

# 퍼셉트론 형태의 SOM : SOM의 일반화

송근배<sup>†</sup> · 이행세<sup>††</sup>

## 요 약

본 논문에서는 퍼셉트론 형태의 SOM(PSOM)을 정의한다. 그리고 이 PSOM의 출력뉴런의 목표 값을 적당히 설정할 경우 PSOM은 Kohonen's SOM이 됨을 보인다. 이는 PSOM가 SOM의 일반화된 알고리즘임을 시사한다. 또한 클러스터링 문제를 단위 초구면상(Hypersphere)에 분포한 벡터들로 한정할 경우 SOM은 Dot-product SOM(DSOM)과 동등한 알고리즘임을 보인다. 즉, DSOM은 SOM의 특수한 형태이며, 결론적으로, PSOM은 DSOM도 포함하는 알고리즘이다. 본 논문에서는 이를 증명하고 결론을 맺는다.

# Perceptron-like SOM : Generalization of SOM

Geun-Bae Song<sup>†</sup> · Haing-Sei Lee<sup>††</sup>

## ABSTRACT

This paper defines a perceptron-like self-organizing map(PSOM) and show that PSOM is equivalent to Kohonen's self-organizing map(SOM) if target values of output neurons of PSOM are selected properly. This fact implies that PSOM is a generalized SOM algorithm. This paper also show that if clustering is restricted to vector sets distributed on hypersphere with unit radius, SOM and dot-product SOM(DOSM) are equivalent algorithms. Therefore we conclude that DSOM is a special case of SOM, which in turn a special case of PSOM.

## 1. 서 론

Kohonen의 Self-organizing map(SOM)[1]은 잘 알려진 알고리즘이다. 이는 간단한 전향(Feed-forward) 형태의 신경망이며 자율적인 경쟁학습(Competitive learning)을 한다. 학습은 승자(Winner) 혹은 승자의 이웃들만 하며 나머지 패자(Loser)들은 전 상태를 그대로 유지하는 식으로 신경망 가중치(Synaptic weight) 벡터들을 변화시켜나간다. 학습에 참여하는 가중치 벡터들은 Hebb 학습규칙[2]에 기초하여 학습하는데 그의 이론은 전체적인 지시를 내리는 교사가 없이(자율학습) 좁은 영역에서의 뉴런 사이의 상호 영향에 따라 가중

치를 조절해 나가는 이론이다. 요약만 이야기하면 두 뉴런을 연결해주는 가중치는 양쪽 뉴런의 출력의 곱에 비례하는 양으로 조절된다. 가령, 둘 다 양의 큰 값으로 활성화되었을 경우(성공) 그 사이의 가중치는 양의 큰 값으로 증가(연결 강화)될 것이고, 그 반대의 경우에는 음의 큰 값으로 감소(연결 약화)될 것이다. Kohonen의 학습법도 이와 유사하여 주어진 입력 벡터에 대해 승리한 뉴런의 가중치 벡터는 입력벡터 쪽으로 정렬되는 형태로 강화되고 패배한 뉴런들은 전 상태가 그대로 유지되는 형태로 학습에서 소외시킨다. 이와 같이 동작하는 SOM은 반복학습을 통하여 미지의 데이터의 통계적 특성을 스스로 발견해 나가며 고차원 데이터를 시각화(Visualization)하고, 양자화(Clustering) 혹은 패턴분류(Classification)를 할 수 있는 알고리즘이 된다.

한편, 퍼셉트론 신경망[3-5]은 목표 값이 주어지야

† 정희원 아주대학교 대학원 전자공학과

†† 김희원 아주대학교 교수

논문접수 2000년 7월 7일, 심사완료 2000년 9월 28일


하며(타올학습) 이에 따라 목적함수(보통 Mean Square Error)가 정의되고 경도 강하(Gradient descent)방법에 의해 가중치들을 조절하여 이 함수에의 최적화를 수행하는 알고리즘이다 이와 같이 동작하는 퍼셉트론 또한 입력 데이터를 분류할 수 있으며 특히, 다층 구조로 동작할 경우 훨씬 복잡한 함수를 모델링 할 수 있는 알고리즘이다. 이상에서 볼 때 퍼셉트론과 SOM은 서로 다른 이론적 배경에서 제안되었다.

본 논문에서는 Perceptron-like SOM(PSOM)을 제안한다 이 신경망은 단층 퍼셉트론과 달리 경쟁학습을 하며 경쟁의 결과로부터 자율적으로 목표패턴을 생성한다. 즉 목표패턴을 스스로 생성(Self-generating)하는 자율학습 알고리즘이다. 특히, PSOM의 목표 값을 적당히 선정할 경우 PSOM는 SOM과 같은 알고리즘이 됨을 알 수 있다. 그 결과 보다 일반화된 형태의 SOM을 정의할 수 있음을 보인다.

본 논문의 2절에서는 PSOM 알고리즘을 정의하미 또한 SOM과 Dot-product SOM(DSOM)에 대해 복습한다. 3절에서는 PSOM이 SOM의 일반화된 알고리즘임을 증명하며, 4절에서 결론을 맺는다.

## 2. Perceptron-like SOM과 Kohonen의 SOM에 대한 검토

단층 퍼셉트론이나 SOM에서 쓰이는 신경망 구조는 (그림 1)과 같다




(그림 1) 단층 신경망

여기서, 입력 벡터  $X = \{x_1, x_2, \dots, x_N\}^T \in R^N$  가중치 벡터를  $W_i = \{w_{i1}, w_{i2}, \dots, w_{iN}\}^T \in R^N$ 라 하고, 출력 뉴런의 출력 값을  $y_i$ 라 하자. 여기서 T는 전치(Transpose)를,  $i \in \{1, 2, \dots, M\}$ 는 출력 뉴런을 가리킨다.

### 2.1 PSOM

(그림 2)는 본 논문에서 제안하는 PSOM의 개략도를 나타내고 있다. 'Single-layer Neural Net-work'이 표시된 블록은 (그림 1)의 신경망 구조에 대응되는 블록이다. PSOM는 일반적인 퍼셉트론과 마찬가지로 경도 강하 학습법을 사용한다. 그러나 PSOM는 일반적인 퍼셉트론에 대해 다음 사항이 수정이 되었다 이 점을 1.1절에서 언급하며 1.2절에서는 PSOM의 학습알고리즘에 대해서 언급한다.



(그림 2) 제안된 Perceptron-like SOM

#### 2.1.1 PSOM와 표준 퍼셉트론의 차이점

##### 1) 뉴런 입출력 관계식

뉴런의 출력은 가중 합(Weighted sum)의 형태

$$y_i(t) = f\left(\sum_{j=1}^N w_{ij}(t)x_j(t)\right) = f(W_i^T(t)X(t)) \quad (1)$$

에서 Euclidean Norm의 형태로 바뀐다. 즉,

$$y_i(t) = \|X(t) - W_i(t)\| \quad (2)$$

여기서  $f(\cdot)$ 는 활성화함수,  $\|\cdot\|$ 는 Euclidean Norm을 나타내며  $t$ 는 학습 사이클을 가리킨다.

Euclidean Norm은 연속적으로 미분 가능한 함수이므로 뉴런 출력을 이와 같이 정의할 때 경도 강하 방법을 적용하기 용이하다.(이와 유사한 형태의 입출력을 정의하는 신경망으로 RBF신경망[6]이 있다. 그러나 RBF에서는 PSOM에서 다루지 않는 활성화수가 중요한 의미를 가진다).

##### 2) 경쟁학습의 도입

SOM와 마찬가지로 경쟁학습 방법을 도입한다 즉, 출력 단계 승자 Decision 블록을 둔다. 승자는 하나(Single-winner mode)일 수도 있고 여럿(Multiple-

winner mode)이 될 수도 있다. 그리하여 목표패턴은 기존의 퍼셉트론과 달리 각 입력벡터에 대해 사전에 정해지지 않고 일단 승자 뉴런이 결정된 뒤 그에 따라 적절한 규칙에 의해 생성되게 된다

3) 활성화함수

활성함수는 사용하지 않는다(혹은 선형 함수를 사용한다). 이는 위 1번의 조건에 함축되어 있다.

4) Bias 항

퍼셉트론에서 일반적으로 사용되는 Bias 항은 사용하지 않는다. 이는 PSOM의 가중치 벡터의 의미가 패턴공간의 경계선과 관련된 파라미터가 아니라 SOM과 마찬가지로 클러스터 Centroid 벡터의 의미를 가지므로 불필요한 항이다.

2.1.2 PSOM 학습 알고리즘

1) 입출력 관계식 :

$$y_i(t) = \| X(t) - W_i(t) \|.$$

2) 승자 결정(Winner decision)

$$\| X(t) - W_c(t) \| = \min, ( \| X(t) - W_i(t) \| ), \quad (3)$$

여기서 c는 승자 뉴런을 가리킨다.

3) 학습(PSOM 학습법)

아래는 경도 강하 방법에 의해 PSOM 학습법을 유도한 결과이다 아래 식의 유도는 III절에서 하기로 한다.

$$\begin{aligned} W_i(t+1) &= W_i(t) + \Delta^{psom} W_i(t) \\ &= W_i(t) + [-\alpha(t) \nabla \varepsilon_i] \\ &= W_i(t) + [-\alpha(t) (\frac{t}{y_i} - 1) [X - W_i]], \\ & \quad i \in \{1, 2, \dots, M\}, (0 < \alpha(t) < 1) \end{aligned} \quad (4)$$

2.2 SOM

2.2.1 뉴런 입출력 관계식(정의)

원래의 SOM의 입출력은 아래와 같은 형태로 정의되어 있지 않다. SOM에서는 입력 벡터의 해석을 뉴런의 ‘출력 값’이 아니라 활성화된 뉴런(승자)의 ‘위치’에

서 이끌어낸다. 아래의 정의는 단지 PSOM과의 설명의 일관성을 위해 설정한 것이다.

$$y_i(t) \equiv \| X(t) - W_i(t) \|.$$

2.2.2 승자 결정(Winner decision)

$$\| X(t) - W_c(t) \| = \min, \{ \| X(t) - W_i(t) \| \}$$

2.2.3 학습(SOM학습법)

1) 단일 승자 모드(Single-winner mode)

$$\begin{aligned} W_c(t+1) &= W_c(t) + \Delta^{som} W_c(t) \\ &= W_c(t) + \alpha(t) [X(t) - W_c(t)], \end{aligned} \quad (5)$$

$$(0 < \alpha(t) < 1)$$

$$W_i(t+1) = W_i(t), \quad \text{그 밖의 } i \neq c. \quad (6)$$

2) 복수 승자 모드(Multiple-winner mode)

만약  $i \in N_c(t)$  라면,

$$\begin{aligned} W_i(t+1) &= W_i(t) + \Delta^{som} W_i(t) \\ &= W_i(t) + \alpha(t) [X(t) - W_i(t)], \end{aligned} \quad (7)$$

$$(0 < \alpha(t) < 1)$$

만약  $i \notin N_c(t)$  라면,

$$W_i(t+1) = W_i(t) \quad (8)$$

여기서  $N_c(t)$ 는 승자 뉴런 c에 이웃한 뉴런들의 집합을 나타낸다.

2.3 Dot-product SOM

2.3.1 뉴런 입출력 관계식

$$y_i(t) = \sum_{j=1}^N w_{ij}(t) x_j(t) = W_i^T(t) X(t). \quad (9)$$

2.3.2 승자 결정(Winner decision)

$$y_c(t) = \max, \{ y_i(t) \}. \quad (10)$$

2.3.3 학습(DSOM 학습법)

1) 단일 승자 모드

$$\begin{aligned}
 W_c(t+1) &= W_c(t) + \Delta^{dsom} W_c(t) \\
 &= W_c(t) + \alpha(t)X(t) \quad (11) \\
 &\quad (0 < \alpha(t) < 1)
 \end{aligned}$$

$$W_i(t+1) = W_i(t), \quad \text{그 밖의 } i \neq c \quad (12)$$

2) 복수 승자 모드

만약  $i \in N_c(t)$ 라면,

$$\begin{aligned}
 W_c(t+1) &= W_c(t) + \Delta^{dsom} W_c(t) \\
 &= W_c(t) + \alpha(t)X(t), \quad (13) \\
 &\quad (0 < \alpha(t) < 1)
 \end{aligned}$$

만약  $i \notin N_c(t)$ 라면,

$$W_i(t+1) = W_i(t)$$

### 3. PSOM과 SOM, DSOM의 관계

PSOM과 SOM의 관계는 먼저 단일 승자 모드에 대해 살펴보기로 한다. 그런 다음 이 결과의 복수 승자 모드로의 확장은 직접적으로 이루어질 수 있다.

**정리 1 :** 단일 승자 모드에서 PSOM는 승자 뉴런  $c$ 의 목표 값을 '0'으로 하고 나머지 뉴런(패자)의 목표 값은 자기 자신의 출력 값  $y_i (i \neq c)$ 로 하였을 경우 SOM와 같아진다

**증명 :** PSOM와 SOM의 신경망 구조는 동일 하므로 두 신경망의 가중치에 대한 학습법이 같음을 보인다. 먼저 경도 강화 방법에 의해 PSOM의 충분 항  $\Delta^{psom} W_c(t)$ 을 유도한 뒤 정리에서 제시된 목표 값이 주어질 경우  $\Delta^{psom} W_c(t) = \Delta^{som} W_c(t)$ 로 귀결됨을 보인다(식을 간단히 하기 위해 미분 식은 벡터 형태로 나타내고 학습 사이클  $t$ 는 생략하기로 한다).

위 PSOM의 입력벡터를  $X$ , 뉴런의 출력을  $y_i$ 라 하면 입출력 관계식은 아래와 같다.

$$y_i = \|X - W_i\|, \quad i \in \{1, 2, \dots, M\}$$

각 출력 노드  $i$ 에서의 목표 값을  $t_i$ 라하고, 오차함수  $\epsilon_i$ 는 다음과 같이 정의하기로 한다.

$$\epsilon_i = \frac{1}{2}(t_i - y_i)^2 = \frac{1}{2}(t_i - \|X - W_i\|)^2 \quad (14)$$

이 오차함수에 대해 벡터  $W_i$ 방향으로의 Gradient  $\nabla \epsilon_i$ 를 계산하면

$$\begin{aligned}
 \nabla \epsilon_i &= \frac{1}{2} \frac{\partial}{\partial W_i} (t_i - \|X - W_i\|)^2 \\
 &= \frac{1}{2} \frac{\partial}{\partial W_i} (t_i^2 - 2t_i \|X - W_i\| + \|X - W_i\|^2) \quad (15) \\
 &= \left( \frac{t_i}{\|X - W_i\|} - 1 \right) [X - W_i] \\
 &= \left( \frac{t_i}{y_i} - 1 \right) [X - W_i].
 \end{aligned}$$

따라서 각 뉴런의 가중치 벡터들을 학습시키기 위한 충분 항은 다음과 같이 된다.

$$\Delta^{psom} W_i = -\alpha \nabla \epsilon_i = -\alpha \left( \frac{t_i}{y_i} - 1 \right) [X - W_i] \quad (16)$$

이 된다.

이때 승자 뉴런의 목표 값  $t_c$ 을 0으로 주면 승자 뉴런의 가중치 벡터의 충분 항은

$$\begin{aligned}
 \Delta^{psom} W_c &= -\alpha \left( \frac{0}{y_c} - 1 \right) [X - W_c] \\
 &= \alpha [X - W_c] = \Delta^{som} W_c \text{ 가 된다}
 \end{aligned}$$

또한 이 식에서 패자들의 목표 값  $t_i (i \neq c)$ 를 그 뉴런의 출력 값  $y_i$ 로 할 경우  $\Delta^{psom} W_i = 0 = \Delta^{som} W_i$ 이 됨을 쉽게 알 수 있다. ■

<검토> SOM 학습법을 살펴보면 승자의 가중치 벡터를 입력벡터 쪽으로( $\Delta^{som} W_c = \alpha [X - W_c]$ 만큼) 이동시키는 형태이다 즉, 승자의 가중치 벡터가 입력벡터에 가까워지도록 한다. 이는 승자의 출력  $y_c = \|X - W_c\|$ 가 0에 가까워지도록 하는 것과 동등하다. 경도 강화 학습법 관점에서, 승자의 목표 값  $t_c$ 를  $0 \leq t_c < y_c$ 의 어떤 값으로 줄 경우 위 학습법과 동등한 효과를 가져올 수 있다. 특별히  $t_c$ 를 0으로 줄 경우 승자 뉴런의 학습에 있어서 PSOM와 SOM은 정확히 일치하게 된다. 마찬가지로의 논의를 SOM의 패자들에 대해 할 수 있는데, SOM의 패자들의 가중치 벡터를 변화시키지 않는다는 것(즉,  $\Delta^{som} W_i = 0, i \neq c$ )은 같은 입력 벡터  $X$ 에 대해 패자들의 출력  $y_i (i \neq c)$ 가 전과 같도록 지시하는 것과 같다. 이는 경도 강화 학습법 관점에서 패자 뉴런의 목

표 값  $t_i$ 를 전의 출력  $y_i$ 로 지시하는 것과 동등하다  
그 결과  $\Delta^{PSOM} W_i = 0 = \Delta^{DSOM} W_i (i \neq c)$  됨을 쉽게 알 수  
있다. 이와 같이 각 뉴런의 목표 값을 정해진 결과  
PSOM 학습법은 SOM 학습법과 같아진다.

결론적으로, PSOM와 SOM은 같은 구조이며 같은  
학습법을 가짐을 알 수 있다. 그러므로 특정한 목표패  
턴이 주어질 경우 PSOM와 SOM은 같은 알고리즘이다

소 정리 2: 정리 1은 복수 승자 모드로 확장될 수  
있다.

증명: SPVQ의 승자의 이웃들에게도 정리 1의 승자  
와 같은 목표 값을 부여하면 된다 ■

소 정리 3: 입력 벡터  $X$ 와 가중치 벡터  $W_i$ 가 단위  
벡터이고  $c^{som}$ 를 SOM의 승자 뉴런,  $c^{dsom}$ 를 DSOM의  
승자 뉴런이라 할 때,

$$c^{som} = \arg \min_i \{ \|X(t) - W_i(t)\| \} \text{와}$$

$$c^{dsom} = \arg \max_i \{ W_i^T(t)X(t) \}$$

두 연산의 결과는 같다 즉,

$$c^{som} = c^{dsom} \tag{17}$$

증명:  $c^{som}$ 의 연산에서 시작하여 이는  $c^{dsom}$ 와 같아짐  
을 보이면 된다

승자 뉴런 결정한다는 관점에서 다음 등호가 성립함  
을 쉽게 알 수 있다.

$$c^{som} = \arg \min_i \{ \|X(t) - W_i(t)\| \}$$

$$= \arg \min_i \{ \|X(t) - W_i(t)\|^2 \} \tag{18}$$

여기서 괄호 안의 Norm의 제곱(내적)은 다음과 같이  
 전개된다.

$$\|X - W_i\|^2 = (X - W_i)^T (X - W_i)$$

$$= (X^T - W_i^T)(X - W_i)$$

$$= X^T X - X^T W_i - W_i^T X + W_i^T W_i$$

$$= 2 - 2W_i^T X \tag{19}$$

위 식의 마지막 등호는  $X$ 와  $W_i$ 가 단위 벡터라는 조건  
과  $X^T W_i = (W_i^T X)^T = W_i^T X$ 라는 사실로부터 얻어진다  
이 결과를 괄호 안에 대입하면 다음의 결과로 귀결된다

$$c^{som} = \arg \min_i \{ \|X(t) - W_i(t)\|^2 \}$$

$$= \arg \min_i \{ 2 - 2W_i^T X \} = \arg \max_i \{ W_i^T X \}$$

$$= c^{dsom} \tag{20} \blacksquare$$

정리 4: 입력벡터들의 집합을 단위 초구면으로 한  
정할 경우 SOM과 DSOM은 동일한 알고리즘이다.

증명: SOM과 DSOM은 동일한 구조의 신경망이다.  
따라서 (정리 1)의 경우와 마찬가지로 두 알고리즘의  
학습법이 같음을 보이기만 하면 된다

먼저 소 정리 3로부터 SOM와 DSOM은 동일한 승  
자를 결정함을 알 수 있다. 이제 소 정리 3의 결론과  
더불어 각각의 승자  $c^{som}$ 과  $c^{dsom}$ 의 가중치 벡터들이  
각각의 학습법에 대해 같은 방향으로 학습됨을 보이면  
된다. 이의 증명은 기하학적인 설명으로 대신하기로  
한다.(제 2차원 공간에서의 기하학적 설명은 (그림 3)과  
4를 참조한다)

SOM의 학습 방정식과 DSOM의 학습 방정식을 다  
시 쓰면 각각 다음과 같다.

$$W_c(t+1) = W_c(t) + \Delta^{som} W_c(t)$$


$$= W_c(t) + \alpha(t)[X(t) - W_c(t)]$$

$$(0 < \alpha(t) < 1)$$

$$W_c(t+1) = W_c(t) + \Delta^{dsom} W_c(t)$$

$$= W_c(t) + \alpha(t)X(t) \quad (0 < \alpha(t) < 1)$$

먼저 SOM의 경우를 살펴보면 승자 뉴런의 가중치  
벡터는 가중치 벡터와 입력 벡터 사이의 차이가 줄어  
드는 방향으로 변화된다.(그림 3)에서 보면,

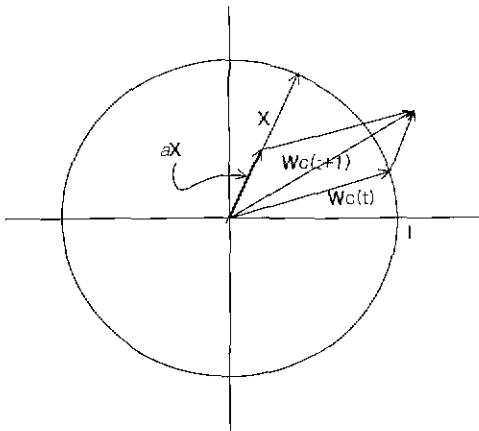


(그림 3) SOM학습에 의한 가중치 벡터의 변화

$W_c(t)$ 의 끝에서  $X$ 의 끝으로 벡터를 연결하면 차 벡터  $[X - W_c(t)]$ 가 된다. 다음에 스칼라  $\alpha(0 < \alpha < 1)$ 를 곱하면 크기가 줄어든  $\Delta^{som} W_c(t) = \alpha[X - W_c(t)]$ 가 된다. 그 다음에 원점에서 벡터  $\Delta^{som} W_c(t)$ 의 끝까지 잇는 선이 증분된 가중치 벡터  $W_c(t+1)$ 이다. 최종적으로 증분된 가중치 벡터  $W_c(t+1)$ 는 단위 길이로 정규화(Normalize)된다. 이상에서 볼 때 학습은 가중치 벡터를 입력벡터 쪽으로 회전시키되 그 길이는 바꾸지 않고 회전만 시키는 것이 된다.

DSOM의 경우에도 이와 비슷한 설명을 할 수 있다. (그림 4)를 보면 DSOM의 경우도 승자의 가중치 벡터를 입력벡터 쪽으로 회전시키는 형태이다.

이상은 다차원 공간으로 확장될 수 있다 그러므로 단위 초구면 상에서 SOM과 DSOM은 같은 알고리즘이다.■



(그림 4) DSOM학습에 의한 가중치 벡터의 변화

<검토> SOM과 DSOM의 경우에 학습률  $\alpha(t)$  ( $0 < \alpha(t) < 1$ )를 동일한 함수로 사용할 경우 두 알고리즘은 학습 과정에서 Step size의 차이를 가지게 된다. 하지만 학습률 함수  $\alpha(t)$ 는 정해진 것이 없고 단지  $t$ 에 반비례하여 감소하는 임의의 스칼라 함수라는 자유가 주어졌기 있다 따라서 이 차이는 중요하지 않다

#### 4. 결 론

본 논문에서는 Kohonen의 SOM 학습법을 타울학습 정도 강화 학습법에 의해 재해석하였다 먼저 단일 승자 모드에 대해서 고찰한 뒤 이의 결과는 복수 승자

모드로 직접적으로 확장하였다 결과적으로 이렇게 해서 유도된 새로운 PSOM알고리즘은 SOM의 일반화된 알고리즘이 됨을 보였다. 즉, PSOM 학습법에 특정 목표 패턴을 부여할 경우 PSOM는 Kohonen의 SOM으로 귀결됨을 보인 것이다.

또한 SOM과 DSOM을 비교함에 있어, 입력벡터들이 단위 초구면의 벡터들의 집합으로 한정될 경우 SOM과 DSOM은 동일한 알고리즘임을 보였다 DSOM은 내적의 형태로 입력 벡터의 가중치 벡터의 거리를 계산하므로 그 응용이 단위 초구면상으로 제약되어야 한다. 반면에 SOM은 이와 같은 엄밀한 제약조건이 필요치 않다 따라서 SOM은 DSOM의 일반화된 알고리즘이다. 이상을 종합하여 볼 때, 결론적으로, SOM은 그것이 Euclidean Norm 형태든 Dot-product 형태든 PSOM의 특수한 형태이다.

PSOM가 SOM의 일반화된 신경망이라는 관점을 얻음으로써 SOM 설계의 보다 큰 자유도를 얻을 수 있다. 즉, 수렴속도 개선이나 극부 최소(Local minimum) 문제를 극복하기 위해 다른 형태의 목표패턴을 고려할 수 있으며 또한 이 문제들을 해결하기 위해 그동안 경도 타울학습 강화 학습법 분야에서 제안된 방법들의 사용 및 결과예측이 가능해진다. 이는 본 논문의 향후 연구과제가 될 것이다.

#### 참 고 문 헌

- [1] T Kohonen, *Self-Organizing Maps*. Springer-Verlag, 1995.
- [2] D. O. Hebb, *Organization of Behavior*, New York : Science Editions. 1949.
- [3] R. Rosenblatt, *Principles of Neuro-dynamics*. New York : Spartan Books. 1959.
- [4] D Rumelhart, J. McClelland and the PDP Research Group, *Parallel Distributed Processing: Explorations in the Micro-structure of Cognition*, MIT Press, Cambridge, MA, Vol 1, 1986.
- [5] R. P Lippman, "An introduction to computing with neural nets," *IEEE ASSP Magazine*, Vol. ASSP-38, Vol.4, pp.4-22, April 1987.
- [6] X. M Song, "A radial basis function network for empirical modeling of soil extraction process," in *Proc. of EANN'95 Conf*, 1995.



### 송근배

e-mail:geunbae@madang.ajou.ac.kr

1992년 아주대학교 전자공학과  
(학사)

1995년 아주대학교 전자공학과  
(공학석사)

1995년~1996년 현대전자  
소프트웨어 연구소

1996년~현재 아주대학교 전자공학과 박사과정

관심분야 : 음성인식, 인공지능 및 신경망

### 이행세

e-mail:hangsci@madang.ajou.ac.kr

1966년 전북대학교 전기공학과(학사)

1972년 서울대학교 전자공학과(공학석사)

1984년 고려대학교 전자공학과(공학박사)

1968년~1970년 해군사관학교 교관

1982년~1983년 Columbia Univ.n.y. 객원교수

1987년~1988년 INRIA PARIS 객원교수

1992년~1994년 거제전문대학장

1973년~현재 아주대학교 교수

관심분야 : 음성인식, 인공지능 및 신경망