

論文95-33B-1-20

## 신경망에 대한 적응 집단 코딩 모델

### (Adaptive population coding model for neural networks)

張珠錫 \*

(Ju-Seog Jang)

#### 요 약

오류를 최소화하는 방법에 기초한, 신경망에 대한 간단한 적응 집단 (population) 코딩 모델을 개발하였다. 이 모델은 원숭이의 자발적 팔운동에 있어서, 운동피질에서 발견되는 신경세포들의 집단 코딩의 성질과 잘 부합한다. 학습이 이루어진 후에, 특정의 방향성 모델 신경들을 제거함으로써, 이들 신경들의 코딩에 대한 기여를 조사하였다. 또, 나머지 신경들만을 가지고 학습을 시킴으로써, 그들 세포들의 선호 방향이, 코딩 오차를 줄이기 위해, 어떻게 변하는가를 관측하였다. 이와 같은 집단 코딩의 적응성은 아직 예측되거나 실험적으로 관측된 바가 없으므로, 집단코딩에 기초한 정보처리를 수행한다고 여겨지는 실제의 뇌피질에서도 유사한 적응성질이 존재하는지 조사해 보는 것도 흥미로울 것이다.

#### Abstract

We develop a simple adaptive population coding model for neural networks based upon an error minimization method. Our model exhibits properties that have been experimentally observed in the population coding of the motor-cortical cells during the voluntary arm movements of primates. By removing a group of directionally tuned cells after learning, we study its contribution to the population coding. Through the learning process of the remained cells, we observe how the cells modify their preferred directions to reduce the coding errors. Since this adaptive property has been neither predicted nor experimentally observed before, it would be interesting to find whether a similar adaptive property exists in real cortices that are believed to encode the information in their cell populations.

#### I. 서 론

집단 코딩 (population coding)에서는, 많은 신경 세포들이 주어진 정보를 함께 분산하여 표현하고 처리한다. 따라서 신경 개개의 잡음에 강하고, 몇개의 신

경세포가 죽거나 파괴되어도 전체 정보의 표현에 큰 영향을 받지 않는다. 뇌의 정보처리는 기본적으로 이러한 집단 코딩의 성질을 갖추고 있다. 가장 잘 알려진 집단코딩의 예는 원숭이의 운동피질일 것이다. 원숭이가 자발적 팔 운동을 할 때, 그의 운동피질에 있는 많은 세포들이 함께 활동을 하고, 이들 활동을 종합하여 팔의 이동방향을 잘 예측할 수 있음이 실험적으로 밝혀져 있다<sup>[1]</sup>. Georgopoulos와 그의 동료들은 자신들의 실험결과를 바탕으로 운동피질 세포들에 대한 집단 코딩 모델을 제안한 바 있다<sup>[2-5]</sup>. 이러한 집단코

\* 正會員, 釜山水産大學校 情報通信工學科  
(Dept. of Telematics Eng. Nat. Fisheries Univ. of Pusan)

接受日字: 1995年10月23日, 수정완료일: 1995年12月20日

딩 모델의 성질은, 선형적 입출력 특성을 갖는 모델 신경을 사용하여, 이론적으로 많이 연구되었다. Gaal은 집단 코딩 모델을 텐서모델과 비교한 바 있고<sup>[6]</sup>, Seung과 Sompolinsky는 이와 유사한 시각피질에서의 집단 코딩 모델을 제안하고 집단코딩된 정보를 Perceptron 과 같은 회로로 읽어내는 연구를 수행한 바 있다<sup>[7]</sup>. 그리고, Tanaka는 집단코딩모델의 여러 가지 성질을 수치해석적으로 연구하였으며<sup>[8]</sup>, Sanger는 집단코딩에 있어서 여러 성질의 상호 관련성을 지적하였다<sup>[9]</sup>.

집단 코딩으로 표현하고자 하는 정보를  $L$  개의 특징들로 나타낸다고 하자. 집단코딩이란, 이  $L$  차원 특징 벡터를  $N(>L)$ 개의 신경세포의 활동상태로 표현한다고 볼 수 있다. 본 논문에서는, 비선형 입출력 특성을 갖는  $N$ 개 신경들의 활동을  $L$ 개 출력 특징들로 변환시키는 적절한 가중치 (weights)를 학습을 통하여 찾음으로써,  $L$  차원 특징 벡터를  $N$  차원의 신경활동 상태로 표현하는 적응적 집단 코딩 모델을 제안한다. 여기서 학습이란 신경활동 상태로 표현된 특징 벡터와 본래의 특징 벡터 사이의 오차 함수를 최소화하는 과정을 의미한다. 이러한 오류 최소화 방법에 기초한 학습 방법이 신경망에 적용된 예가 허다하지만<sup>[10, 11]</sup> 집단코딩에 있어서의 논의는 아직 없었던 것 같다. 결국 이 가중치는 항상 적응적으로 변할 수 있어서 몇개의 세포가 파괴되면 새로운 가중치로 변환되어 (즉, 학습이 이루어져) 항상 코딩하고자하는 특징 벡터들을 올바르게 표현하는 것이다.

한 예로, 원숭이의 팔운동을 제어하는 운동피질 세포들을 생각해 보자. 세포의 활동이 손의 이동방향에 대한 정보를 잘 표현하므로, 코딩하고자 하는 특징들을 손의 이동 속도 즉, 이동 방향과 그 빠른 정도(=속력)라고 가정하자. 간단히  $L=2$ 인 2차원에서의 손의 움직임을 생각한다면,  $N$ 개 세포들의 활동 벡터가 이 2차원 속도 벡터를 표현하고, 각각의 세포활동은 특정한 가중치를 갖고 손의 속도 벡터 표현에 기여하는 것이다. 우리의 적응 모델은 지금까지 운동피질에 대해 실험적으로 관측된 집단코딩 성질에 기초하여 제안되었으며, 실제로 이와 잘 부합하는 성질을 나타낸다. (실험적으로 잘 알려진 운동피질 세포의 집단코딩 성질은 참고문헌 [9]에 간략히 잘 요약되어 있다.) 게다가 지금까지 관측되지 않았던 적응적 성질도 갖는다. 만약 일부 세포들을 제거하면, 처음에는 전체 신경세포의 활동이 손

의 속도 벡터를 올바르게 표현하지 못하지만, 가중치를 적절히 바꾸어 줌으로써 (학습을 통해) 나머지 세포들만으로 다시 손의 속도 벡터를 올바르게 표현하게 되는 것이다. 이 적응집단코딩 모델은 팔움직임 외의 다른 정보들의 집단 코딩에도 그대로 적용될 수 있다.

## II. 적응 집단 코딩 모델

$N$ 개의 비선형 입출력 관계를 갖는 모델 신경들이 어떤 정보에 대한  $L$ 개의 특징들을 코딩하는 관계를 그림 1(a)의 점선내에 나타내었다. 모델 신경들은 속이 빈 원으로 표시하였고 코딩하고자 하는 특징들은 속이 찬 작은 원으로 표시하였다. 그리고 모델신경의 활동이 특징 벡터의 표현에 기여하는 정도를 나타내기 위한 가상의 가중치를 그들 사이의 선으로 나타내었다. 예를 들어 원숭이의 자발적 팔운동의 경우, 가상의 가중치란 운동피질 세포들의 활동이 연수와 척수등에 있는 릴레이 신경들을 통하여 근육의 수축 혹은 이완을 유발하여 손의 움직임으로 변환될 때의 기여도를 종합적으로 표현한 것으로 볼 수 있을 것이다.


이 가상적 가중치를, 표현하고자 하는 정보의 특징 (feature) 벡터  $\mathbf{F}$  와 세포활동 (discharge rate) 벡터  $\mathbf{D}$  사이를 연결하는,  $L \times N$  크기의 행렬  $\mathbf{W}$ 로 표시하기로 한다. 그러면, 특징 벡터  $\mathbf{F}$ 는 다음과 같이 표현된다.

$$\mathbf{F} = \sum_{n=1}^N D_n \mathbf{U}^n \quad (1)$$


여기서  $\mathbf{U}^n$  은 행렬  $\mathbf{W}$  의  $n$ 번째 칼럼 벡터를 나타내고  $D_n$ 은  $n$ 번째 세포의 활동세기를 나타낸다. 만약 손움직임의 이동방향을 코딩하는 운동피질 세포를 생각한다면,  $\mathbf{U}$ 은  $n$ 번째 세포가 기여하는 선호방향 (preferred direction)을 결정한다. 그리고 운동피질 세포의 활동세기는, 그 세포의 선호방향과 손의 이동방향간의 각도를  $\theta$ 라 할 때,  $\theta$ 의 cosine 함수로 잘 표현된다는 것이 실험적으로 밝혀져 있다<sup>[2-5, 12]</sup>. 따라서, 특징 벡터  $\mathbf{F}$ 를 표현하기 위한  $n$ 번째 세포의 활동 크기는 다음과 같이 표현된다고 가정한다.

$$D_n = f(\|\mathbf{U}^n\| \cdot \|\mathbf{F}\| \cos \theta) = f(\mathbf{U}^n \cdot \mathbf{F}) \quad (2)$$

여기서 세포활동의 세기는 상한과 하한으로 제한되므로 이를 나타내기 위해 비선형 함수  $f(\cdot)$ 를 포함시켰다.



(a)



(b)

그림 1. (a) 우리 모델의 회로 구조. 출력은 정보를 표현하는데 필요한 특징 요소들이다. (b) 시뮬레이션에서 사용된 비선형 세포활동 함수들.

Fig. 1. (a) The network architecture of our model. The output is the feature elements required to represent the information. (b) The nonlinear cell-activation functions used in simulations.

식 (1)과 (2)에서, 본래 표현하고자 하는 어떤 예시적 특징 벡터  $F^m$ 과 세포 활동에 의해 표현되는  $F^{m*}$  사이의 오차 함수를 다음과 같이 정의한다.

$$E = \sum_{m=1}^M \| F^m - F^{m*} \|^2 = \sum_{m=1}^M \| F^m - \sum_{n=1}^N f(U^n \cdot F^m) U^n \|^2 \quad (3)$$

여기서 임의의  $M$ 개의 예시적 특징 벡터들  $F^m$ ,  $m = 1, 2, \dots, M$ 을 표현한다고 간주하였다. 학습이라 함은 식 (3)을 최소화하는  $N$ 개의 적절한  $U$ 들을 얻는 과정이다. 최대 경사 하강법 (the steepest descent method)을 사용하여  $E$ 를 최소화 하는 과정은 일종의 Hebb학습 규칙과 같은 결과를 준다.  $W(0)$ 를 학습전의 초기 무작위로 택한 가중치 값이라고 하면, 반복적

으로 가중치를 바꾸어 줌으로써,  $k$ 번째 시각에 얻어지는 가중치  $W(k)$ 는 다음과 같이 표현된다.

$$W_{ij}(k) = W_{ij}(k-1) + \eta \sum_{m=1}^M [ F_i^m f(\Omega_j^m) + F_i^{m*} \Omega_j^m f'(\Omega_j^m) - F_i^{m*} f(\Omega_j^m) - F_i^{m*} \Omega_j^{m*} f'(\Omega_j^m) ] ,$$

$$\Omega_j^m = \sum_{i=1}^L W_{ij}(k-1) F_i^m$$

$$F_i^{m*} = \sum_{j=1}^N W_{ij}(k-1) f(\Omega_j^m)$$

$$\Omega_j^{m*} = \sum_{i=1}^L W_{ij}(k-1) F_i^{m*} . \quad (4)$$

여기서  $f'$ 은  $f$ 의 미분함수이고,  $\eta$ 는 학습율이다. 첨자  $i$ 와  $j$ 는 행렬의  $i$ 번째 및  $j$ 번째 요소를 각각 나타낸다. 식 (4)의 두번째 식에서  $\Omega_j^m$ 은 집단코딩을 수행하는 신경세포들에 입력되는 양으로서, 특징 벡터  $F^m$ 을 발생시키려는 요구에 의해 바로 이전 신경층에서 공급하는 것으로 생각할 수 있다. 또, 식 (4)의 네번째 식에서  $\Omega_j^{m*}$ 은, 그림 1(a)에는 표시되지 않았지만, 어떤 다른 경로를 통해 feedback 되어  $z$ 학습에 이용된다고 볼 수 있다. 식 (4)에는  $f'$ 과  $f$ 가 있어서 다소 복잡해 보이지만  $f$ 가 선형함수라고 생각하면 Hebb의 학습 규칙과 같은 매우 단순한 의미를 지니고 있음을 알 수 있다.

만약  $f$ 가 선형함수이면,  $N$ 이  $L$ 보다 크므로 학습 후  $D$ 로  $F$ 를 정확히 표현하는 가중치  $U$ 가 얻어진다. 즉, 식 (3)에서  $E$ 가 0이 된다. 이 경우 가중치 행렬  $W$ 는 모든  $m$ 에 대해  $L$  차원의  $F^m$  벡터들을  $N$  차원의  $D^m$  벡터로 확장시키게 된다. 다시 말해, 모든  $m$ 과  $n$ 의 쌍에 대해,  $F^m$ 과  $F^n$  사이의 Euclid 거리는 대응되는  $D^m$ 과  $D^n$  사이의 Euclid 거리와 같다. 학습에 필요한 특징 벡터  $F$ 의 갯수  $M$ 은 최소한  $L+1$  이어야 한다.

식 (4)의 학습과정은 단일 신경층에 대해 적용된다. 그러나 다층 신경망에도 동일 절차를 매 층마다 반복함으로써, 모든 층이 자신이 표현할 정보를 집단 코딩하며 이 정보를를 아래층으로 전달 할 수 있다. 이 때 각 층간의 가중치는 세포간 유효 시냅스 연결 세기로 볼 수 있다.

### III. 적응 집단 코딩 모델의 성질

집단코딩의 적응적 성질을 관찰하기 위해, 앞절의

학습과정을 컴퓨터로 시뮬레이션하였다. 특히 원숭이의 자발적 팔운동에 있어서 운동피질 세포의 집단코딩 성질과 비교하기 위하여, 특징 벡터  $F$ 는 2차원 ( $L=2$ 의 경우)에서의 손의 이동 속도 (이동방향 및 그 속력)으로 설정하였다. 3차원 ( $L=3$ 인 경우)에도 시뮬레이션을 수행하였는데 그 결과는 2차원인 경우와 정성적으로 다르지 않았다. 초기 가중치  $w_{ij}(0)$ 는 평균이 0인 정규분포의 작은 크기의 무작위 값을 할당하였다. 이는 학습되기 전의 세포들의 초기 기여 선호방향 (preferred direction) 즉,  $U^n$ 들의 방향이 2차원 공간 (360도 방향)에 균일하게 분포하고 있음을 의미한다. 학습을 위한 특징 벡터  $F^m$  들은 고정된 벡터를 반복해서 사용하지않고, 2차원 원점을 중심으로 범위가 제한된 연속 실수공간 (real space)에서 매회마다 무작위로 선택하여 학습시켰다. 제한된 범위를 사용한 이유는 손의 이동속력이 무한히 클 수 없기 때문이다. 학습에 있어서 무작위  $F^m$ 들을 매회 선택한다는 것은 실제로 아무렇게 움직이는 것처럼 보이는 신생아들의 순시적 팔움직임과 닮아 있다. 최근 이러한 신생아들의 팔움직임에도 팔운동 제어와 관련된 학습목적의 가능성이 있다는 것이 보고된 바 있다 [13].

시뮬레이션에 사용된 두가지의 간단한  $f$  함수를 그림 1(b)에 나타내었다. 쌍극함수를 사용했을 때를 "경우 1" (Case 1)로 지칭하고 단극함수를 사용했을 때를 "경우 2" (Case 2)로 지칭하기로 한다. 두 경우 모두, 초기  $U$ 들의 방향분포가 균일할 경우, 학습후에





그림 2. 우리 모델의 집단 코딩 성질. 세포의 수는 200입. (a) 세포의 선호 방향과 그 가중치 값. (b) 단위 크기의 속력을 갖는 두 방향의 손 움직임에 대한 집단코딩: 경우 1은 -135도 방향이고 경우 2는 0도 방향임. (c) 실제로 발생된 이동방향과 속력에 대한 지도. 외곽의 둥글게 위축된 그리드는 손의 이동속력은 제한되는데 반해 손의 이동방향은 비교적 정확하다는 것을 의미한다.

Fig. 2. The population coding properties of our model. The number of cells is 200. (a) Cells' preferred directions and their wight values. (b) Population coding of two hand movements with unit velocity: -135 degree direction for Case 1 and 0 degree direction for Case 2. (c) The maps of actually generated movement directions and velocities. The round shrinkage of the outer part of grids implies that the direction of hand is relatively accurate even though its velocity magnitude is limited.

도 균일한 방향분포를 갖는다. 그러나 초기 선호 방향이 균일하지 않을 경우 일반적으로 학습후의 선호방향도 균일하게 분포되지 않았다.  $N = 200$ 일 때, 전형적으로 얻어지는 학습후의  $U$ 들을 그림 2(a)에 나타내었다. 주어진 초기값으로 부터 최종 학습결과를 얻는데 소요되는 시간은 Workstation (예를 들어 SUN SPARC 2) 에서 대략 (order of) 1분 정도였다. 경우 1과 2 각각에 대하여, 단위 속력을 갖고 방향 -135도 및 0도로 손움직임이 있을 때, 모든 세포들의 기여 정도를 그림 2(b)에 나타내었다. 이들은 참고문헌 [2-5, 12] 에서 나타낸 운동피질 세포에 대한 실험결과와 매우 닮아 있다. 신경들의 비선형 입출력 특성  $f$  때문에, 근육이나 릴레이 신경들이 이상적인 경우라고

할지라도, 실제로 얻어지는 손움직임의 속력  $\|F\|$ 는 제한된다. 이를 그림 2(c)에 외곽이 위축된 그리드(grid)로 나타내었다. 이 때, 만약  $N_e$ 가 선형이라면 균일간격의 그리드가 형성될 것이다. 이 그림에서 주목할 것은 이동속력이 제한되더라도 그 이동방향은 비교적 정확하다는 점이다.

집단 코딩은 중복적이고 따라서 손상에 강한 정보 표현 방법이다. 사실, 무작위로 선택한  $N_e$  ( $\ll N$ )개의 세포들만 가지고도 손의 이동방향을 비교적 정확하게 예측할 수 있다. 전체  $N$ 개의 세포집단에서 부분적인  $N_e$ 개의 세포집단만 가지고  $F^m$ 의 추정 값  $F'^m$ 을 계산하는 것은 다음과 같다.

$$F'^m = \sum_{k=1}^{N_e} D_k U^k. \quad (5)$$

여기서  $D_k = f(U^k \bullet F^m)$ 이다. 시뮬레이션에서는  $N = 1000$ 이었다. 무작위 선택으로 인해, 자칫 엉뚱하게 큰 오차가 발생하는 것을 막기 위하여 여덟개의  $F^m$  ( $m = 1, 2, \dots, 8$ )을 추정에 사용하였다. 이들의 크기는 모두 1이고, 방향은 0도에서 시작하여 45도 간격으로 균등하게 분포된 것들이다.  $N_e$ 는 최소 2에서 최대 1000을 가질 수 있는데, 하나의 특정값  $N_e$ 에 대해, 여덟개의  $F^m$ 들과 이에 대응되는 8개 추정치  $F'^m$ 들 사이의 각도 오차 및 Euclid 거리오차를 각각 계산하였다. 그리고 이들 각도 및 거리에 대한 8개씩의 오차들을 각각 평균하여  $\delta_{ang}$ 과  $\delta_{dis}$ 를 얻었다. 특정  $N_e$  값에 대해,  $N_e$ 개의 세포를 무작위로 선택하는 것을 100번 수행함으로써 위 계산을 100번 반복하였다.

이로 부터 얻은 100개씩의  $\delta_{ang}$ 과  $\delta_{dis}$ 들을 크기순으로 순서를 매겼다. 또한, 이들 100개씩에 대한 각각의 평균,  $\bar{\delta}_{ang}$  및  $\bar{\delta}_{dis}$ 를 계산하였다.  $N_e$ 가 증가함에 따라  $\bar{\delta}_{dis}$ 는 거의 선형으로 감소하였다. 반면에  $\bar{\delta}_{ang}$ 은  $N_e$ 가 대략 0.1N이 될 때까지는 급격히 감소해가다  $N_e$ 가 대략 0.1N보다 커지면 매우 천천히 감소하여 거의 일정한 각도 오차를 나타내었다. 그림 3은 5번째로 큰 각도오차  $\delta_{ang}$  및 단순 평균값  $\bar{\delta}_{ang}$ 를  $N_e$ 에 대해 그린 것이다. 5번째로 큰 각도오차란 주어진  $N_e$ 에 대한 100개의 각도 오차들 중에서, 95%에 포함되는 오차분포를 의미한다. 이 그래프는 실제로 원숭이 운동피질 세포의 실험에서, 어떻게 단지 수백개의 제한된 세

포수를 가지고도 그의 손의 움직임 방향을 비교적 잘 예측해 줄 수 있었던가를 설명해 줄 수 있다고 생각된다. 사실 그림 3은, 실제 실험 데이터로부터 얻은, 참고문헌 [3]의 그림 3과 매우 흡사함을 알 수 있다.

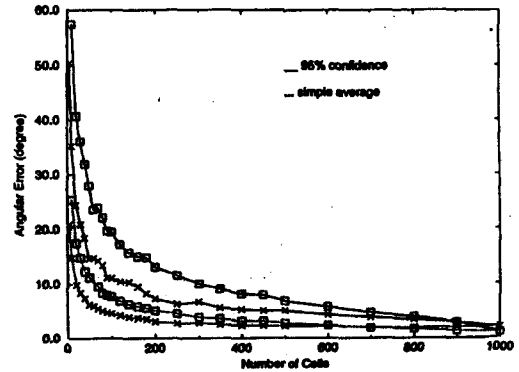


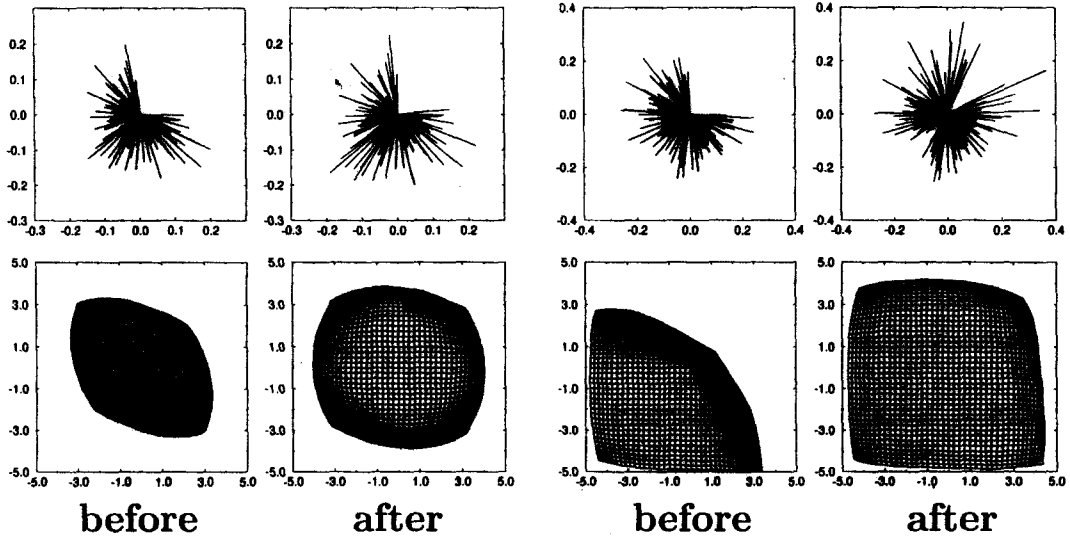
그림 3. 무작위로 선택된 부분적 세포그룹을 이용한 각도 오차의 추정. 전체 집단 크기는 1000임. 기호  $\times$ 와  $\square$ 는 각각 경우 1과 경우 2를 나타낸다.

Fig. 3. Angular error estimation using a subgroup of randomly selected populations. The whole population size is 1000. The symbols  $\times$  and  $\square$  are used for Case 1 and 2, respectively.


학습이 끝난 뒤에, 가령 세포가 죽거나 ( $N$ 의 감소), 근육의 갑작스런 손상 (가중치의 변화) 등으로 인해 식 (3)의 오차합수  $E$ 가 증가할 수 있다. 가중치의 변화는 앞절의 학습을 반복함으로써 최소 오차의 새로운 가중치를 얻어낼 수 있다. 죽는 세포들이 있을 경우, 이들이 무작위로 선택된다면 위에서 설명한 것처럼 그 오차합수는 갑자기 커지지 않을 것이고, 나머지 세포들의 선호방향의 방향분포는 여전히 균일할 것이다. 따라서 재학습 후에도 이들 선호방향은 역시 균일하게 분포되어 있을 것이며, 이는 처음부터  $N$ 보다 작은 수의 신경세포들을 가지고 시뮬레이션한 결과와 마찬가지로 일 것이다. 우리는 세포의 적응성질을 보다 선명하게 관측하기 위하여 특정 선호방향의 세포들을 인위적으로 제거한 뒤 재학습시키는 시뮬레이션을 수행하였다. 경우 1과 2 각각에 대해, 특정 방향의 방향성 세포들을 제거한 3가지 예에 대해 재학습 전과 재학습 후의 상황을 그림 4에 나타내었다. 이 결과, 제거된 세포들의 선호방향과 비슷한 선호방향을 갖는 세포들의 경우, 제거

된 세포들의 선호방향쪽으로 다소 회전하는 경향을 보인다. 하지만 나머지 세포들 전체의 선호방향은 균일하게 분포되지 않는다. 그 이유는 제거되지 않은 세포들이 자신들의 선호 방향을 크게 바꾸지 않고도 제거된 세포의 기능을 비교적 고르게 분산적으로 분배하여 대신할 수 있기 때문이다.

물론 특정 방향으로 제거된 세포의 수가 증가할수록 나머지 세포의 선호방향 변화가 뚜렷하다. 그림 4의 그리드 그림을 보면, 학습후 세포들의 선호방향이 균일하지 않더라도, 손의 최대 이동속력은 제한되어 있지만 그 이동방향은 360도 어느쪽으로도 비교적 정확하게 움직일 수 있도록 회복됨을 볼 수 있다.



(a)



(b)

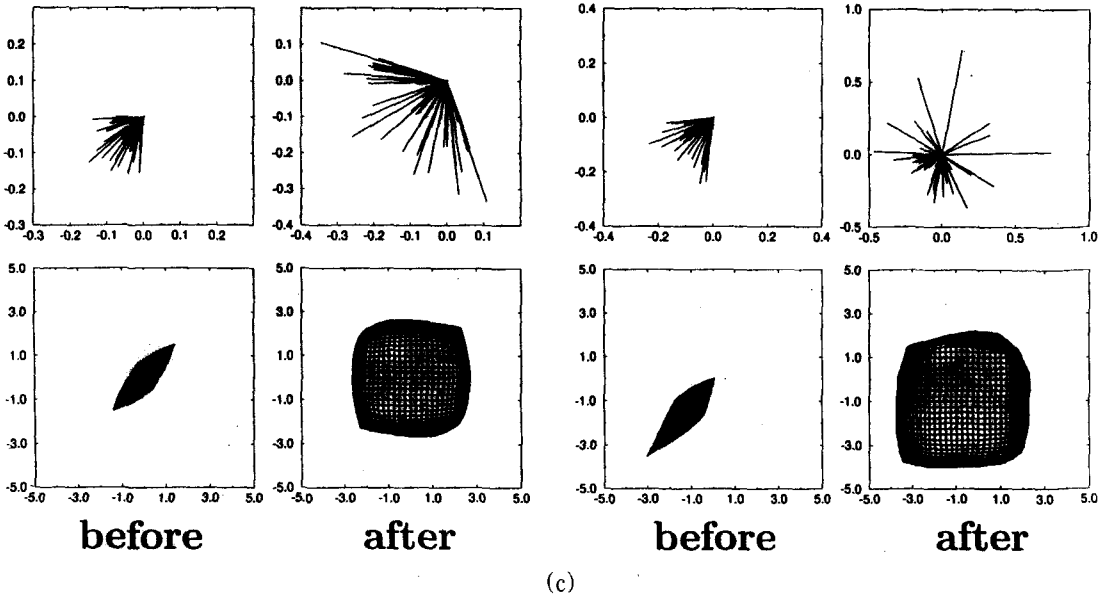


그림 4. 적응에 의한 집단 코딩의 재구성. 재구성 이전과 이후에 대한 세포들의 선호방향과 그 가중치 크기 및 대응되는 이동 지도를 나타내었다. (a) 0도에서 90도 사이의 선호방향을 갖는 세포들을 제거 하였을 때. (b) 위쪽 선호방향을 갖는 세포들을 제거하였을 때. (c) 선호방향이 -90도에서 -180도 사이인 세포들만 남겼을 때.

Fig. 4. Reorganization of the population coding by adaptation. The preferred directions and weight values of the cells and the corresponding movement maps before and after reorganizations are given. (a) When the cells whose preferred directions are between 0 and 90 degrees are removed. (b) When the cells with upward preferred direction component are removed. (c) When the cells whose preferred directions are between -90 and -180 degrees are remained.

그리고 집단 코딩에 사용된 세포수가 감소할수록 전반적으로 가중치의 크기가 줄어들므로, 많은 수의 세포를 제거할수록 이를 보상하기 위해 세포 각각의 가중치 값의 크기가 더욱 증가함을 볼 수 있다. 경우 1이 경우 2에 비해 적응성이 뛰어난데 반해 (혹은 손상에 더욱 강한데 반해) 경우 2는 경우 1에 비해 선형영역 범위가 넓다.

IV. 토의 및 결론

제안된 적응 집단 코딩 모델은 모든 세포가 모든 특징요소들을 표현하는데 함께 기여한다고 간주되었다. 즉 그림 1(a)의 점선 안에서 신경세포들과 특징요소 사이가 완전히 연결되어 있는 경우이다. 그러나 세포마다 표현에 기여하는 특징들이 부분적으로 전문화된 경

우도 있을 수 있다. 이 경우 세포들과 특징요소들과는 부분적 연결로 이루어진다. 이 경우에는 코딩에 무관한 가중치값을 0혹은 어떤 값으로 제한함으로써, 마찬가지로 식 (4)를 적용하여 적응 집단코딩 모델을 얻을 수 있을 것이다.

우리가 제안하는 적응적 집단 코딩 모델은 원숭이의 자발적 팔 움직임에 있어서 운동피질 세포의 활동 성질에 기초하여 제안되었지만, 명백히 손의 이동외에도 다른 정보를 코딩하는데 적용될 수 있다. 그 한 예로 사람이나 원숭이의 얼굴 영상을 코딩하는 경우를 생각해 보자. 얼굴 영상의 특징들로는 눈과 눈사이의 거리, 눈과 코간의 거리, 얼굴의 길이, 얼굴의 넓이, 입술의 두께와 넓이, 코와 입간의 거리, 입이 있는 위치에서의 얼굴폭, 눈이 있는 위치에서의 얼굴폭, 눈의 크기 및 기울어진 각도, 이마의 넓이 및 길이등을 생각할 수 있

다. 이러한 값들을 원소로하는 특징 벡터들을 각각의 얼굴 영상에 대해 구하고, 이를 많은 수의 신경에 집단 코딩 시킬 수 있다. 실제로 원숭이의 사람 얼굴 인식에서도 앞에서 열거한 특징들이 집단코딩되어 사용되고 있음을 뒷받침하는 생리학적 실험이 보고된 바 있다 [14].

결론적으로, 어떤 정보를 표현할 때 그의 특징 요소들을 추출한 후 이를 많은 수의 신경활동으로 표현하는 적응적 집단 코딩 모델을 오류 최소법에 기초하여 제안하였다. 이 모델을 원숭이의 자발적 팔운동에 있어서 운동피질 세포에 적용할 때 실험적으로 관측된 결과와 잘 부합한다는 것을 알았다. 게다가 부분적으로 세포를 제거했을 때와 같이 갑작스런 표현오차가 발생했을 때, 남은 세포들이 자신들의 선호방향과 기여정도를 조절함으로써, 그 오차를 줄이는 적응적 성질을 갖고 있다. 이 모델에서는 세포들의 초기 선호방향이 작업 공간에 균일하게 분포하지 않았다면, 최종학습 후의 선호 방향들의 방향이 바뀌기는 하지만 완전히 균일한 분포를 주지 않음을 예측하고 있다. 또, 신경세포의 비선형적 입출력 함수에 따른 적응성을 조사해 보았는데, 동작점이 선형영역의 가운데 있는 경우 (경우 1)가 동작점이 선형영역의 끝부분에 있는 경우 (경우 2)에 비해, 남은 세포의 선호 방향을 많이 바꾸지 않고도 발생된 오차를 많이 줄일 수 있다는 점에서, 적응성이 낮다고 말할 수 있다. 반면에 경우 2가 경우 1에 비하여 넓은 선형영역을 가짐을 알 수 있었다. 이 적응적 모델의 타당성은, 집단코딩에 기초한 정보처리를 수행한다고 여겨지는 실제의 뇌피질에서 유사한 적응성질이 존재하는지를 조사해 봄으로써, 확인할 수 있을 것이다.

### 감사의 글

이 연구에 도움을 준 캘리포니아 공과대학 (California Institute of Technology, Pasadena, CA, USA)의 Demetri Psaltis 교수와 George Barbastathis에게 감사드린다. 이 연구의 일부분은 본 저자가 한국과학재단의 연수지원에 의해 캘리포니아 공과대학에서 연수를 받는 동안에 수행되었음을 밝힌다.

### 참고문헌

[1] J. F. Kalaska, and D. J. Crammond,

"Cerebral cortical mechanisms of reaching movements," *Science* **255**, 1517-1523, 1992.

- [2] A. P. Georgopoulos, A. D. Schwartz, and R. E. Kettner, "Neuronal population coding of movement direction," *Science* **233**, 1416-1419, 1986.
- [3] A. P. Georgopoulos, R. E. Kettner, and A. B. Schwarz, "Primate motor cortex and free arm movement to visual targets in three-dimensional space. II. Coding of direction of movement by a population," *J. Neurosci.* **8**, 2928-2937, 1988.
- [4] A. P. Georgopoulos, J. T. Lurito, M. Petrides, A. D. Schwartz, and J. T. Massey, "Mental rotation of the neuronal population vector," *Science* **243**, 234-236, 1989.
- [5] A. P. Georgopoulos, M. Taira, and A. Lukashin, "Cognitive neurophysiology of the motor cortex," *Science* **260**, 47-52, 1993.
- [6] G. Gaal, "Calculation of movement direction from firing activities of neurons in intrinsic coordinate systems defined by their preferred directions," *J. Theor. Biol.* **162**, 103-130, 1993.
- [7] H. S. Seung, and H. Sompolinsky; Simple models for reading neuronal population codes," *Proc. Natl. Acad. Sci. USA* **90**, 10749-10753, 1993.
- [8] S. Tanaka, "Numerical study of coding of the movement direction by a population in the motor cortex," *Biol. Cybern.* **71**, 503-510, 1994.
- [9] T. D. Sanger, "Theoretical considerations for the analysis of population coding in motor cortex" *Neural Comp.* **6**, 29-37, 1994.
- [10] D. E. Rumelhart, J. L. McClelland, and the PDP Research Group, *Parallel Distributed Processing Vol. 1: Foundations*, (The MIT Press, MA, 1986), Chap. 8.
- [11] J.-S. Jang, S.-Y. Lee, and S.-Y. Shin, "An optimization network for matrix



- inversion." in D. Z. Anderson (ed.), *Neural Information Processing systems* (AIP, New York, 1988), 397-401.
- [12] A. B. Schwarz, R. E. Kettner, and A. P. Georgopoulos, "Primate motor cortex and free arm movement to visual targets in three-dimensional space. I. Relations between single cell discharge and direction of movement" *J. Neurosci.* **8**, 2913-2927, 1988.
- [13] A. L. H. van der Meer, F. R. van der Weel, and D. N. Lee, "The functional significance of arm movements in neonates" *Science* **267**, 693-695, 1995.
- [14] M. P. Young and S. Yamane, "Sparse population coding of faces in the inferotemporal cortex," *Science* **256**, 1327-1331, 1992.

---

저 자 소개



張珠錫(正會員)

1961년 6월 12일생. 1984년 2월 부산대학교 전기기계공학과 졸업(공학사). 1986년 2월 한국과학기술원 전기 및 전자공학과 졸업(공학석사). 1989년 8월 한국과학기술원 전기 및 전자공학과 졸업(공학박사).

1989년 11월~1991년 4월 미국 University of Colorado (Boulder 소재) 물리학과 및 Joint Institute for Laboratory Astrophysics 연구원. 1991년 8월~1993년 2월 한국전자통신연구소 기초기술연구부 선임연구원. 1993년 3월~1995년 3월 부산수산대학교 정보통신공학과 전임강사. 1994년 7월~1995년 7월 미국 California Institute of Technology (Pasadena 소재) Computation and Neural Systems 객원 연구원. 1995년 4월~현재 부산수산대학교 정보통신공학과 조교수. 주관심분야는 광정보처리, 광메모리, 광패턴인식, 신경정보처리 모델링등임.