

확산뉴런망을 이용한 영상처리

(Image Processing by a Diffusion Neural Network)

權 栗*, 南基坤*, 尹台焘*, 金在昌*

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

要約

임펄스 형태의 자극이 확산되면 가우스분포가 형성된다. 본 논문에서는 확산방정식에서 확산뉴런망 모델을 유도한다. 그리고 두 가우스함수의 차(DOG)가 가우스함수를 2차 미분한 함수(LOG)와 같은 모양임을 보인다. 또한 입력된 자극을 확산함으로써 DOG 콘볼루션을 실행할 수 있는 뉴런망모델을 제시한다. 그리고 제시된 모델로 영상에서 밝기변화를 검출할 수 있음을 보인다. 이 모델에서 각 뉴런은 단지 네 개의 고정된 값을 갖는 시냅스만을 갖기 때문에 하드웨어로 실현할 때 매우 효과적이라 할 수 있다.

Abstract

A Gaussian is formed by diffusing a spot excitation. In this paper, a diffusion neural network model is derived from the diffusion equation. And it is shown that a difference of two Gaussians(DOG) may have the same shape as a Laplacian of a Gaussian(LOG). A neural network model executing a DOG convolution by diffusing an external excitation is proposed. By this model intensity changes of image may be detected. This model may be implemented economically because each neuron has only four fixed-valued synapses.

1. 서론

최근 관심이 고조되고 있는 신경회로망에 관한 연구는 영상처리 분야에도 다양하게 적용되어 왔다. 특히 동물의 시각처리 능력을 파악하고 이를 인공적으로 실현하고자 하는데 많은 노력을 기울이고 있다.^[1,2] 동물의 시각처리 능력에 관한 연구는 Hartline^[3] 과 Kuffler^[4]에 의해 개구리와 고양이의 눈의 기능을 밝혀내는데서 시작되었다. 그 후 Rodieck과 Stone,^[5] 그리고 Enroth-Cugell과 Robson^[6]은 빛에 대한 눈의 반응이 공간적으로 폭이 좁은 가우스분포 모

양의 자극반응과 폭이 넓은 가우스분포의 억제반응의 중첩으로 이루어졌음을 밝혀내었다.

눈의 시각처리 기능이 두 가우스함수의 차(DOG: difference of two Gaussians)로 밝혀짐에 따라, Marr와 Hildreth^[7]는 가우스함수를 2차 미분한 함수(LOG: Laplacian of a Gaussian)가 DOG와 유사한 모양을 가지며, 영상의 밝기변화의 검출에 적용될 수 있음을 보였다. LOG를 이용한 영상처리에는 계산량이 많다는 단점이 있다. 이러한 점을 보완하여 LOG연산의 계산량을 줄이는 알고리즘도 제시되었다.^[8,9]

그리고 Oyster 등^[10]은 LOG연산을 뉴런망에 적용하였다. 또한 권 울 등^[11]은 망막에서의 신호전달 형태를 자극의 확산으로 보고, 자극을 확산시켜 가우스분포가 되도록 하는 두 개의 확산뉴런망을 구성하

*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 10月 10日

였으며, 두 뉴런망의 반응의 차를 구하여 영상의 밝기변화를 검출하였다.

본 논문에서는 입력자극의 확산으로 가우스분포의 반응을 갖는 확산뉴런망 모델을 유도한다. 그리고 DOG가 LOG와 같은 모양을 가질 때의 조건과 확산의 선형성을 이용하여, 하나의 확산뉴런망으로 분포도가 다른 두 가우스분포의 중첩을 구하는 모델을 제시한다. 이로서 연산량이 적어지고, 연산의 속도도 빨라질 수 있음을 보인다. 또한 이 모델은 연결이 적고, 고정된 연결세기로 연결되므로 하드웨어의 실현에 매우 효과적이라 할 수 있다.

II. 확산 뉴런 망 모델

눈으로 입사된 빛은 광수용기에서 전기적인 자극으로 변환된 다음 망막의 안 쪽으로 전달되어 가는데, 이 때 자극은 주변으로도 확산되어 간다. 일반적으로 자극이 주변으로 확산되면 가우스함수 모양을 이룬다. 이러한 예를 그림 1(a)에 나타내었다. 이 그림은 한 뉴런에 "1"의 자극이 인가되었을 때 인접한 다른 뉴런들에게로 자극의 1/4이 전달되고 자신은 반으로 감쇄되는 반응을 보인 것이다. 확산이 계속되면 가우스분포에 근접하게 된다. 이것은 이항분포와 같다. 이와 같은 확산은 뉴런망의 기본적인 동작으로 볼 수 있으며 그림 1(b)와 같이 간단하게 연결된 뉴런망에서 수행될 수 있다.

그림 1(b)와 같은 확산뉴런망 모델은 열전달을 표현한 다음과 같은 확산방정식¹¹³⁾에서도 유도될 수 있다.

$$\nabla^2 v = \frac{1}{\alpha} \frac{\partial v}{\partial t} \tag{1}$$


여기서는 2차원의 영상에 적용하고자 하기 때문에 v 는 x, y, t 의 함수이며, α 는 확산계수(diffusivity)를 나타낸다. 이 방정식은 높은 준위의 영역에서 낮은 준위로 에너지가 확산되어 가는 것을 표현한 것으로써 Fourier의 열전달법칙(Fourier's law of heat conduction)¹¹³⁾에서 유도될 수 있다. 식 (1)의 2차원 편미분 방정식의 해¹¹⁵⁾는

$$v(x, y, t) = \frac{1}{4\pi\alpha t} \int_{-\infty}^{\infty} v_0(\eta, \xi) \exp\left[\frac{(x-\eta)^2 + (y-\xi)^2}{-4\alpha t}\right] d\eta d\xi \tag{2}$$

이다. 여기에서 $v_0(\eta, \xi)$ 는 $v(x, y, t)$ 의 $t=0$ 일 때의 초기값이므로서 $v_0(\eta, \xi) = v(x, y, t)|_{x=\eta, y=\xi, t=0}$ 이다. $v(x, y, t)$ 의 초기값이 임펄스일 때, 즉 $v(x, y, 0) = \delta(x, y)$

step	responses
n = 0	1
n = 1	$\frac{1}{4} \frac{2}{4} \frac{1}{4}$
n = 2	$\frac{1}{16} \frac{4}{16} \frac{6}{16} \frac{4}{16} \frac{1}{16}$
n = 3	$\frac{1}{64} \frac{6}{64} \frac{15}{64} \frac{20}{64} \frac{15}{64} \frac{6}{64} \frac{1}{64}$

(a)



(b)

그림 1. 확산의 예와 확산뉴런망 모델

(a) 스폿 자극에 대한 확산뉴런망의 반응의 예(확산 계수 1/4, 자체 감쇄계수 1/2, 확산횟수 n)

(b) 1차원적인 확산뉴런망 모델

Fig. 1. An example of diffusion and a diffusion neural network model.

(a) An example of the responses to a spot excitation(a diffusivity $\alpha=1/4$, a self decay coefficient 1/2, the number of diffusion iterations n),

(b) an one-dimensional diffusion neural network model.

$$v(x, y, t) = \frac{1}{4\pi\alpha t} \int_{-\infty}^{\infty} v_0(\eta, \xi) \exp\left[\frac{x^2 + y^2}{-4\alpha t}\right] \tag{3}$$

일 때의 해¹¹⁵⁾는 으로 주어진다. 식 (3)은 분산 $\sigma^2=2\alpha t$ 인 가우스함수이다.

본 논문에서는 확산방정식에서 이산적인 해(discrete solution)을 구하고 이를 뉴런망에 적용하여 확산뉴런망 모델을 구하고자 한다. 이를 위해 먼저 확산방정식 (1)을 라플라스 변환하고, 그 결과를 z 변환의 평면상으로 사상(mapping)한다. 그 다음 역 z 변환하면 이산적인 해를 구할 수 있다.

그러면 먼저 식 (1)의 라플라스 변환을 구하여 본다. 이 때 x 나 y 에 대해서는 그 범위가 $-\infty$ 에서 $+\infty$ 이므로 two-sided transform을 취하고, t 에 대해서는 그 범위가 0에서 $+\infty$ 이므로 one-sided transform을 취한다¹¹⁴⁾ 그 결과는

$$(s_x^2 + s_y^2)V = \frac{1}{\alpha}(s_z V - V_0) \tag{4}$$

이므로 확산방정식의 라플라스 변환형의 해는

$$V = \frac{V_0}{s_z - \alpha(s_x^2 + s_y^2)} \tag{5}$$

이 된다. 여기서 $V = \mathcal{L}\{v(x, y, t)\} = V(s_x, s_y, s_z)$ 이고, V_0 는 $t=0$ 일 때의 초기값 $V_0(x, y)$ 의 라플라스 변환형 $V_0 = \mathcal{L}\{v_0(x, y)\} = V_0(s_x, s_y)$ 이다.

이제 s 평면상에 표현된 식 (5)를 z 평면상으로 사상한다. S_x 와 S_y 는 two-sided transform으로 표현된 것이므로 사상함수(mapping function)^[16]는 각각

$$s_x^2 = (1 - z_k^{-1})(z_k - 1) \tag{6}$$

$$s_y^2 = (1 - z_m^{-1})(z_m - 1) \tag{7}$$

이 된다. 여기에서 Z_k 는 S_x 에서 사상된 변수이며 Z_m 은 S_y 에서 사상된 변수이다. 또 S_z 는 one-sided transform으로 표현되었으므로 그 사상함수는

$$s_z = z_n - 1 \tag{8}$$

을 사용한다. 여기에서 Z_n 은 S_z 에서 사상된 변수이다. 식 (8)과 같이 forward difference를 사용한 이유는 현재의 확산된 결과를 다음 스텝에서 입력으로 사용하기 때문이다. S_x, S_y, S_z 의 각 변수에 대한 사상함수인 식 (6), (7), (8)을 확산방정식 (5)에 대입하여 z 변환형으로 나타내면 다음과 같다.

$$V(z_k, z_m, z_n) = \frac{V_0}{z_n - 1 - \alpha(z_k^{-2} - 2 + z_k^{-1} + z_m^{-2} - 2 + z_m^{-1})} \tag{9}$$

위의 식 (9)를 역 z 변환하면 우리는 다음과 같은 이산적인 확산방정식의 해를 얻을 수 있다.

$$v(k, m, n+1) = \alpha v(k+1, m, n) + \alpha v(k-1, m, n) + \alpha v(k, m+1, n) + \alpha v(k, m-1, n) + (1-4\alpha)v(k, m, n) + v_0(k, m)\delta(n), \tag{10}$$

여기에서 다섯번째 항의 계수인 $(1-4\alpha)$ 는 정규화된 자체 감쇄계수이고 여섯번째 항인 $V_0(k, m)\delta(n)$ 은 초기값을 뜻한다. 초기값이 공간적으로 임펄스일 때 이 식의 계산 결과는 다음의 분산값

$$\sigma^2 = 2\alpha n \tag{11}$$

을 가지는 가우스함수가 된다.

임의의 영상을 초기값으로 하여, 식 (10)에 따라 확산하면, 입력된 영상과 가우스함수와의 콘볼루션(convolution)을 얻을 수 있다. 식 (10)을 뉴런망에 적용하면 임의의 입력을 가우스함수와 콘볼루션하는 확산뉴런망을 만들 수 있다. 1차원적인 확산뉴런망을 구성하면 앞에서 제시한 그림 1(b)와 같은 모델이 되고, 이산적인 1차원 확산방정식의 해는

$$v(m, n+1) = \alpha v(m-1, n) + \alpha v(m+1, n) + (1-2\alpha)v(m, n) + v_0(m)\delta(n) \tag{12}$$

이 된다. 이 모델에서 각 뉴런은 그림 1(b)에 표현한 것과 같이 바로 인접한 두개의 뉴런들과 연결세기 α 인 시냅스(synapse)를 갖고, 자체적으로는 $(1-2\alpha)$ 의 크기인 감쇄루프를 갖는다. 이와 같이 3개의 연결만으로 확산이 가능하나, 입력통로와 출력통로를 추가한다. 영상처리를 위한 2차원적인 확산뉴런망에서 각 뉴런은 확산을 위한 시냅스 4개를 갖는다.

이 모델의 한 뉴런에 임펄스가 가해지면 그 자극은 시냅스를 통해 주변의 뉴런들에게로 전달되고 자극을 받은 뉴런의 반응은 지수적으로 감쇄되어 간다. 확산이 계속되면 뉴런망의 전체적인 반응은 가우스분포를 이룬다. n 번 확산되었을 때 가우스분포의 분산 σ^2 은 $2\alpha n$ 이 된다.

이 모델을 이용하여, 입력영상과 분산 $2\alpha n$ 인 가우스함수와의 콘볼루션을 구하고자 할 때 n 번 확산하는 과정에서, 1번 확산된 결과와 2번 확산된 결과 등, $(n-1)$ 번 확산된 결과를 중간과정으로 얻을 수 있다. 따라서 다른 크기의 분산을 가지는 가우스함수와의 콘볼루션을 얻고자 할 때에는 식 (11)의 분산 $2\alpha n$ 에서 확산계수를 변화시키지 않고 n 만 변화시키는 것이 효과적이라 할 수 있다. 그러나 더 중요한 것은 고정된 확산계수를 사용하면, 하드웨어로 구현할 때 고정된 값의 연결세기로 연결하는 것이 가능하며 연결갯수도 매우 적으므로 대단히 경제적이라는 것이다.

빠른 연산이 요구될 때에는 뉴런들간의 시냅스 연결을 더 늘여 빠른 확산이 일어나도록 할 수 있다. 그러나 하드웨어로 구현할 때에는 그만큼 연결갯수가 늘어나므로 비효율적이라 할 수 있다.

III. 영상의 밝기변화 검출 모델

1. DOG

고등동물 눈의 세포반응에 관한 신경생리학적 실험에 의하면, 임펄스에 대한 반응이 공간적으로 망막의

수용장에 넓게 분포된 억제반응과 폭이 좁게 분포된 자극반응의 중첩으로, 두 반응의 형태가 가우스함수와 같다고 제시되었다.^[5,6] 즉, 뉴런 수용장의 공간적 분포가, 서로 다른 표준편차를 갖는 두개의 가우스분포함수의 차, 즉 DOG와 같다. 그리고 DOG의 두 가우스함수중에서 자극가우스함수가 억제가우스함수보다 분산이 작다.

DOG의 두 가우스분포함수의 표준편차를 적절히 취하면, DOG는 가우스분포함수를 2차 미분한 LOG와 유사하여진다.^[2,11] Marr와 Hildreth^[7]는 두 가우스함수의 표준편차가 1:1.6의 비율일 때 LOG와 가장 근사하게 된다고 하였다. 그리고 LOG가 대역통과 필터의 특성을 가지므로, 그들은 LOG를 공간주파수 추출기(spatial frequency extractor)로서 이용하여 영상에서의 윤곽선을 검출하였다.

그리고 권율 등^[11,12]은 자극반응의 가우스분포의 표준편차를 σ 라 놓고 억제반응의 가우스분포의 표준편차를 $\sigma + \Delta\sigma$ 라 놓으며, $\Delta\sigma \ll \sigma$ 라 가정하여, 다음과 같이 σ 에 관한 미분의 형태로 DOG를 표현하였다.

$$\begin{aligned} \text{DOG} &= g(x, y, \sigma) - g(x, y, \sigma + \Delta\sigma) \\ &= -\Delta\sigma \frac{\partial}{\partial \sigma} g(x, y, \sigma) \\ &= \frac{\Delta\sigma}{2\pi\sigma^3} \left(2 - \frac{x^2 + y^2}{\sigma^2} \right) \exp\left(-\frac{x^2 + y^2}{2\sigma^2} \right) \end{aligned} \quad (13)$$

또한 식 (13)의 DOG가 다음의 LOG

$$\nabla^2 g(x, y) = \frac{-1}{2\pi\sigma^4} \left(2 - \frac{x^2 + y^2}{\sigma^2} \right) \exp\left(-\frac{x^2 + y^2}{2\sigma^2} \right) \quad (14)$$

와 같은 모양이 됨을 보였다.

이 조건 $\Delta\sigma \ll \sigma$ 에 의하면 두 가우스함수의 분산비 (IEVR: the inhibitory to excitatory variance ratio),

$$\text{IEVR} = \frac{\sigma_i^2}{\sigma_e^2} = \frac{(\sigma + \Delta\sigma)^2}{\sigma^2} \quad (15)$$

이 1보다 조금 더 큰 값을 가져야 할 것이다. 여기서 첨자 'i'는 억제(inhibitory)를 'e'는 자극(excitatory)을 뜻한다.

2. DOG의 초기값을 확산하는 뉴런망 모델

DOG를 구성하는 두 가우스함수를 모두 확산뉴런망에서 만든다고 하면, 자극가우스함수의 분산은 $2\alpha n_e$ 이 되고 억제가우스함수의 분산은 $2\alpha n_i$ 가 된다. 따라서 분산비는 $2\alpha n_i / 2\alpha n_e$ 이 된다. 여기서 두 확산뉴런망의 파라미터인 변수 α 와 n 을 모두 변화시키면

모델의 구성과 운용이 복잡하여지기 때문에 비효율적이다. 따라서 권 율 등^[11]은 연결세기 α 와 α_i 를 갖는 두 확산뉴런망을 구성하고, 확산횟수 n 은 서로 같도록 운용하여 영상의 밝기변화 검출에 적용하였다.

본 논문에서는 같은 값의 α 와 α_i 를 사용하여, 하나의 확산뉴런망을 구성하고, 확산횟수 n 을 조절하여 분산이 다른 두 가우스분포를 구한다. 따라서 이 모델에서의 분산비는 n_i/n_e 이 된다. 또 DOG가 LOG와 같은 모양을 갖기 위해서는 $\Delta\sigma \ll \sigma$ 인 조건이 만족되어야 하고, 분산비가 1에 가까운 값을 가지고 $n_i > n_e$ 가 되려면, $n_i = (n+1)$, $n_e = n$ 이 되어야 할 것이다. 따라서 이 모델의 분산비는

$$\text{IEVR} = \frac{2(n+1)\alpha}{2n\alpha} = \frac{n+1}{n} \quad (16)$$

이 되며, n 이 클 때 분산비는 1에 가까운 값이 된다. 즉, 억제반응은 자극반응에서 한번 더 확산되어 분산이 조금 더 큰 가우스분포가 된다.

확산은 선형(linear) 연산이다. 임의의 입력을 확산하여 가우스함수와의 콘볼루션을 얻을 수 있는 것도 선형성을 이용한 것이다. 입력에 대한 자극반응과 억제반응의 중첩을 확산하면 그 결과는 각각의 값을 별도로 확산하여 중첩한 것과 같다. 따라서 이 모델에는 하나의 확산뉴런망이 구성되고, 이 뉴런망의 입력으로는 DOG의 초기값이 사용된다. 즉, 이 모델은 DOG의 초기값을 확산하는 뉴런망 모델이다.


이 모델에서는 자극가우스분포의 초기값으로는 $n=0$ 인 때의 반응을 취하고, 억제가우스분포의 초기값으로는 $n=1$ 일 때의 반응을 취한다. 3개의 뉴런으로 구성된 1차원적인 뉴런망에서, 가운데 뉴런이 자극을 받았다고 하면, 자극가우스분포의 초기값은 $(0, 1, 0)$ 이 되고, 억제가우스분포의 초기값은 $(-\alpha, -1+2\alpha, -\alpha)$ 가 된다. 따라서 DOG의 초기값은 $(-\alpha, 2\alpha, -\alpha)$ 가 된다.

이 모델은 입력이 있을 때 확산뉴런망에서 DOG의 초기값인 $(-\alpha, 2\alpha, -\alpha)$ 를 확산시키는 시스템이 된다. 확산계수가 1/4인 모델에 임펄스의 입력이 가해졌을 때, 이 모델의 반응도 분포의 예를 그림 2(b)에 나타내었고, 이러한 처리를 실행하는 이 모델의 1차원적인 구조를 그림 2(a)에 나타내었다. 이 모델 구성중 분배층(distribution layer)은 자극에 대한 DOG의 초기값 $(-\alpha, 2\alpha, -\alpha)$ 를 확산층(diffusion layer)에 인가하기 위한 것이다. 따라서 분배층의 각 뉴런은 확산층의 바로 마주 대하는 뉴런과는 자극의 2α 배가 전달되도록 연결되어 그 반응을 자극시키고, 확산층의 바로 양 옆으로 대하는 뉴런과는 자극의 $-\alpha$ 배가 전달

되도록 연결되어 그 반응을 억제시킨다. 확산층은 앞에서 제시한 확산뉴런망으로서 중첩된 입력을 확산하여 중첩된 가우스분포를 형성시킨다.

step	input	distribution	diffusion
	layer	layer	
n=0	1	1	0
n=1	0	0	$\frac{-1}{4} \quad \frac{2}{4} \quad \frac{-1}{4}$
n=2	0	0	$\frac{-1}{16} \quad \frac{0}{16} \quad \frac{2}{16} \quad \frac{0}{16} \quad \frac{-1}{16}$

(a)



(b)

그림 2. DOG의 초기값의 확산 예와 제안 모델.

- (a) 초기값(-α, 2α, -α)의 확산 예(확산계수 1/4),
- (b) (a)의 반응을 하는 1차원적인 제안 모델.

Fig. 2. An example of the diffusion of the initial values of a DOG and the proposed model.

- (a) an example of diffusing the initial values (-α, 2α, -α) with the diffusivity of 1/4, and
- (b) the proposed model responding as (a).

이 모델의 임펄스에 대한 반응인 그림 2(b)와 같은 분포는 확산이 거듭됨에 따라 LOG함수와 근사하게 된다. 이 모델의 특성을 알아보기 위해, n=305일 때 이 모델의 반응을 LOG와 비교하였다. 그리고 Marr^[2,7]가 제안한 자크가우스함수의 표준편차가 10이고 억제가우스함수의 표준편차가 16인 DOG와도 비교하였다. 또한 Δσ=10⁶×σ 일 때 미분으로 유도된 식 (13)의 DOG도 포함하여 그림 3에 그래프로 나타내었다. 그래프상에서는 미분에 의한 DOG와 확산에 의한 DOG가 모두 LOG와 완전히 일치하여 구분되지 않기 때문에, 각각의 반응과 LOG간의 평균자승

오차(MSE: mean square error)를 계산하였다. Marr가 제안한 DOG는 MSE=4.6x10¹¹을 가지며, 미분에 의한 DOG는 MSE=2.3x10¹⁴, 이 모델에 의한 DOG는 MSE=6.7x10³⁶을 가진다. 따라서 이 모델에 의한 DOG가 Marr의 제안 DOG보다 더 LOG와 유사함을 알 수 있다. 그러나 분산비에 상당한 차이가 있어도 거의 유사한 모양을 하므로, 분산비가 함수의 특성에 미치는 영향은 크지 않다고 할 수 있다.




그림 3. DOG와 LOG의 비교.

- (a) LOG(σ=12.35).
- (b) 가우스함수를 σ에 관한 미분으로 표현한 DOG(Δσ=10⁶×σ, σ=12.35).
- (c) 제안 모델로 305번 확산해서 얻은 DOG(α=1/4, σ=12.4).
- (d) Marr가 제시한 DOG(α=10, σ=16).

Fig. 3. Comparison between DOGs and a LOG.

- (a) the LOG(σ=12.35).
- (b) the DOG by differentiation(Δσ=10⁶×σ, σ=12.35).
- (c) the DOG by this model(α=0.25, n=305, and σ=12.4), and
- (d) the DOG suggested by Marr(α=10, σ=16).

그러면 본 논문에서 제시한 확산뉴런망으로 영상처리를 할 때 계산량을 알아본다. 확산뉴런망으로 영상처리할 경우, 1회 확산에서의 곱셈계산 횟수가 5회이며, 분산이 σ²에 해당되는 확산횟수 n은 식 (11)에 의해 σ²/2α이 되므로 최소당 곱셈 계산량 q는

$$q = 5n = \frac{5}{2\alpha} \sigma^2 \tag{17}$$

이 된다. 2차원에서 확산계수 α 로는 1/6을 사용하였다. 반면 LOG 마스크를 사용한 영상처리에는 LOG 마스크의 크기가 $6\sqrt{2}\sigma$ 이면 충분하므로 화소당 곱셈 계산량은 726^2 이 되어서 제안 모델의 5배 정도가 된다.^{[11][2]} 그리고 LOG나 확산방식의 연산자가 모두 행과 열로 서로 대칭이므로, 행과 열을 분리하여 처리할 수도 있다.^[6] 이 경우, 1차원적으로 한 화소당 3번 곱셈이 계산되고, 행과 열이 각각 처리되어야 하므로, 한번의 확산시 6번의 곱셈을 하게 된다. 그러나 1차원적으로는 확산계수 α 를 2차원보다 크게 둘 수 있다. 1차원에서 확산계수를 1/4로 두면, 화소당 곱셈 계산량 q_n

$$q = 6n = \frac{3}{\alpha} \sigma^2 = 12\sigma^2 \quad (18)$$

이 된다. 이들간의 처리방식에 대한 계산량을 비교하면 표 1과 같다.

그러나 이 모델에 의한 방법에서 확산계수로 1/4나 1/8과 같은 1/2의 거듭제곱인 수를 사용하면, 연산시간이 많이 소요되는 곱셈연산대신 연산속도가 훨씬 빠른 쉬프트(shift)연산으로 처리 가능하므로 연산속도를 10배 이상 높일 수 있다. 또한 하드웨어로 구현할 때 쉬프트 리지스터만의 사용으로 연산이 가능하므로 구조가 매우 간단해 진다고 할 수 있다.

그리고 하나의 확산뉴런망으로 DOG를 처리하며 뉴런간의 연결세기를 고정된 값을 사용하기 때문에, 하드웨어의 구현시 LOG 마스크에 비해 그 구조가 월등히 간단하고 쉬워진다고 할 수 있다. 이들 처리 방식과 하드웨어의 구현에 대한 비교를 표 1에 나타내었다.

표 1. 제안 모델과 LOG 마스크 방법간의 곱셈 계산량과 하드웨어 구현방식의 비교.

Table 1. Comparison of the proposed model with a LOG masking method in the number of multiplications and hardware implementation.

처리방식	α^2	소프트웨어 구현			하드웨어 구현			
		곱셈 계산량		비교	연결갯수		연결방식	
		LOG	확산		LOG	확산	LOG	확산
2차원적 처 리	1	72	15	20X	72	4	가변	고정
	2	144	30	20X	144	4	가변	고정
	4	288	60	20X	288	4	가변	고정
	8	576	120	20X	576	4	가변	고정
1차원적으로 분리하여 처 리	1	17	12	70X	17	4	가변	고정
	2	24	24	100X	24	4	가변	고정
	4	34	48	141X	34	4	가변	고정
	8	48	96	200X	48	4	가변	고정

IV. 시뮬레이션 및 결과 고찰

본 논문에서 영상의 밝기변화를 검출하는 2차원 제안 모델을 시뮬레이션 하였다. 입력으로는 64×64 링컨(Lincoln) 영상을 사용하였다. 이 때 이 모델의 영상처리 결과와 같은 파라미터를 갖는 LOG함수의 콘볼루션으로 처리된 결과를 비교한다. 제안 모델의 확산계수는 1/6로 고정하였으며, 각 데이터는 모두 정수로 처리하였다. LOG 마스크는 실수로 계산하여 정수값만을 사용하였다.

제안 모델에 의한 영상처리 방법으로는, 입력된 영상을 계속 확산하면서 확산이 반복될 때마다 계속 중간결과를 얻을 수 있으며, 이 들은 서로 상이한 공간주파수를 갖는 의미 있는 것들이다. 그림 4는 본 시뮬레이션에 사용한 64×64 링컨 영상이다. 그림 5는 이것을 제안 모델로 처리한 결과이다. LOG 함수를 이용하여 처리한 것을 그림 6에 나타내었다. 그림 5에서 (a)는 확산이 3번 되었을 때의 결과이고, (b)는 6번 확산된 결과이다. 그림 6의 (a)와 (b)는 그림 5의 (a)와 (b)에 해당되는 LOG 마스크를 각각 구하여 콘볼루션한 것이다. 그리고 각 그림에서는 양의 값만을 나타내었다.

이 들 결과에서 제안 모델을 이용한 것과 LOG 마스크에 의한 것이 거의 유사하다. 우리는 여기서 LOG 마스크 방법에 의하거나 확산뉴런망을 이용하거나 거의 같은 공간주파수의 밝기변화를 추출할 수 있음을 알 수 있다.




그림 4. 입력으로 사용한 링컨영상.

Fig. 4. Lincoln picture as an input image.

그리고 확산계수로 다른 값을 사용하더라도 확산횟수를 조정하여 같은 분산값을 갖도록 하면 역시 같은 결과를 얻는다. 그러나 확산계수를 0.25이상의 값으



(a)



(b)

그림 5. 확산계수 1/6인 제안 모델로 처리한 결과 중 양의 값: (a) 3번, (b) 6번 확산 시.

Fig. 5. The positive response only processed by the proposed model with the diffusivity of $\alpha=1/6$ and the number of iterations (a) $n=3$ and (b) $n=6$.

로 취하면 자체 감쇄계수가 음의 값이 되어 가우스분포의 근접이 잘 이루어지지 않는다. 이 결과에서 확산횟수가 늘어날수록, 또 확산계수가 커질수록 추출할 수 있는 입력영상의 밝기변화의 공간주파수는 낮아짐을 알 수 있다. 즉, 확산횟수가 적을 때에는 세밀한 윤곽이 나타나나, 확산이 거듭됨에 따라 윤곽이 희미해진다.

확산뉴런망을 이용하면, 확산계수를 LOG와 같이 함수계산에 의존하지 않고 고정된 값을 취하여 계속 확산하면서, 확산을 1회 반복할 때마다 공간주파수가



(a)



(b)

그림 6. LOG 함수를 이용하여 콘볼루션한 결과 중 양의 값: (a) $\sigma^2=1$, (b) $\sigma^2=2$ 일 때.

Fig. 6. The positive response only in the convolution results with LOG mask of (a) $\sigma^2=1$ and (b) $\sigma^2=2$.

서로 다른 의미있는 중간결과를 구할 수 있다. 따라서 일련의 처리과정으로 각 공간주파수에 대한 밝기변화를 한꺼번에 얻을 수 있어 종합적인 결과를 도출할 수 있다. 확산뉴런망 모델을 이용한 결과인 그림 5의 (a)와 (b)는 연속되는 확산과정에서 얻은 것이며, 그림 6은 각각의 분산 2에 해당되는 LOG 마스크를 계산한 다음 각 LOG 마스크와 입력영상을 콘볼루션한 결과이다.

V. 결 론

본 논문에서는 동물의 시각처리 기능인 뉴런망의 신호전달을 확산의 형태로 해석하여, 입력자극의 확산으로 가우스분포의 반응을 갖는 확산뉴런망 모델을 유도하였다. 그리고 DOG가 LOG와 같음을 보였으며, DOG연산을 하는 뉴런망 모델을 제시하였다.

제안된 모델의 뉴런망에 입력된 자극이 확산뉴런망에서 확산됨으로써 DOG 연산이 가능하며 입력영상의 다양한 밝기변화에 대한 반응을 일련의 확산과정으로 얻을 수 있음을 시뮬레이션을 통해 보였다. 이러한 모델들은 간단한 구성으로 영상의 다양한 밝기변화를 검출할 수 있으며, 기존의 LOG에 의한 영상처리보다 계산량이 줄어든다. 또한 하드웨어로 구현할 때 쉬프트 리지스터만의 사용으로 연산이 가능하므로, 구조가 매우 간단해 진다고 할 수 있다.

뉴런망에서 하나의 뉴런에 연결되는 시냅스는 2차원적으로 4개에 불과하고, 확산계수도 함수값에 의존하지 않으면서 확산횟수와 서로 보완관계에 있으므로 고정된 값을 부여할 수 있다. 이러한 모델들은 연결이 매우 적고 연결세기가 고정된 값이어서 하드웨어의 실현에 매우 효과적이라 할 수 있다.

參考文獻

[1] M. D. Levine, Vision in Man and Machine, McGraw-Hill, New York, 1985.
 [2] D. Marr, Vision, A Computational Investigation into the Human Representation and Processing of Visual Information, Freeman, San Francisco, 1982.
 [3] H. K. Hartline, "The receptive fields of optic nerve fibers," *Am. J. Physiol.*, 130, pp. 690-699, 1940.
 [4] S. W. Kuffler, "Discharge pattern and functional organization of mammalian retina," *J. Neurophysiol.*, 16, pp. 37-68, 1953.
 [5] R. W. Rodieck and J. Stone, "Analysis of receptive fields of cat retina ganglion cells," *J. Neurophysiol.*, 28, pp. 833-849,

1965.

[6] C. Enroth-Cugell and J. G. Robson, "The contrast sensitivity of retinal ganglion cells of the cat," *J. Physiol.*, 187, pp. 517-552, 1966.
 [7] D. Marr and E. C. Hildreth, "Theory of edge detection," *Proc. R. Soc. London B207*, pp. 187-217, 1980.
 [8] A. Huertas and G. Medioni, "Detection of intensity changes with subpixel accuracy using Laplacian-Gaussian mask," *IEEE Trans. Pat. Anal. Machine Intel.*, vol. PAMI-8, no.5, pp. 651-664, Sep. 1986.
 [9] 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.
 [10] J. M. Oyster, F. Vicueb, and W. Boardwell, "Associative network application to low-level machine vision," *Applied Optics*, vol.26, no.10, pp. 1919-1926, May 1987.
 [11] 권율, 남기근, 윤태훈, 김재창, "확산뉴런망을 이용한 밝기변화 추출," 대한전자 공학회논문집, 제 29권, B편, 제 11호, pp. 85-92, 1992.
 [12] Y. Kown, K. G. Nam, T. H. Yoon, and J. C. Kim, "Detection of spatial and temporal intensity changes by a diffusion neural network," *JTC-CSCC'92*, pp. 513-516, 1992.
 [13] J. P. Holman, Heat Transfer, Mertic Edition, Ch.1, McGraw-hill, 1989.
 [14] R. N. Bracewell, The Fourier Transform and its Applications, Second Edition, Ch.17, McGraw-Hill, 1978.
 [15] E. Kreyszig, Advanced Engineering Mathematics, Fifth Edition, Ch.12, John Wiley & Sons, 1983.
 [16] B. C. Kuo, Discrete-data control systems, Printice Hall, Ch.3, pp. 33-74, 1970.

著 者 紹 介

權 栗(正會員) 第 29卷 B編 第 11號 參照
현재 삼우실업 연구소 근무

尹台焄(正會員) 第 29卷 B編 第 11號 參照
현재 부산대학교 전자공학과
조교수

南基坤(正會員) 第 29卷 B編 第 11號 參照
현재 부산대학교 전자공학과 조교수

金在呂(正會員) 第 29卷 B編 第 11號 參照
현재 부산대학교 전자공학과 교수