 소프트웨어인 SPM을 이용하였다(Fig. 4).




Fig. 1. Data measurement systems

환자에게 4가지의 맛을 제공하기 위한 실험장비는 아래의 Fig. 2와 같다.

그림 (a)은 4개의 맛을 각각 분류하여 50 cc 주사기에 채운그림이다.

그림 (b)은 4개의 맛 시료 원액으로 실험대상자의 필요에 따라 재 주입 하기위한 시료이다.

그림 (c)은 환자의 구강에 일정시간에 일정양의 실험 시료를 편리하게 주입하기위한 장치이다.



(a)



(b)



(c)

Fig. 2. Experimental equipments

### 1. 맛의 분류 알고리즘

본 논문에서는 네 가지 다른 맛의 자극에 대하여 각각 다르게 발생하는 대뇌피질의 활성화 신호의 세기를 측정하여 입력패턴벡터로 사용한다. 이 입력패턴벡터를 사용하여 네트워크를 학습시킨 후 임의의 맛의 자극에 대하여 발생하는 좌표와 신호의 세기를 패턴벡터로 네트워크에 가해졌을 때 어떠한 맛인지를 역으로 분류하는 학습네트워크를 설계하였다.

본 논문에서 제안된 학습네트워크는 SOM의 학습 알고리즘을 이용하여 LVQ 네트워크의 초기 참조벡터를 학습하여 안정도를 향상시키고, out-star 학습규칙을 사용하여 LVQ 출력뉴런이 속해야 할 클래스를 학습하는 네트워크를 설계하여 맛 분류 알고리즘으로 사용된다.

### 2. 학습네트워크

본 연구에서 사용된 맛의 분류 학습네트워크의 구조는 Fig. 3과 같다.

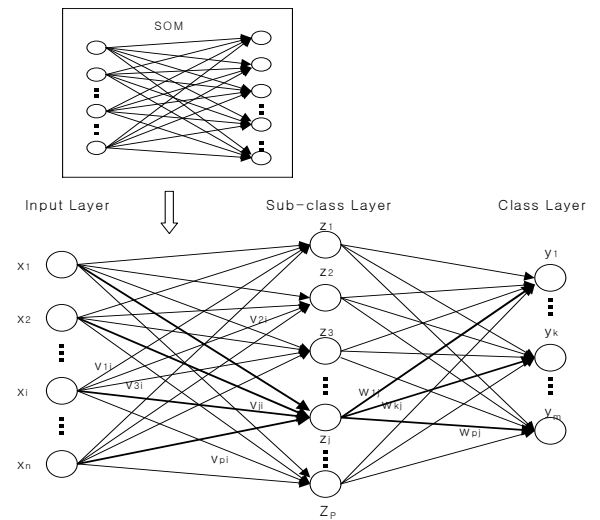


Fig. 3. Classification learning networks

Fig. 3에서  $x_1, x_2, \dots, x_n$ 은  $n \times 1$  입력패턴벡터,  $z_1, z_2, \dots, z_p$ 는 각각  $p$ 개의 출력뉴런  $v_{ji}$ , ( $i = 1, 2, \dots, n, j = 1, 2, \dots, p$ )로 in-star 학습규칙에 의해 학습될 SOM 또는 LVQ의 연결강도이고, 또한 in-star 학습규칙에 의해 학습될  $p$ 개의 클러스터 층의 뉴런이다.

제안된 학습 네트워크에서는 학습의 안정성을 위하여 SOM을 사용하여 입력 층과 종속 클래스 층 사이의 초기 참조벡터를 학습하였다. 입력 층과 종속 클래스 층 사이의 네트워크는 LVQ의 구조와 같고, 학습된 초기 참조벡터를 사용하는 LVQ의 참조벡터는 학습하는 도중에 국소적 접근 안정 평형점에 가까이 존재하고, 학습이 진행되면서 참조벡터가 평형점으로부터 멀리 이동되지 않게 되어 LVQ의 참조벡터는 수렴하고 LVQ 네트워크는 우수한 분류성능을 갖는다<sup>9,10</sup>. 이렇게 안정된 초기 참조벡터를 가지고 시작되는 LVQ의 학습은 입력 패턴벡터와 가장 일치하는 유사도를 갖는 종속 클래스 층의 뉴런과 입력 층

뉴런과 연결된 연결강도를 학습한다. 이것은 입력패턴벡터가 종속 클래스 층의 종속 클래스에 속하게 되는 것을 의미하고, 이 종속 클래스는 out-star 학습규칙에 의해 종속 클래스 층과 클래스 층 사이의 연결강도를 조정하여 가장 적합한 클래스로 지정된다. 따라서 입력패턴벡터는 in-star 경쟁학습에 의해 종속 클래스가 지정되고, 그 패턴벡터가 속하는 종속 클래스는 다시 out-star 경쟁학습에 의해 클래스가 지정된다.

3. 맛의 분류 알고리즘

맛의 분류 학습네트워크는 알고리즘의 측면에서 성능 향상을 갖는 LVQ 네트워크이다. 먼저, LVQ의 참조벡터가 안정적으로 수렴하는 학습능력을 갖기 위해서 식 (1)의 SOM 학습규칙으로 온라인 또는 오프라인으로 학습을 진행한다.

$$v_{ji}^{k+1} = v_{ji}^k + \alpha_S [x_i - v_{ji}^k] \dots\dots\dots (1)$$

여기서  $v_{ji}$ 는 입력패턴벡터의  $i$ 번째 요소  $x_i$ 에서  $j$ 번째 출력 뉴런  $z_j$  사이의 연결강도이며,  $\alpha_S$ 는 SOM의 학습률이다. SOM의 학습이 완료되면, 학습된 연결강도를 LVQ 네트워크의 초기 참조벡터로 그림 Fig. 3과 같이 설정한다. 이것은 학습 네트워크의 입력 층과 종속 클래스 층 사이의 연결강도를 학습된 SOM의 연결강도로 대치하면 된다. 즉, Fig. 3에서 학습 네트워크의 입력 층과 종속 클래스 층 사이의 네트워크는 LVQ 네트워크로 사용된다. 두 번째의 학습으로 안정된 초기 참조벡터를 가지고 식 (2)를 이용하여 LVQ의 학습을 수행한다.

$$v_{ji}^{k+1} = v_{ji}^k \pm \alpha_L [x_i - v_{ji}^k] \dots\dots\dots (2)$$

여기서  $\alpha_L$ 은 LVQ의 학습률이며, 승리뉴런의 클러스터와 입력벡터의 클러스터가 같은 경우가 +로, 다른 경우는 -로 학습된다. 세 번째로, 적은 학습률  $\alpha_{CP}$ 로 고정된 값을 가지고 식 (3)으로 정밀 학습을 진행한다.

$$v_{ji}^{k+1} = v_{ji}^k + \alpha_{CP} [x_i - v_{ji}^k] \dots\dots\dots (3)$$

식 (1)의 SOM과 식 (3)의 입력 층 및 클러스터 층 사이의 네트워크의 학습은 승리뉴런과 이웃한 뉴런들을 동시에 학습하거나 승리뉴런 만의 학습이 가능하다. 네 번째로, 종속 클래스 층의 승리뉴런을 결정하고, 그 승리뉴런이 속할 클래스

는 식 (4)로 학습된다. 즉, 클러스터 층의 승리뉴런과 출력 층 사이의 연결강도  $w_{kj}(j = 1, 2, \dots, m, k = 1, 2, \dots, p)$ 의 학습은 out-star 학습규칙에 의해 학습된다. 클러스터 층의  $j$ 번째 뉴런이 승리뉴런이 되었을 때 연결강도의 학습 규칙은 식 (4)로 된다.

$$w_{ji}^{k+1} = w_{ji}^k + \beta [x_i - w_{ji}^k] \dots\dots\dots (4)$$

식 (4)에서  $\beta$ 는 학습률이며, 학습이 진행되면서 서서히 감소된다.

4. 데이터 획득

데이터 획득 방법은 쓴맛, 단맛, 신맛 및 짠맛 순서로 환자 혀에 자극이 가도록 주입하였다. 실험재료는 익모초 200 g을 물 200 cc에 희석하여 쓴 맛을 만들었다. 단 맛은 설탕 200 g을 물 500 cc에 희석하여 만들었으며, 신 맛은 사과 식초 100 cc에 물 500 cc를 희석하여 만들었다. 마지막으로 짠 맛은 소금 50 g에 물 500 cc를 희석하여 만들었다. 특히 4가지 맛은 검사자가 누운 상태로 자극을 하기 때문 가능한 과도한 자극은 피하고 피 실험자 5명의 test를 거쳐 자극적이지만 누워서 감당할 수 있는 범위 내에서 자극의 강도를 조정하여 시험액을 만들었다. 시험액 주입방법은 50 cc 주사기를 extention conecter로 연결하여 자기장 보어(magnetic bore) 안에서 검사자가 불편하지 않고 움직임이 없도록 원격 주입하였다. 첫 번째 쓴맛에서 짠맛 순서로 시험액 주입은 scan time 동안 지속적으로 주입을 하였으며, dummy scan: 4개, rest 20 sec, stimulation 20 sec, 7회 반복하여 매회 5 cc 시료를 구강에 주입하여 fMRI를 각각 140 image를 획득하여 맛 감각영역 활성화 자극신호의 크기를 측정하였다.


사람에 따라 맛을 감지하는 정도가 다른 점을 감안하여 건강하고 몸에 이상이 없는 남녀 구분 없이 20대의 건강한 대학생 10명을 대상으로 데이터를 획득하였다. 이 중 뇌 활성화 신호가 가장 높은 1명을 대상으로 패턴분류를 하였다.

이렇게 획득한 data처리는 MATLAB & 소프트웨어인 SPM을 이용하여 표현한 맛 영역 활성화 data를 획득한 좌표와 신호의 세기를 표현하였다(Fig. 4).


대뇌의 맛 감각영역 부위 각각의 데이터를 뇌 영역의 가장 활성화 된 그림 영역의 신호세기를 특징벡터로 추출하였다.

데이터의 측정은 각각의 맛에서 30개의 데이터를 측정


하여 120개의 2차원 데이터를 획득하였다. 그러므로 1번의 측정은 2×1의 맛 활성화된 패턴벡터를 얻고, 각각의 맛의 상태마다 30개의 데이터를 측정하여 모두 120개의 데이터를 획득하였다.




(a) Bitter (SI: 1790) 3D map



(b) Sweet (SI: 1845) 3D map



(c) Sour (SI: 1825) 3D map



(d) Salty (SI: 1716) 3D map

Fig. 4. Activation axial, 3D map

### III. 시뮬레이션 결과

제안된 알고리즘의 유용성을 확인하기 위하여 획득된 데이터로 학습 및 테스트용 데이터를 사용하여 시뮬레이션 하였다.

먼저, 제안된 네트워크의 초기 참조벡터를 얻기 위하여 5×5 형상지도를 갖는 SOM 네트워크를 구성하였다.

SOM네트워크의 초기 학습률은 0.9, 초기 이웃반경은 학습이 진행되면서 단계적으로 감소되게 하였다. 초기 연결강도는 [0, 20]의 값으로 무작위로 발생시켰고, 학습 횟수는 10,000번 수행하였다.

제안된 학습알고리즘을 맛의 패턴인식에 시뮬레이션하고, 기존의 LVQ 학습알고리즘과의 패턴분류성능을 비교하였다. 기존의 LVQ의 초기참조벡터의 설정은 [0, 20] 사이의 값을 무작위로 발생시킨 경우와 학습용 패턴벡터를 초기 참조벡터로 사용한 경우로 나누어 시뮬레이션하고, 각각의 패턴분류 특성을 비교하였다.

실험조건에서 단맛일 때를 상태 A, 신맛일 때를 상태 B, 쓴맛일 때를 상태 C로 고려하고, 짠맛일 때를 상태 D로 한다. 기존의 LVQ 네트워크는 입력 뉴런 4개, 출력 뉴런 25개를 사용하였고, 25개의 출력 뉴런 중 7개, 6개, 6개, 6개를 각각 상태 A, B, C, D로 예 속 되도록 종속 클래스를 지정하였다. 또한 제안된 학습네트워크의 입력 뉴런 4개, 종속 클래스 층의 뉴런 25개, 클래스 층의 뉴런은 2개를 사용하였다. 클래스 A, B, C, D에 대한 각각의 클래스 층의 뉴런의 설정값은 [-1, -1], [-1, 1], [1, -1], [1, 1]로 하여 종속 클래스 층의 승리뉴런과 클래스 층의 출력 뉴런 사이의 연결강도를 학습하도록 하였다.

SOM, LVQ의 연결강도 및 제안된 방식의 입력 층과 종속 클래스 층 사이의 연결강도를 학습하기 위하여 사용된 학습률은 학습이 진행됨에 따라 서서히 감소하며 식 (5)와 같이 학습이 진행됨에 따라 감소된다.

$$a = a(0) \cdot \frac{ITER_{num} - k}{ITER_{num}} \dots\dots\dots (5)$$

식 (5)에서  $ITER_{num}$ 는 학습횟수,  $a(0)$ 는 학습률을 나타낸다. 학습률  $a$ 는 설정된 초기값  $a(0)$ 로부터 학습이 진행되면서 서서히 감소된다. 또한 제안된 학습네트워크에서 종속 클래스 층과 출력 층 사이의 연결강도 역시 식 (5)를 사용하여 학습이 진행되면서 감소된다. 식 (5)에 의해 감소되는 학습률의 초기값을 각각 0.9, 0.7, 0.5로 설정하고 제안된 학습방식을 갖는 LVQ와 기존의 LVQ와의 fMRI 데이터 패턴분류를 시뮬레이션 한 각각의 결과를 볼 수 있다(Table 1~3).

Table 4는 Table 1~3을 평균한 분류오차 수 및 오차율이다.

**Table 1.** Classification errors of training data errors ratio :  $(a(0) = 0.9)$

the number of iterations	1000	2000	5000	10000
LVQ(Random)	91	91	91	91
LVQ(Learning vector)	36	36	36	36
the proposed method	31	31	31	31

**Table 2.** Classification errors of training data errors ratio :  $(a(0) = 0.7)$

the number of iterations	1000	2000	5000	10000
LVQ(Random)	75	75	75	75
LVQ(Learning vector)	37	38	38	35
the proposed method	33	33	33	33


**Table 3.** Classification errors of training data errors ratio :  $(a(0) = 0.5)$

the number of iterations	1000	2000	5000	10000
LVQ(Random)	91	91	91	91
LVQ(Learning vector)	35	37	36	36
the proposed method	33	33	33	33


**Table 4.** Number and ratio of classification errors

the number of iterations		1000	2000	5000	10000	평균
LVQ (Random)	Number	56	56	56	56	56
	ratio [%]	47	47	47	47	47
LVQ (Learning vector)	Number	36	37	36	35	36
	ratio [%]	30	31	30	29	30
the proposed method	Number	32	32	32	32	32
	ratio [%]	27	27	27	27	27

Table 4에 대한 평균 분류 오차 및 오차율을 그래프로 나타내었다(Fig. 5).



(a) The number of the classification errors



(b) Ratio of the classification errors

**Fig. 5.** Comparison of the classification errors

Fig. 5에서 LVQ(random)는 초기 참조벡터를 무작위로 발생시킨 LVQ이고, LVQ(L-vector)는 학습에 사용되는 패턴벡터를 초기 참조벡터로 설정된 LVQ 학습방식이다.

추출된 패턴벡터의 분류를 위해 제안된 학습알고리즘은 학습하는 동안 안정적으로 수렴될 수 있도록 SOM으로 초기 참조벡터를 학습하였다. 그리고 학습된 초기 참조벡터를 사용하여 LVQ의 학습을 진행한 다음, 다시 한번 더 적은 값으로 고정된 학습률로 정밀 학습을 하였다.

종속 클래스 층의 승리뉴런을 결정하고, 그 승리뉴런이 속할 클래스를 학습하기 위하여 out-star 학습규칙을 사용하였다. 측정 및 특징벡터로 추출된 fMRI에서 얻은 데이터를 학습벡터 및 시험 벡터로 사용하여 제안된 학습 방식과 기존의 LVQ 학습 방식에 적용하여 시뮬레이션 하였다.

시뮬레이션 결과 LVQ(random)는 47%, LVQ(L vector)는 30%의 평균분류오차를 얻었지만, 제안된 알고리즘을 사용한 방식에서는 27%의 평균 분류 오차를 얻을 수 있었다.

따라서 제안된 방식은 LVQ(random) 보다 평균 20%, LVQ(L-vector) 학습방식보다 평균 3%의 평균 분류 오차율이 개선되었음을 확인하였다.

## IV. 고찰

본 논문에서는 맛의 자극에 대한 신호의 획득을 위하여 1.5 T fMRI를 사용하여 4가지 맛에 대한 자극신호를 측정하였다. 5가지 맛에 포함된 매운 맛은 맛이라기보다는 신경의 자극으로 통증을 유발하므로 본 연구에서는 매운 맛을 제외하였다. 4가지 다른 맛의 자극에 대하여 각각 다르게 발생하는 대뇌피질의 활성화 신호의 세기를 측정하였다. 측정된 데이터를 소프트웨어인 SPM을 이용하여 좌표와 신호의 세기로 표현되는 데이터를 얻어 입력패턴벡터로 사용하였다(Fig. 4).

본 연구를 통해서 fMRI에서 얻은 data를 제안된 학습 algorithm을 이용하여 입력 패턴벡터로 이용한 맛의 자극 신호 강도를 MateLab & SPM으로 분석하여 대뇌피질 감각영역(sensory region)의 맛 활성화 영역의 패턴분류 결과, 사람의 두뇌활동에 있어 맛의 활동은 ① 단맛 → ② 신맛 → ③ 쓴맛 → ④ 짠맛 순서로 표현되었다. 맛의 대뇌피질 활성화 세기를 분석한 결과, 단맛: 1845 → 신맛: 1826 → 쓴맛: 1790 → 짠맛: 1716의 순으로 뇌가 활성화됨을 알 수 있었다. 4가지 맛을 패턴분류 한 결과 사람의 두뇌 활동에서 가장 활성화되는 맛은 단맛, 신맛, 쓴맛, 짠맛 순서로 제안된 수식 (1), (2), (3), (4)의 알고리즘을 통해서 확인하였다. 이 결과 대뇌의 감각영역의 뇌 활성화를 공학적 알고리즘을 적용하여 표준화되고 수치화된 의학적 분석이 가능하였다

맛의 곁침은 자극을 계속해서 각각의 맛을 주고 앞에 주었던 맛을 없애기 위해 rest 시간에 물을 입안에 주어 맛의 곁침을 최대한 줄이고자 하였다.

그러나 이번 연구결과 자극과 휴식의 간격이 짧기 때문에 혀에 먼저 자극 주었던 맛이 남아있을 가능성을 배제하기 위해 rest time을 충분히 주는 것이 특징벡터의 추출이 용이할 것으로 생각된다.

## V. 결론 및 추후과제

그 동안 뇌 활성화 범위를 fMRI 입체 사진을 통해 컬러로 활성화 된 부위를 보고 판단하였으나 본 연구를 통해 정확한 수치의 데이터를 얻으므로 해서 두뇌 활성화의 정도를 표준 수치화 하는 결과로 의학에서 정확한 진단을 하는데 도움이 될 것으로 기대되며, 인간의 노화 및 치매 연구에 있어 sensory 손상 유무를 taste fMRI 검사와 공학적 알고리즘을 활용하여 감각영역의 중추신경계 손상과

치매 연구에 도움이 될 것으로 생각된다. 4종류의 맛 패턴 분류가 일정한 비율의 결과를 얻음으로서 패턴인식 학습네트워크를 활용한다면 의학에 적용하여 치매의 기전을 정확히 분류할 수 있을 것으로 기대된다. 치매는 중추신경계에서 가장 먼저 시작되어 가장 늦게 motor, taste sensory 도달하는데 대표적인 알츠하이머병, 파킨슨병인 사지와 몸이 떨리고 경직되는 중추 신경계의 퇴행성 질환인 노인성치매와 혈관 이상(중풍, 당뇨, 심장질환, 고지혈증, 고혈압, 혈관염증, 성인병 등)으로 치매가 오는 혈관 질환성 치매의 구별이 어려운데, 본 연구의 맛 패턴분류 연구를 통해 중추신경계의 sensory 기능 손상여부를 측정하여 노인 치매의 기전을 판별하는데 도움이 될 것으로 기대한다.

본 연구를 통해 의학적으로 맛 영역이 심한 곁침으로 분류가 불가능하다는 통설을 공학적인 알고리즘을 이용하여 분류하였는데 본 연구의 의의가 있다고 생각된다.

향후 연구는 상상으로 맛을 구별하는 sensory 영역과 실제 자극을 준 결과를 비교 분석하여 어떤 차이가 있는지에 대한 연구가 필요하다고 생각된다. 앞으로 이러한 연구를 통하여 인지기능, 음성인식, 영상인식 fMRI, 연상 메모리 등 공학 및 의학 등의 많은 분야에서 공동연구가 기대된다. 맛의 의학적인 인지기능 패턴분류 연구를 통하여 의학과 공학의 활발한 공동연구로 방사선과학의 발전을 기대해 본다.

## 참고 문헌

1. 감일영: 전신자기공명영상, 고려의학, 2-34, 1995
2. KK Kwong, JW Belliveau, DA Chesler et al.: Dynamic magnetic resonance imaging of human brain activity during primary sensory stimulation. Proc Acad Ssi USA 1992, 5675-5679, 1989
3. Ogawa S, Tank DW, Menon R et al.: Intrinsic signal changes accompanying sensory stimulation, functional brain mapping using MRI. Proc Natl Acad USA, 5951-5955, 1992
4. 남궁호, 임호수, 송인찬: 대뇌 운동 피질의 기능적 자기공명영상, 대한방사선사협회지, 제 23 권 제 1 호, 62-63, 1997
5. 성재구 외: 운동 동작 없이 생각만을 이용한 대뇌 운동 영역의 기능적 자기공명영상에 대한 고찰, 대한자기공명기술학회지, 제 17 권 1 호, 113-117, 2007

6. 이용구, 최우승: Forward C.P. Net.을 이용한 3단 LVQ 학습알고리즘, 한국컴퓨터정보학회논문집, 제 9 권 제 4 호, 33-39, 2004
7. 이용구, 최우승: 분류오차유발 패턴벡터 학습을 위한 학습네트워크, 한국컴퓨터정보학회논문집, 제 10 권 제 5 호, 77-86, 2005
8. 이용구, 이선엽, 최우승: 뇌파의 입력패턴벡터 추출 및 패턴인식, 한국정보학회논문집, 제 11 권 제 5 호, 95-103, 2006
9. Baras, J.S. and LaVigna, A: Conergence of Kohonen's Learning Vector Quantization, IJCNN, Vol. 3, 17-20, June, 1990
10. Tanaka, T. Saito, M: Quantitative Properties of Kohonen's Self-Organizing Maps as Adaptive Vector Quantizers, IEICE transactions on information and systems, D-II, Vol. J75-D-II, No. 6, 1085-1092, 1992(in Japanese)

• Abstract

## Input Pattern Vector Extraction and Pattern Recognition of Taste using fMRI

Sun-Yeob Lee · Yong-Gu Lee · <sup>1)</sup>Dong-Ki Kim

*Department of Radiological Technology, Hallym College*

<sup>1)</sup>*Department of Industrial Engineering, Kangwon National University*

In this paper, the input pattern vectors are extracted and the learning algorithms is designed to recognize taste(bitter, sweet, sour and salty) pattern vectors. The signal intensity of taste are used to compose the input pattern vectors.

The SOM(Self Organizing Maps) algorithm for taste pattern recognition is used to learn initial reference vectors and the ot-star learning algorithm is used to determine the class of the output neurons of the subclass layer.

The weights of the proposed algorithm which is between the input layer and the subclass layer can be learned to determine initial reference vectors by using SOM algorithm and to learn reference vectors by using LVQ(Learning Vector Quantization) algorithm. The pattern vectors are classified into subclasses by neurons in the subclass layer, and the weights between subclass layer and output layer are learned to classify the classified subclass, which is enclosed a class. To classify the pattern vectors, the proposed algorithm is simulated with ones of the conventional LVQ, and it is confirmed that the proposed learning method is more successful classification than the conventional LVQ.

Key Words : Taste activate, Pattern vector extraction, LVQ, Pattern classification