

확산뉴런망을 이용한 밝기변화 추출

(Detection of Intensity Changes by a Diffusion Neural Network)

權 栗*, 南 基 坤*, 尹 台 焄*, 金 在 昌*

(Yool Kwon, Ki Gon Nam, Tae Hoon Yoon, and Jae Chang Kim)

要 約

뉴런망에는 뉴런들이 시냅스를 통해 다른 뉴런들과 연결되어 있으며, 외부자극이 있을 때 자극을 받은 뉴런이 주변의 뉴런들에게로 그 자극을 전달하는 기능과 자극을 억제하는 기능을 갖고 있다. 이러한 자극의 전달이나 억제는 시냅스를 통해 반응이 확산되는 동작으로 볼 수 있다. 본 논문에서는 뉴런망의 확산기능을 이용하여 흥분부와 억제부로 구성되는 확산뉴런망 모델을 세우고, 이것이 외부자극으로 가해지는 입력영상에 대해 밝기변화를 추출하는 기능이 있음을 보인다. 또한 확산계수, 확산횟수와 공간주파수와의 관계를 제시한다. 확산뉴런망을 이용하여 윤곽선을 검출할 경우 기존의 LOG(a Laplacian of a Gaussian) 마스크보다 계산량을 줄일 수 있으며, 일련의 처리과정으로 종합적인 결과를 도출할 수 있다.

Abstract

In this paper we propose a diffusion neural network model. In this model, each excitatory and inhibitory neuron has the capability of diffusing external excitations. We show that this model can be used for the detection of intensity changes of an input image. The relations between the diffusion coefficient, the iteration number of diffusion, and the detected spatial frequency are analyzed. The calculation time is reduced than that of a LOG(a Laplacian of a Gaussian) method.

I. 서 론

인공지능(AI)은 사람이 사물을 보고 그 의미를 파악하며 생각하는 것과 같은 능력을 인공적으로 구현하려는 것으로 오래전부터 꾸준히 연구되어왔다. 그러나 인공지능에서 음성인식이나 영상인식과 같이 패턴정합(pattern matching)으로 처리되어야 될 작업은 데이터 양이 대단히 많아서 기존의 노이만(Neumann)형과 같이 명령어 단위로 처리하는 컴퓨터로는 그 처리가 용이하지 않

다. 최근 관심이 고조되고 있는 뉴로컴퓨터(neurocomputer)는 고등동물의 뉴런망작용을 인공적으로 구현하려는 것으로 병렬처리를 하기 때문에 음성인식이나 영상인식과 같은 작업을 쉽게 처리할 수 있다. 특히 영상처리 분야에서는 고등동물의 시각작용에 관한 연구결과를 구현하고자 하는 노력이 활발히 진행되고 있다.^[1-3]

뉴런망은 뉴런들과 그들간을 연결하는 시냅스(synapse)로 구성된다. 뉴런은 시냅스를 통해 다른 뉴런들로부터의 신호를 받으며, 입력된 신호들을 합한 값이 임계치(threshold)를 넘으면 다른 뉴런들에게 그 반응을 보낸다. 뉴런망은 시냅스의 연결세기로 정보를 처리하거나 기억한다. 연결세기는 입력정보에 따라 바람직한 출력을 얻을 수 있도록 학습되므로, 원하는 반응을 하는 시스템이 되게 할 수 있다. 따라서 뉴런망은 CAM(content

*正會員, 釜山大學校 電子工學科
(Dept. of Elec. Eng., Pusan Nat'l Univ.)
接受日字: 1992年 2月22日


addressable memory) 과 오류정정능력을 갖는 기억모델이나, 패턴정합을 병렬로 처리하는 패턴인식 모델, 또는 논리연산이나 산술연산을 하는 연산모델^[4] 등, 다양하게 적용될 수 있다. 특히 산술연산에 적용될 경우에는 컨볼루션(convolution)연산을 쉽게 수행할 수 있어, Oyster 등^[4]은 이를 이용하여 영상의 윤곽선을 검출하는 마스크 컨볼루션 연산에 적용시켜 시뮬레이션하였으며, 뉴런망의 파라미터를 적절히 조절함으로써 모든 논리연산도 가능함을 보였다.

일반적으로 동물의 시각피질은 다양한 폭과 방향을 가지는 윤곽선과 막대를 추출할 수 있는 특징추출기(feature detector)로 구성되어 있다. 그리고 이것은 폭이 좁은 가우스 분포를 갖는 흥분부(excitatory region)와 폭이 넓은 가우스 분포를 갖는 억제부(inhibitory region)의 중첩된 작용 즉, 가우스 분포함수의 차(DOG : a difference of two Gaussians)로 이루어지는 공간주파수 푸리에분석기(spatial frequency Fourier analysis)의 기능을 갖추고 있다.^[1,2] Marr^[1,5]는 영상에 포함된 정보중 인식에 가장 필요한 정보는 영상의 밝기변화로 보고 이를 추출할 수 있는 연산자인 가우스 분포함수를 2차 미분한 $\nabla^2 G$ (LOG : a Laplacian of a Gaussian) 함수를 제시하고, 이 연산자가 DOG 연산자와 마찬가지로 공간주파수 추출기로 사용될 수 있음을 보였다. 그리고 Huertas, Chen 등^[6,7]은 LOG 컨볼루션 연산의 계산량을 줄이는 방법을 제시하였다.


본 논문에서는 뉴런망을 이용하여 영상처리의 초기작업인 밝기변화를 추출하고자 한다. 뉴런망에 입력된 자극이 흥분부와 억제부로 나뉘어진 뉴런망에 각각 확산되는 모델을 구성하고, 이 모델로 DOG 연산이 가능하며 입력 영상의 다양한 밝기변화에 대한 반응을 얻을 수 있음을 시뮬레이션을 통해 보인다. 또한 확산계수(시냅스 세기)와 확산횟수에 대한 공간주파수와와의 관계를 제시하고, LOG 마스크(masking)과의 계산량 및 장단점을 비교하고자 한다.

II. 확산뉴런망

뉴런은 정보처리용 세포로서, 다른 뉴런들과 복잡하게 연결되어 뉴런망을 이룬다. 뉴런은 수상돌기를 통해 다른 뉴런들로부터 신호를 받으며 축삭돌기를 통해 다른 뉴런들에게 자신의 반응을 전달한다. 뉴런에 신호가 입력될 때 연결부분인 시냅스에서 연결세기가 가중치(weight)로서 곱하여지고, 이들이 모두 합하여진다. 합계가 어느 임계치를 넘으면 뉴런은 반응하며, 반응값이 출력된다. 그림 1은 뉴런의 동작을 나타낸 것이다. 반응함수는 S자 모양의 시그모이드(sigmoid) 함수이나, 이를 간략화하여 그림 1(b)



(a)



- ① a sigmoid function.
- ② a linear piece-wise function.
- ③ a binary function.

(b)

그림 1. (a) 뉴런모델
(b) 반응함수


Fig 1. (a) A typical neuron model,
(b) activation functions.

의 점선과 같은 선형조합 함수나 이진화 함수가 사용되기도 한다. 선형조합 함수의 선형부분만을 이용하면 산술연산, 특히 컨볼루션 연산에 적합하며, 이진화 함수를 이용하면 뉴런상태는 0 또는 1의 안정상태를 유지할 수 있으므로 논리연산이나 기억모델로 사용할 수 있다.


뉴런망에서 하나의 뉴런에 자극이 가해지면 그 자극은 주변의 다른 뉴런들에게로 전달되어 가는데, 이러한 과정을 자극이 주변으로 확산되어 가는 현상으로 볼 수 있다. 그림 2에 1차원적으로 확산하는 뉴런망과 뉴런의 연결세기, 확산과정을 나타내었다. 뉴런이 뉴런 자체의 감쇄 루프(decay loop)와, 바로 이웃한 뉴런들과 시냅스로 연결되어있고, 시냅스 연결세기의 합이 1이 된다고 하면, 그림 2(a)와 같이 간단한 형태의 연결망을 갖는 확산뉴런망이 구성된다. 이러한 뉴런망에 임펄스(impulse) 형태의 외부자극이 한 뉴런에 입력되면, 자극은 이웃 뉴런들에게로 확산되어 간다. 확산이 반복되면서 뉴런들의 반응도 분포는 이항분포가 되고, 더욱 더 반복되면 가우스 분포와 유사하게 된다. 그리고 이항분포함수는

$$f(x) = {}_n C_x p^x (1-p)^{n-x} \approx \frac{1}{\sqrt{2\pi np(1-p)}} \exp\left(\frac{(x-np)^2}{-2np(1-p)}\right) \quad (1)$$

이므로 분산은 $\sigma^2 = np(1-p)$ 가 되고, 확산에 의한 그림 2(c)와 같은 분포에서 분산은 다음과 같다.^[8]



(a)



(b)

$m = 0$		1			
$m = 1$		$\frac{1}{4}$	$\frac{2}{4}$	$\frac{1}{4}$	
$m = 2$		$\frac{1}{16}$	$\frac{4}{16}$	$\frac{6}{16}$	$\frac{4}{16}$
		$\frac{1}{16}$

(c)

그림 2. (a) 확산뉴런망 모델
 (b) 뉴런의 연결세기
 (c) 확산계수가 1/4일 때의 확산 과정의 예
 Fig 2. (a) A diffusion neural network model,
 (b) the interconnection weights
 of a neuron,
 (c) an example of the diffusing process
 with the diffusion coefficient of 1/4.

$$\sigma^2 = 2md, \tag{2}$$

여기서 m은 확산횟수이고 d는 확산계수이다. 또 뉴런들의 반응도 분포를 정규화시키려면, 시냅스 연결세기의 합이 1이 되어야 하므로,

$$2d + d_s = 1 \tag{3}$$

이 성립되어야 한다. 여기서 d_s 는 자체감쇄계수(self decay loop weight)이다. 물론 하나의 뉴런과 연결된 주변 뉴런들이 많을 경우에는 확산이 더 빠르게 진행되므로 더 큰 분산값을 갖게 된다.

III. 밝기변화추출

고등동물의 초기 시각작용은 신경생리학적 실험에 의하면 뉴런반응의 공간적 분포상태가 망막의 수용장에 넓게 분포된 억제영역과 폭이 좁게 분포된 흥분영역의 중첩된 작용으로, 두 영역의 형태가 가우스분포와 같다고 제시

되었다. [1, 2, 3, 5] 즉 뉴런의 전체적인 반응상태는 두 개의 가우스분포의 차와 같은 형태가 된다. 이를 그림 3에 도시하였다. 그림 3(a)에는 수용장의 중심에 인가된 자극에 의해 발생된 흥분영역에서의 반응을 실선으로, 억제영역에서의 반응을 점선으로, 각각 나타내었다. 그림 3(b)는 이 두 반응이 합쳐진 것을, 그림 3(c)는 그림 3(b)의 주파수 특성을 나타낸 것이다.




그림 3. 뉴런 수용장의 공간적 분포 및 응답특성
 (a) 흥분영역과 억제영역의 반응 분포
 (b) 두 반응의 합
 (c) 주파수 특성

Fig 3. The spatial organization and response of receptive fields.
 (a) an excitatory and an inhibitory response distribution,
 (b) summation of two responses,
 (c) a frequency response.

이러한 반응은 뉴런 수용장의 공간적 분포가, 서로 다른 표준편차를 갖는 두개의 가우스 분포함수의 차, 즉 DOG 분포와 같다. 그리고 DOG의 두 가우스 분포함수의 표준편차를 적절히 취하면, DOG는 가우스 분포함수를 2차 미분한 LOG와 유사하여 진다. [1, 5] 즉 흥분영역의 분산을 σ_e , 억제영역의 분산을 σ_i 라 할 때, $\sigma_e = \sigma, \sigma_i = \sigma + \delta\sigma$ 로 두고, $\delta\sigma \ll \sigma$ 라 가정하면, 흥분영역의 분포 $g_e(x, y)$, 억제영역의 분포 $g_i(x, y)$, 두 영역의 반응의 차이

DOG 함수는, 각각 다음과 같이 표현될 수 있다.

$$g_e(x, y) = \frac{1}{2\pi\sigma_e^2} \exp\left(\frac{x^2+y^2}{-2\sigma_e^2}\right) \quad (4)$$

$$g_i(x, y) = \frac{1}{2\pi\sigma_i^2} \exp\left(\frac{x^2+y^2}{-2\sigma_i^2}\right) \quad (5)$$

$$DOG = \frac{1}{2\pi(\sigma+\delta\sigma)^2} \exp\left(\frac{x^2+y^2}{-2(\sigma+\delta\sigma)^2}\right) - \frac{1}{2\pi\sigma^2} \exp\left(\frac{x^2+y^2}{-2\sigma^2}\right) \quad (6)$$

$$\simeq \delta\sigma \frac{\partial}{\partial\sigma} g(x, y, \sigma)$$

$$= \frac{\delta\sigma}{2\pi\sigma^3} \left(2 - \frac{x^2+y^2}{\sigma^2}\right) \exp\left(\frac{x^2+y^2}{-2\sigma^2}\right)$$

그리고 LOG 함수는

$$\nabla^2 g(x, y) = \frac{1}{2\pi\sigma^4} \left(2 - \frac{x^2+y^2}{\sigma^2}\right) \exp\left(\frac{x^2+y^2}{-2\sigma^2}\right) \quad (7)$$

이 되므로, 식 (6)의 DOG와 같은 모양이 된다. LOG 함수는 대역통과필터의 특성을 갖는다. 이것은 LOG 함수를 푸리에변환한 특성함수(characteristic function) $C(j\omega)$ 를 보면 잘 알 수 있다.

$$C(j\omega) = (\omega_x^2 + \omega_y^2) \exp\left(\frac{\sigma^2(\omega_x^2 + \omega_y^2)}{-2}\right) \quad (8)$$

그림 2의 구조를 갖는 확산뉴런망이 DOG의 기능을 갖기 위해서는 분산이 작은 흥분 확산뉴런망(excitatory diffusion neural network)과 분산이 큰 억제 확산뉴런망(inhibitory diffusion neural network)의 중첩으로 구성되어야 할 것이다. 흥분 확산 뉴런망과 억제 확산 뉴런망의 확산계수를 각각, d_e , d_i 라 하면, 두 확산뉴런망의 확산에 의한 분산은 각각,

$$\sigma_e^2 = 2md_e \quad (9)$$

$$\sigma_i^2 = 2md_i \quad (10)$$

이 되므로 분산비 σ_e^2/σ_i^2 는

$$\frac{\sigma_i^2}{\sigma_e^2} = \frac{d_i}{d_e} \quad (11)$$

와 같이 확산계수비(IEDR : inhibitory to excitatory diffusing ratio)로 표현된다. DOG나 LOG 함수에서 분산은 공간주파수와 밀접한 관계가 있으므로, [1, 5, 9] 식 (9) - (11)에서와 같이 확산계수 d_e , d_i 와 확산횟수 m 은 영상의 공간주파수와 밀접한 관계를 갖는다.

앞에서 나타난 함수들의 반응특성은 외부자극이 뉴런 수용장의 중심에 임펄스의 형태로 가해졌을 경우에 해당된다. 이제 외부자극이 임의의 형태로 가하여 졌을 때, 즉, 가장 간단한 예로 사각형 모양의 자극이 입력되었다고 하면, 이는 임펄스의 중첩된 형태로 볼 수 있으므로 그림 2(c)와 같은 확산과정이 중첩되어 일어나게 된다. 이러한 예를 그림 4에 나타내었다. 그림 4(a)는 흥분 확산 뉴런망의 반응을 그림 4(b)는 억제 확산 뉴런망의 반응을, 그림 4(c)는 두 반응의 차를 나타낸 것이다. LOG나 DOG는 식 (8)과 그림 3(c)와 같이 대역통과필터이다. LOG에서 대역통과 중심주파수 ω_0 를 식 (8)에서 구하여 보면^[9]

$$\omega_0 = \frac{2\pi}{T_n} = \frac{\sqrt{2}}{\sigma} \quad (12)$$

이 된다. 여기서 T_n 은 영상의 주기로서 화소 개수를 뜻한다. DOG에서는 분산비를 적절히 취해줌에 따라 LOG와 유사하게 되므로, DOG의 σ_e 와 LOG의 σ 가 같다고 하면 식 (2)와 (12)로부터

$$\sigma_e = \sqrt{2md_e} = \sqrt{2T_n}/2\pi \quad (13)$$

이 유도된다. 따라서 확산계수 d_e 와 확산횟수 m 에 해당하는 영상의 주기 T_n 은

$$T_n = 2\pi \sqrt{md_e} \quad (14)$$

이 된다.

확산뉴런망의 반응결과 그림 4(c)와 같이 외부자극의 세기변화가 있는 부분에 양에서 음으로 또는 음에서 양으로 반응값이 변하는 제로크로싱(zero-crossing)이 발생된다. 외부자극의 세기변화에 의해 생기는 윤곽선을 추출하기 위해서는 제로크로싱이 있는 점들을 찾아내어 이를 연결시켜 그 궤적을 구하면 된다. Oyster 등^[4]은 제로크로싱을 뉴런망으로 검출하기 위해 AND 논리연산을 하였고, Huertas와 Medioni^[6]는 그 궤적을 중시하여 24가지의 대표적인 윤곽선 패턴을 마련하고 그것과의 패턴 정합으로 검출하였다. 본 논문에서는 단순히 공간적으로 화소의 값이 양에서 음으로 또는 음에서 양으로 연이어 위치하면 그 위치에 외부자극의 세기변화가 있는 윤곽선으로 보았다.

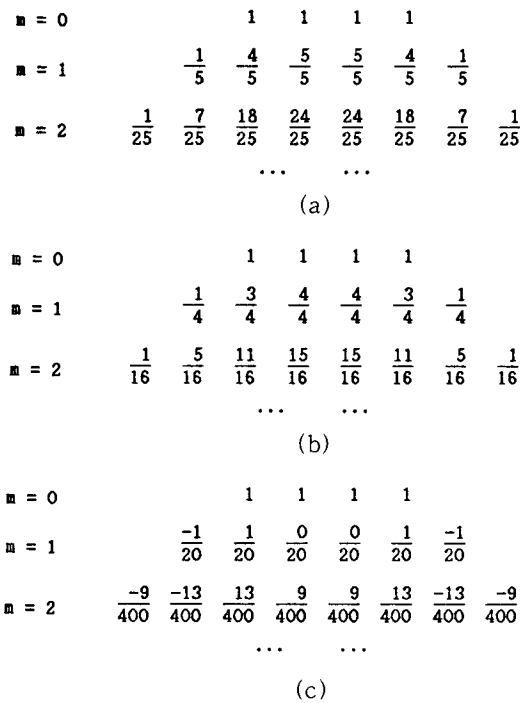


그림 4. 외부자극에 대한 확산뉴런망의 반응의 예
 (a) 확산계수가 1/5인 흥분 확산뉴런망의 반응
 (b) 확산계수가 1/4인 억제 확산뉴런망의 반응
 (c) 두 반응의 차
 Fig 4. An example of the responses of diffusion neural networks to external excitation.
 (a) the response of an excitatory diffusion neural network with the diffusion coefficient of 1/5,
 (b) the response of an inhibitory one with that of 1/4,
 (c) the difference of two responses.

IV. 성능분석 및 결과고찰

확산뉴런망에 의한 반응은 LOG와 마찬가지로 대역통과의 특성을 갖는다. 확산에 의한 DOG 분포에서 확산계수나, 확산계수비, 또 확산횟수에 대한 공간주파수와 의 관계를 알아보려면 LOG와 비교하면 된다. 즉, 확산계수와 확산횟수는 가우스함수의 표준편차에 관계되며, 확산계수비는 같은 표준편차를 갖는 DOG와 LOG의 유사성에 관계된다. 이러한 관계를 정량적으로 구해보면 다음과 같다.

먼저 표준편차 σ 를 갖는 LOG를 계산하고, 이와 표준편차가 같은 흥분 확산분포와 이보다 조금 큰 표준편차를 갖는 억제 확산분포를 구한다. 그 다음에 두 확산에 의한

분포의 차를 계산하고 그 중심피크치가 LOG와 같도록 계수를 조정 한 후, LOG와의 평균자승오차를 계산한다. 그리고 억제 확산분포의 표준편차를 변화시켜 가장 최소의 평균자승오차를 갖는 확산에 의한 DOG를 구한다. 이때의 각 파라미터를 표1에 나타내었다. 즉, 표 1은 흥분 확산분포의 확산계수 d_e 를 고정시키고 LOG와 가장 유사할 때의 확산계수비를 나타낸 것이다. 이 결과에서와 같이 확산계수비는 확산계수와 확산횟수에 따라 조금씩 다르나 1에 가까워야 LOG와 유사하게 된다. 이것은 식(6)에서 $\delta\sigma \ll \sigma$ 로 가정 한 것과 같이, $d_i \approx d_e$ 인 경우에 확산에 의한 DOG가 LOG와 가장 유사함을 뜻한다. 그림 5는 d_e 가 0.25, m 이 16, 확산계수비가 1.004일 때의 확산에 의한 DOG와, $\sigma^2=8$ 인 LOG 함수를 1차원적으로 그래프

표 1. 흥분 확산계수 d_e 를 고정하였을 경우, 확산에 의한 DOG가 LOG와 가장 유사해질 때의 확산횟수에 따른 확산계수비

Table 1. The number of diffusion iterations vs the IEDR when the DOG by diffusion with fixed d_e is most similar to a LOG.

확산 횟수	LOG와 가장 유사할 때의 확산계수비(IEDR= d_i/d_e)와 분산(σ^2)					
	1 dimension, $d_e=0.25$		2 dimension, $d_e=0.125$		2 dimension, $d_e=0.167$	
	IEDR	σ^2	IEDR	σ^2	IEDR	σ^2
2	-	1.0	1.001	0.5	1.001	0.67
4	1.001	2.0	1.287	1.0	1.001	1.33
8	1.005	4.0	1.187	2.0	1.025	2.67
12	1.005	6.0	1.107	3.0	1.015	4.00
16	1.004	8.0	1.074	4.0	1.010	5.33
24	1.003	12.0	1.046	6.0	1.006	8.00
32	1.002	16.0	1.033	8.0	1.004	10.67




그림 5. 확산에 의한 DOG ($d_e=0.25, m=16, d_i/d_e=1.004$)와 LOG ($\sigma^2=8$)의 비교
 Fig 5. Comparison of a DOG by diffusion ($d_e=0.25, m=16, d_i/d_e=1.004$) with a LOG ($\sigma^2=8$).

에 나타난 것이다. 여기서도 상대적 비교를 위해 그 중심 피크치를 일치시켰다. LOG와 일치하는 확산계수비는 확산횟수에 따라 조금 달라지나, LOG와 일치하여야 대역통과필터로서의 특성이 강한 것은 아니며, 확산을 거듭 하면서 확산계수를 변화시키는 것은 사실상 불가능한 작업이므로, 확산계수를 고정시키고 구하고자 하는 윤곽선의 주기에 맞도록 확산횟수를 조절하여 윤곽선을 검출하는 것이 타당할 것이다. 따라서 본 논문에서는 확산횟수나 확산계수에 관계없이 확산계수비를 1.02로 고정시켜 사용하였다.

LOG 함수를 이용한 윤곽선의 검출은 계산된 LOG 마스크와 입력영상과의 컨볼루션으로 이루어지므로, 영상의 크기가 $N \times N$ 이고, LOG 마스크의 크기를 M 이라 하면, 총 곱셈의 계산량은 M^2N^2 이 된다. 여기서 분산 σ^2 에 관련된 공간주파수를 검출한다고 하면 LOG 마스크의 크기 M 은

$$M = 6\sqrt{2} \sigma \tag{15}$$

이 되면 충분하므로,^[6,9] 총 계산량 Q 는

$$Q = M^2N^2 = 72\sigma^2N^2 \tag{16}$$

이 된다.

같은 영상에 대해 확산뉴런망으로 처리하면, 1회 확산에서의 계산횟수가 흥분뉴런인 경우 5회, 억제뉴런인 경우 5회로 합 10회이며, 분산이 σ^2 일 때 확산횟수 m 은 식 (2)나 (13)에 의해

$$m = \frac{\sigma^2}{2d} \tag{17}$$

이 되므로 총 곱셈의 계산량 Q 는

$$Q = 10mN^2 = \frac{5}{d} \sigma^2N^2 \tag{18}$$

이 된다. 2차원에서 확산계수 d 는 식 (3)에 따라 $4d$ 가 1보다 작아야 하므로 $1/6$ 이면 적합하다.

그리고 LOG나 확산에 의한 DOG, 모두 행과 열로 서로 대칭이므로 행열을 각각 분리하여 처리할 수 있다.^[6] 분리하여 처리할 경우, 1차원적으로 2회 처리되어야 하므로 확산계수 d 를 $1/4$ 로 하면 총 곱셈의 계산량 Q 는

$$Q = 12mN^2 = \frac{6}{d} \sigma^2N^2 = 24\sigma^2N^2 \tag{19}$$

이 된다. 이들 처리방식에 대한 계산량을 비교하면 표 2와 같다.

표 2. 확산뉴런망과 LOG간의 영상처리 곱셈 계산량 비교

Table 2. Comparison of a diffusion neural network with a LOG in the number of multiplications.

확산뉴런망		LOG	비 고
확산계수	계산량	계산량	
$d=0.125$	$40\sigma^2N^2$	$72\sigma^2N^2$	56%
$d=0.167$	$30\sigma^2N^2$	$72\sigma^2N^2$	42%
$d=0.250$	$24\sigma^2N^2$	$72\sigma^2N^2$	33%

그리고 확산뉴런망을 이용하면, 확산계수를 LOG와 같이 함수계산에 의존하지 않아도 된다. 또한 고정된 값으로 계속 확산하면서, 확산을 1회 반복할 때마다 공간주파수가 서로 다른 의미있는 중간결과를 구할 수 있으므로, 일련의 처리과정으로 각 공간주파수에 대한 윤곽선 검출결과를 한꺼번에 얻을 수 있어 종합적인 결과를 도출할 수 있다.

본 논문에서는 확산뉴런망을 이용하여 2차원적인 영상의 윤곽선을 검출하는 시뮬레이션을 하였다. 검출절차는 그림 6과 같이 먼저 외부자극에 대한 흥분 확산뉴런망의 반응과 억제 확산뉴런망의 반응을 각각 얻어 두 뉴런망의 반응을 뺀다. 결과는 그림 4와 같은 형태로 DOG 연산결과에 해당되므로 여기에서 제로크로싱을 검출하면 윤곽선을 얻을 수 있다.





그림 6. 윤곽선 검출절차
Fig 6. Procedure of edge detection.

본 시뮬레이션에서는 뉴런망의 크기를 64×64 로 하고, 외부자극인 입력영상으로는 링컨초상화를 사용하였다. 입력영상은 그림 7에, 윤곽선 검출결과는 그림 8에 나타내었다. 그림 8(a)는 확산횟수 $m=3$ 일 때(분산 $\sigma^2=1$), (b)는 $m=6$ 일 때(분산 $\sigma^2=2$), 흥분 확산계수 d_e 가 0.167, 확산계수비가 1.02인 확산뉴런망의 반응결과에서



그림 7. 입력으로 사용한 64×64 크기의 링컨초상화
Fig. 7. Lincoln picture as an input image with 64×64.




(a) (b)

그림 9. LOG 함수를 이용한 링컨초상화의 윤곽선 검출결과

- (a) $\sigma^2=1$
- (b) $\sigma^2=2$ 일 때

Fig. 9. The results of edge detection of Lincoln picture by LOG masking, when, (a) $\sigma^2=1$, (b) $\sigma^2=2$.



(a) (b)

그림 8. 확산계수가 0.167인 확산뉴런망을 이용한 링컨초상화의 윤곽선 검출결과
(a) $m=3$
(b) $m=6$ 일 때

Fig. 8. The results of edge detection of Lincoln picture by the diffusion neural network with the diffusion coefficient of 0.167, when, (a) $m=3$, (b) $m=6$.

제로크로싱을 검출한 것이다. 제로크로싱의 검출에는 그림 1(b)에서의 이진화함수를 갖는 뉴런망 모델을 사용하여 상하좌우 4방향에 대해, 양에서 음으로 또는 음에서 양으로의 변화에 반응을 갖도록 하였다. 이 결과를 LOG 연산과 비교하기 위해, 분산 σ^2 이 각각 1, 2일 때의 LOG 연산후 제로크로싱을 검출한 결과를 그림 9에 나타내었다.

그림 8과 9의 두 결과에서와 같이 LOG나 확산뉴런망

의 처리로 거의 같은 공간주파수의 밝기변화를 추출할 수 있음을 알 수 있다. 그러나 LOG 연산 결과인 그림 9와 비교하면 목적물의 윤곽선은 거의 비슷하나, 배경에서는 검출된 윤곽선이 다르다. 이것은 배경에 있는 아주 작은 밝기변화가 검출된 것이다. 제로크로싱의 검출에 적절한 임계치를 설정하고 정형화된 패턴만을 검출하는 알고리즘^[6]을 적용하여 배경의 잡음을 제거하여야 할 것이다.

이 결과에서와 같이 확산횟수가 늘어날수록, 또 확산 계수가 커질수록 추출할 수 있는 입력영상의 밝기변화의 공간주파수는 낮아짐을 알 수 있다. 즉, 확산횟수가 적을 때에는 윤곽선의 간격이 좁으나, 확산이 거듭됨에 따라 높은 공간주파수를 갖는 윤곽선은 제거되고 낮은 공간주파수를 갖는 윤곽선들이 검출된다. 그리고 다른 값의 확산계수를 사용하여도 식 (2)에 따라 분산값이 같도록 확산횟수를 조정하면 같은 결과를 얻을 수 있다. 또한 그림 8의 (a)와 (b)는 연속된 일련의 확산과정에서 얻은 결과이며, 그림 9의 (a)와 (b)는 각각 별도의 LOG 마스크를 구하여 얻은 것이다.

V. 결 론

본 논문에서는 뉴런망의 신호전달을 확산의 형태로 해석하여 DOG 연산을 할 수 있도록 구성하였으며 입력영상의 밝기변화를 윤곽선으로 검출하였다. 이러한 확산방법으로 윤곽선을 검출하면 뉴런망에서 하나의 뉴런에 연결되는 시냅스는 2차원적으로 4개에 불과하므로 빠른 연산이 가능하였으며, 낮은 공간주파수의 반응을 얻고자 할

때에는 확산계수를 조절하여 빠른 확산이 일어나도록 하여 처리속도를 조금 더 높일 수 있었다. 이 때 시냅스의 연결세기 값도 함수계산에 의존하지 않고 단순값을 부여하였다. 그리고 연속된 일련의 확산과정을 거치면서 얻는 반응들을 종합하여 각 공간주파수에 대한 종합적인 결과를 얻을 수 있었다. 또한 시냅스가 임의의 연결세기로 되어있고 원하는 공간주파수의 율박선을 얻고자 할 때에는, 시냅스의 연결세기인 확산계수와 확산횟수가 서로 보완 관계에 있으므로 확산횟수만 적절히 조절해 주면 된다.

参 考 文 獻

[1] D. Marr, *Vision. A Computational Investigation into the Human Representation and Processing of Visual Information*, Freeman, San Francisco, 1982.

[2] M. D. Levine, *Vision in Man and Machine*, McGraw-Hill, New York, 1985.

[3] O. J. Braddick and A. C. Sleigh, *Physical and biological processing of images*, Spring-Verlag, Berlin, 1983.

[4] J. M. Oyster, F. Vicuna, and W. Broadwell,

“Associative network applications to low-level machine vision,” *Applied Optics*, vol. 26, no. 10, pp. 1919-1926, May 1987.

[5] D. Marr and E. C. Hildreth, “Theory of edge detection,” *Proc. R. Soc. London B207*, pp. 187-217, 1980.

[6] A. Huertas and G. Medioni, “Detection of intensity changes with subpixel accuracy using Laplacian-Gaussian mask,” *IEEE Trans. on Tat. Anal. and Machine Intel.*, vol. PAMI-8, no. 5, pp. 651-664, Sep. 1986.

[7] J. S. Chen, A. Huertas, and G. Medioni, “Fast convolution with Laplacian of Gaussian masks,” *IEEE Trans. on pattern analysis and machine intelligence*, vol. PAMI-9, no. 4, pp. 584-590, July 1987.

[8] 권율, 남기곤, 윤태훈, 김재창, “확산뉴런망을 이용한 영상처리,” 전자공학회 논문집, 1992(심사중).

[9] 이우형, 권율, 김재창, 박의열, “ $\nabla^2 G$ 연산자를 이용한 임의의 공간주파수의 밝기변화 추출,” 87년도 전기 전자공학 학술대회 논문집, 포항공대, pp. 1364-1366, 1987.

著 者 紹 介



權 栗 (正會員)

1955年 8月 7日生. 1978年 2月 서강대학교 전자공학과 졸업. 1985年 2月 부산대학교 대학원 전자공학과 석사학위 취득. 1992年 8月 동대학원 박사과정 수료. 1978年 3月~1983年 2月 국방과학연구소 근무. 1984年 3月~1988年 8月 동의공업전문대학 전임강사. 현재 삼우실업 연구소 근무. 주관심분야는 신경회로망, 영상처리 등임.

尹 台 焄 (正會員)

第29卷 A編 第2號 參照
현재 부산대학교 전자공학과
조교수.

金 在 昌 (正會員)

第29卷 A編 第2號 參照
현재 부산대학교 전자공학과
교수

南 基 坤 (正會員) 第29卷 B編 第10號 參照

현재 부산대학교 전자공학과
조교수