

# 신경회로망을 이용한 컴퓨터 시각 및 영상처리 기술

(Neural Network Based Computer Vision and Image Processing)

梁 玄 承  
(한국과학기술원 전산학과)

<p>■ 차례 ■</p> <p>① 서 론</p> <p>② 컴퓨터 시각 및 영상처리를 위해 개발된 신경 회로망 모델 및 알고리즘 : survey</p> <p>2.1 영상 처리</p> <p>2.2 영상 인식과 재생</p> <p>2.3 스테레오 시각과 운동</p> <p>③ 신경 회로망을 이용한 컴퓨터 시각 시스템의 응용 및 실험</p> <p>3.1 Hopfield Net을 이용한 영상 복구</p>	<p>3.2 Hamming Net을 이용한 영상 인식</p> <p>3.3 역전파 학습과 다층 퍼셉트론을 이용한 물체 인식</p> <p>3.4 Markov Random Field Model을 이용한 영상해석</p> <p>3.5 Boundary Contour System(BCS)을 이용한 영상 이해</p> <p>④ 결 론</p>
--	--

## 1. 서 론

컴퓨터를 이용하여 시각 기능을 구현하고자 하는 범용적인 영상처리 및 이해 시스템에 관한 연구는 컴퓨터 시각(Computer Vision)이라는 이름하에 30여년 가량 많은 연구가 되어 왔다. 아직 인간의 시각 기능에 필적할만한 컴퓨터 시각 시스템은 개발되지 못했지만, 현재 많은 컴퓨터 시각 시스템이 여러가지 목적으로 개발되어 산업, 군사, 항공 우주등 여러 분야에서 실용화 되고 있다. 하지만 컴퓨터 시각 시스템은 아직도 몇가지 해결되지 않은 문제점을 가지고 있는데 그중 대표적인 것은

- 충분한 속도의 결여(A lack of sufficient

speed)

- 융통성의 결여(A lack a versatility)
- 형상 표현 방식의 비유연성 (Inflexibility in shape representation scheme)
- low level과 high level visual process의 효과적인 결합 및 제어 방법의 결여(A lack of efficient incorporation and control strategy of the low level and high level visual process) 등이다. 이와 같은 문제점들로 인하여 아직 인간의 시각 기능과 유사한 능력을 갖춘 컴퓨터 시각 시스템이 개발되기에는 더 많은 시간과 연구가 필요하다.

현재까지의 컴퓨터 시각 연구에는 두 가지 접근방법이 존재한다.<sup>(1)</sup>

첫째는 Binford등에 의해 주창된 물리적 접근 방법 (physical approach)이다. <sup>(2)</sup> 이들은 실제 물리적 세계를 모델링하고 물리적 법칙에 입각해서 모델을 이용하여 추론을 행한다. 이 과정에서 인간의 시각 시스템이 실제로 어떤 식으로 동작하는지는 문제삼지 않는다. 두번째는 Marr 등이 주장한 신경회로망적인 접근방법 (neural approach) 이다. <sup>(3)</sup> 이들은 인간의 시각 시스템을 신경세포의 수준에서 모델화하는 것을 목적으로 한다.

현재 물리적 접근 방법은 그 한계에 이르렀으며 그 해결책으로 신경회로망적인 접근 방법이 새로이 제시되고 있다. 인간의 신경회로망을 모델로 하여 개발된 neural network은 다음과 같은 성질을 가지므로 컴퓨터 시각 및 영상처리 분야에 많은 응용 가능성을 가지고 있다.<sup>(4)(5)</sup>

1) 고도의 병렬처리 구조(massively parallel structure)

많은 신경회로망 모델들이 병렬 하드웨어를 이용하여 구현하기에 적합하다. 그 이유는 간단한 기능을 갖는 다수의 처리기 (PE : processing element)들이 인접한 처리기들과만 정보를 주고받으면서 동작하기 때문이다. 기본적으로 컴퓨터 시각과 영상처리 분야는 영상이라는 방대한 양의 정보를 실시간에 처리해야할 필요가 있는 분야이고 대부분의 연산이 국부적으로 수행될 수 있으므로 병렬 분산처리 기법이 필수적이다.

2) 적응형 학습 능력(adaptive learning capability)

사람이 문제의 해법을 구하여 프로그램화 하는 것이 아니고 시스템으로 하여금 주어진 예로부터 연결선의 가중치를 조정함으로써 문제의 해법을 발견하게 할 수 있다. 이와 같은 학습 능력은 특정한 목적으로만 사용될 수 있는 ad hoc 시스템이 아닌 범용적인 (general) 컴퓨터 시각 시스템의 구현에 도움이 된다.

3) 결함 극복 능력(fault tolerance capability)

신경회로망은 가중치나 처리기의 출력값이 어떤 고장에 의하여 바뀌더라도 전체의 성능이 급격히 나빠지지 않고 점차적으로 저하되는 성질을 가지고 있다. 이에 반하여 보통 프로그램은 한 비트만 변경되어도 그 동작은 예측할 수 없이 바뀐다. 그러므로 신경 회로망을 이용하면 보다 신뢰도가 높은 시스템을 구현할 수 있다. 이와 같은 특성은 특히 물체의 변형(distortion)이나 부분적 가림(partial occlusion)등에 민감하지 않은 시각 시스템을 구성할 수 있게 해 준다.

4) 모델 지식의 내재적 표현 능력(implicit representation capability of model knowledge)

물체를 표현하기 위한 많은 기법이 개발되었지만 이들 기법은 각각 특정한 형상에만 사용 가능하므로 유연성 (flexibility)이 부족하다. 신경회로망에서는 물체의 모델에 관한 정보를 사람이 직접적으로 표현할 필요가 없고 가중치에 의해서 내재적으로 (implicitly) 표현된다.

현재까지 개발된 신경회로망 모델 중에서 컴퓨터 시각과 영상처리에 이용 가능한 모델의 종류와 이들의 컴퓨터 시각 및 영상처리에의 응용분야는 아래와 같다.

컴퓨터 시각과 영상처리를 위한 신경회로망

모델의 종류 :

Markov Random Field Model

Neocognitron

Hopfield Net

Boltzmann Machine

Darwin II

BCS

Parameter Net

Silicon Retina

컴퓨터 시각과 영상처리에의 응용 분야 :

Image Transform

Image Segmentation

Image Compression

- Image Restoration
- Shape Recognition
- Stereo Vision
- Motion Analysis

2장에서는 현재까지 컴퓨터 시각 및 영상처리를 위해 개발된 신경회로망 모델 및 알고리즘을 소개하고 3장에서는 그 중 대표적인 모델의 개요 및 동작원리를 실험결과와 더불어 상세히 설명한다.

## 2]. 컴퓨터 시각 및 영상처리를 위해 개발된 신경회로망 모델 및 알고리즘 : survey

### 2.1 영상처리 (Image Processing)

영상처리 분야에서 사용되는 대부분의 알고리즘들은 윈도우 operation에 기초한 알고리즘이다. 윈도우 기법을 개선하기 위해서 신경회로망 이론에 기초한 적응형 윈도우 구조(AWA : adaptive window architecture)의 개념이 개발되었다<sup>(6)</sup> 이 방법은 사용자에게 다양한 크기의 윈도우와 여러가지 함수를 설계할 수 있는 유연하면서도 통일된 수단을 제공한다. Aleksander와 Wilson은 AWA를 양안시(Stereo Vision)에 적용하여 윈도우 operation에 의해 값이 잘못 계산되었을 때 적응과정을 통하여 수정될 수 있는 가능성을 제시하였다. 이러한 AWA의 장점은 앞으로 영상 분할과 texture 분석에 AWA가 효과적으로 사용될 수 있는 많은 가능성을 보여준다.

인간의 시각 시스템은 부분적인 형상이나 움직임 그리고 양안시에서의 미세한 차이를 아주 정밀하게 감지할 수 있음이 알려져 있다. 인간의 초기 시각(early vision)에 대한 컴퓨터 시뮬레이션이 행해졌는데 그 결과는 실제 영상에 대해서 인간과 비슷한 특성을 보였다.<sup>(7)</sup> 이 시뮬레이션에서는 눈의 광학적 특성을 고려하여 입력 영상을 Gaussian 필터로 convolution 하였으며, 전통적인 정사각형 샘플이 어레이 대신에 인간의

눈의 감각기의 분포와 유사한 정육각형으로 구성된 어레이를 사용하였다. 또한 초기 시각 처리를 위해서 Laplacian 연산을 사용하였다.

2차원 Garbor Transform은 공간 영역과 주파수 영역이 결합된 표현 방법으로 영상의 해석, 분할, 압축 등에 적합하다. Dougman이 행한 실험에서는 20:1의 영상 압축 효과가 관찰되었다.<sup>(8)</sup> 2차원 Garbor 필터는 실제로 신경 생리학적인 실험을 거쳐서 도출되었는데 뇌의 시각 피질(visual cortex)의 단순 세포에서 볼 수 있는 공간적 국부성, 방향에 대한 감수성, 공간 주파수에 대한 감수성 등과 특성을 잘 표현하고 있다. Dougman은 임의의 영상 변환에 있어서 최적의 계수를 구하기 위해서 3개의 층을 갖는 신경회로망을 제안하였다.<sup>(9)</sup> 이 신경회로망은 고정된 가중치 값을 갖는 두 개의 층과 조정 가능한 가중치를 갖는 하나의 중간층으로 구성되어 있다. 중간층의 가중치는 계층간의 상호 작용에 의해 사용직으로 학습된다. 안정 상태에 도달했을 때의 중간층의 가중치가 Garbor 변환의 최적 계수가 된다.

영상 분할(image segmentation)은 영상 품질이 유사한 화소들이 구성하는 영역의 집합으로 분할하는 작업이다. 영상내의 임의의 한 화소가 어떤 영역에 포함되는가에 관한 결정은 인접한 주변 화소의 특성과 변화 확률에 따른다. 신경회로망을 사용하지 않는 경우에는 원래 영상을 어떤 방향으로 주사하는가에 따라 분할의 결과가 정해지지만, 신경회로망을 사용하면 신경회로망의 병렬성 때문에 이와 같은 영향이 배제된다. Markov Random Field 모델을 사용하면 시스템이 가장 낮은 에너지 상태에 이르렀을 때가 영상이 정확히 분할된 때이다. 이 방법은 회전 변환, 크기 변환, 위치 변환 그리고 물체의 갯수에 영향을 받지 않는다.<sup>(10)</sup>

컴퓨터 시각을 위한 알고리즘들은 전형적으로 경계선, 편차, 곡률, 그림자 또는 공간 주파수 정보 등과 같은 여러가지 사용 가능한 정보 중에서 단지 한 종류의 정보만을 다룰 수 있도록 설계되어 있다. 그러므로 이와 같은 알고리즘은

실제 문제에 적용하기에는 너무나 제한적이다. 이러한 문제를 극복하기 위하여 Grossberg와 Mingola는 경계선, 바탕무늬, 그림자, 거리, 크기 그리고 운동 등의 영상 정보를 협동적으로 결합하여 이들 정보를 개별적으로 사용한 경우보다 더 많은 정보를 표현할 수 있는 “거리 속에 포함된 형상과 색상(form-and-color-in-depth)”이라는 응집된 표현으로 만들어 주는 범용적인 자동 시각 구조를 개발하였다.<sup>(11)</sup> 경계 윤곽 시스템(BCS: Boundary Contour System)이라 명명된 이 시스템은 영상의 특징을 주위 상황에 따라 효과적으로 처리할 수 있는 능력과 다양한 크기의 영상분할과 통합을 할 수 있는 능력을 가지고 있다. BCS는 크기 단위별로 두 개의 연속된 부 시스템을 포함한다. 하나는 방향성 대조 필터(OCF: Oriented Contrast Filter)이고 또 하나는 협동적 경쟁 루프(CCL: Cooperative Competition Loop)이다. BCS는 학습이나 입력 환경에 관한 구체적인 지식이 없이 동작한다.

참고 문헌[12]에서 제안된 신경회로망 모델은 경계선, 변화율, 방향, 변화율의 각 변화량(곡률), 도약 불연속(jump discontinuity) 그리고 1차 미분 불연속점과 같은 저수준(low level)의 특징을 통합적으로 감지하도록 설계되어 있다. 이 신경회로망은 계층적 구조를 가지며 상위 계층으로 갈수록 복잡한 특징을 추출해 낸다. 이 모델은 Marr의 최소 책임의 원리(principle of least commitment)에 기본을 두고 있다.

## 2.2 영상 인식과 재생(Image Recognition and Restoration)

처리 속도와 잡음에 대한 저항성은 영상패턴 인식과 재생에 있어 해결해야 할 주요 연구과제이다. 신경 회로망은 이 두 가지 점에 있어서 효율적인 수단을 제공해 준다. Kohonen의 연상 기억장치는 계산이 간단하며 손상된 영상의 분류와 재생에 사용되었다. 이 방법은 중앙 윤곽(centroidal profile)을 이용한 형태 표현 기법을 사용하였는데 형태 표현은 영상의 크기 변화, 회전, 위치 변화에 불변하도록 하였다.

다중의 신경회로망에는 Rumelhart<sup>(14)</sup>의 역전파(back-propagation) 학습 방식을 이용한 다중 퍼셉트론을 많이 사용하는데 이 신경회로망은 아무리 복잡한 결정영역을 가지는 인식 문제도 풀 수 있다. 이것은 연속과 이진의 입력 신호에 모두 사용 될 수 있으며 음성과 필기 문자<sup>(15)</sup>의 인식에도 응용되었다.

역전파 학습 방식에는, 신경회로망이 궁극적으로 디지털로 만들어졌을 때, 구현하기 힘든 연속함수인 S자형의 함수(signoidal function)가, 사용된다. 이 문제를 고려하여 Widrow와 Winter<sup>(16)</sup>는 제한 정량자(hard limiting quantizer)를 사용한 적응 계층형 신경회로망을 위한 새로운 알고리즘을 개발하였으며 최소 방해 원리(minimal disturbance principle)에 의해서 학습이 진행되도록 하였다. 또한 학습 가능한 분류기에 사용하는 전처리기를 개발하여 망막 패턴의 상, 하, 좌, 우의 위치 변화와 회전, 크기 변화에 불변한 출력을 만들었다.

Fukushima는 아날로그 형식의 세포로 구성되는 다층구조를 가지는 신경 회로망<sup>(17)</sup>을 제안하였다. 이 모델에서는 자극 연결과 억제 연결이 있고, 신경 회로망의 자체 조직을 위한 기본 법칙은 최대 출력 세포만이 자신의 입력 연결을 강화하는 것이다. 시뮬레이션 결과, 위치 이동과 동시 패턴의 형태 변화에 관계 없음이 보여졌다. Fukushima는 새로운 방식의 Neocognition<sup>(18)</sup>에서 후방연결을 구축하였는데, 이 새로운 시스템은 선택적 집중(selective attention), 세그멘테이션, 동시 다 패턴 인식(recognition of several patterns simultaneously), 완벽한 재구성 등의 능력을 가진다.

Carpenter와 Grossberg<sup>(19)</sup>는 신경회로망 모델에 적응 공명 이론(ART)을 개발하였는데, ART 시스템은 단기 기억장치, 장기 기억장치, 상향식 경쟁학습, 하향식 가설 테스트, 개폐 제어를 통합하고, 입력 영상의 인식, 강화, 재현에 사용되었다.

Messner와 Szu<sup>(20)</sup>는 문자 인식을 위한 3채널 시스템을 만들었는데 이 시스템은 2차원의

Walsh 변환에 의한 영상 전처리, 특징 추출, 연관 기억장치의 형성으로 구성된다. 연관 기억장치는 Kohonen의 교차관계 방법과 Grossberg의 신경 회로망 구조 변형과 비슷한 방법으로 구현되었다.

인간 뇌의 정보처리는, 감각과 중앙의 처리를 거쳐 수용체 (receptor)에서 작동체(effector)로 진행되는 단 방향처리로 생각되기는 하나, 이러한 관점은 알려진 수 많은 신경의 통로가 상호 작용적이라는 사실을 무시한 것이다. 위와 같은 문제점을 고려하여 [21]에 설명된 것과 같은 몇몇 피드백 시스템이 시뮬레이션 되었다. 이러한 시스템은 간단한 특징 분석기의 집합과 패턴 분석기의 집합의 두 단계의 시각 계전기(visual relay)를 포함하는 계층적 모델이고 그것은 상위와 하위의 중심점간의 확장된 교환적인 연결을 가진다. 특징과 패턴은 합산기에서 연결되어 입력을 변경하기 위해 계전기에 피드백되는 일정 크기의 반응을 보인다.

회전과 크기 변환에 대응하는 패턴의 보편적인 표현 방법은 polar 변환, log 변환, Fourier 변환과 같은 일련의 패턴 변환을 이용하여 만들 수 있다. 이러한 변환은 [22]에서 제안된 것과 같은 신경회로망에 포함될 수 있는데, 이 신경 회로망은 7개의 병렬처리 구조로 구성된다. 즉 입력 패턴 표현, 극 좌표 변환, 로그 / 극좌표 변환, 로그 / 극좌표의 형상의 1차원 FT, 계층 3의 FT열 상의 1차 FT, 분류기 그리고 출력 표현의 7계층으로 구성된다.

이진 벡터를 연관적으로 사상시키는 수많은 모델이 있지만 아날로그 벡터를 사상시키는 모델은 적다. 그러나 그레이(gray) 영상은 이진 신경 회로망에 의해서 나타낼 수 있다. [23]에서는 영상의 크기가 L, 그레이 함수의 최대값이 M 일 때  $L \times L \times M$ 개의 상호 연결된 뉴런을 가진 신경 회로망의 모델이 만들어졌고, 영상의 그레이 함수를 신경 상태 변수의 단순함으로 나타낸다.

### 2.3 스테레오 시각과 운동(Stereo vision and

motion)

Sun<sup>(24)</sup>은 양안시 연속성과 불변성을 자동적으로 학습할 수 있는 고차의 반복적인 (recursive) 신경회로망을 만들었다. 가중치는 Hebbian 법칙에 의해 학습시켰는데, Hebbian 법칙이 선형적이고 지역적이기 때문에 분석적인 계산이 가능하였다. 또한 가중치를 대칭적으로 학습시켜 항상 수렴하였으며 불균형 접합을 고치는데 한 두번의 반복만이 필요하였다.

[25]에서는 계층적 신경 회로망을 양안시에 사용하였다. 이 신경 회로망은 불변성, 상세 접합 다중근, 연속성등의 제한 조건을 병렬적으로 처리하여 다른 단일 제한 조건을 사용한 신경 회로망보다 성능이 우수하고 빠르다. 신경 회로망의 각 노드는 해당 접합을 나타내고, 후보 접합 노드 사이의 가중치에 제한 조건을 포함시키며, 후보접합을 지원하는데만 제한 조건을 사용하였다.

일반적인 광 흐름(optic flow) 계산은 영상의 밝기를 기반으로 한 것과 모서리, 선형 특성 같은 특성을 기반으로 한 것이 있으나, 모서리의 회귀성, 노이즈 찌그러짐, 회전에 민감한 문제가 있다. 이러한 문제를 해결하기 위해서 불연속적인 영상에서 연속적인 영상의 밝기와 주곡률을 구하기 위해 2차의 다각형 전개(2D polynomial expansion)를 적용하였다.<sup>(26)</sup>

## 3. 신경회로망을 이용한 컴퓨터 시각 시스템의 응용 및 실험

### 3.1 Hopfield Net을 이용한 영상 복구

1982년도에 Caltech의 John Hopfield는 현재 Hopfield Model 또는 Crossbar Associative Memory라 불리는 신경회로망 알고리즘을 발표하여 1960년대 이후 다소 줄어들었던 신경 회로망 분야에 대한 관심을 새로이 불러일으켰다. Hopfield가 제안한 신경회로망은 모든 처리기(PE : processing element)들이 상호간에 연결

된 구조를 가지며 energy minima를 찾아준다. Hopfield Model에서 신경 세포는 입력의 값을 합한 후 thresholding을 행하고 기억은 신경세포 간의 연결선에 보관된다. Hopfield Net은 기본적으로 이진 입력을 요구하므로 화소의 값이 흑과 백 두가지인 이진 영상이나 8비트의 ASC II 값으로 나타내지는 ASC II Text와 같이 정확히 이진 표현이 사용되는 분야에 적합하다. Hopfield 와 Cohen은 Hopfield Net이 연결선의 가중치가 대칭적이고 노드의 출력값이 비동기적으로 변할 때 Hopfield Net이 수렴함을 증명하였다<sup>27, 28)</sup>

Hopfield Net의 응용분야로는 associative memory로 사용하는 경우와 optimization 문제를 푸는데 사용하는 경우의 두가지 분야가 있다. Associative memory로 사용할 때의 Hopfield Net의 단점은 두가지가 있다. 첫째는 저장하고 다시 상기해 낼 수 있는 패턴의 갯수에 심각한 제한이 있다는 것이다. Abu-Mostafa가 Hopfield Net의 Memory Capacity에 대해 증명한 바에 의하면 입력 원소의 갯수를 N이라고 할 때 학습

가능한 패턴의 갯수는  $0.15 \times N \log(N)$  보다 작아야 한다. 이를 역으로 추산하면 10개의 class의 패턴을 기억하기 위해서는 70개 이상의 노드와 5,000개가 넘는 연결선이 필요하다는 결론이 나온다. Hopfield Net의 두번째 단점은 서로 다른 부류의 패턴들이 공유하는 비트의 숫자가 많아질수록 불안정해진다는 점이다. 이와 같은 문제점을 해결하기 위해서는 복잡한 orthogonalization 과정을 도입해야 한다. Associative Memory로 사용되는 Hopfield Net의 구조가 그림 1에 나와 있다.

< Hopfield Net Algorithm >

step 1 : Assign Connection Weights

$$t_{ij} = \begin{cases} \sum_{s=0}^{M-1} x_i^s x_j^s & i \neq j \\ 0 & i = j, 0 \leq i, j \leq N-1 \end{cases}$$

$t_{ij}$  is the connection weight from node  $i$

to node  $j$ ,  $x_i^s = 1$ , or  $-1$  ( $i$ -th element of class  $s$ )

step 2 : Initialize with Unknown Input Pattern

$$\eta_i(0) = x_i \quad 0 \leq i \leq N-1$$

$\eta_i(t)$  : output of node  $i$  at time  $t$

$x_i$  :  $i$ -th element of the input pattern

step 3 : Iterate Until Convergence

$$\eta_j(t+1) = f_h \left[ \sum_{i=0}^{N-1} t_{ij} \eta_i(t) \right]$$

$f_h$  : hard limiter

step 4 : go to step 2


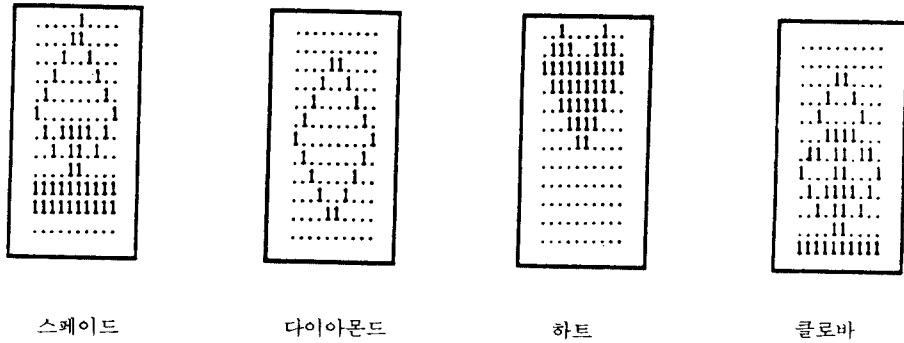



그림 1. Hopfield Net의 구조

그림 2에는 위에서 설명한 Hopfield Net을 이용하여 스페이드, 다이아몬드, 하트, 클로바의 4가지 패턴을 가지고 한 패턴이 심하게 잡음에 영향을 받았을 때 원래의 형상을 복원하는 과정을 실험한 결과가 나와 있다.



(a) 4가지 학습 패턴



(b) 노이즈가 첨가된 스페이드 영상의 복구 과정

그림 2. Hopfield Net의 실험

### 3.2 Hamming Net을 이용한 영상 인식

앞서 나온 Hopfield Net의 실험에서 우리는 학습 패턴의 비트 값을 랜덤하게 바꾼 후 이를 원래 패턴으로 복구하는 문제를 다루었다. 이러한 문제는 전통적으로 통신이론에서 다루어졌던 문제이다. 이 경우 최상의 최소 에러 분류기는 학습 패턴과 입력 패턴 사이의 Hamming distance를 계산하여 그 값이 가장 작은 학습 패턴을 선택하는 것이다. 이와 같은 알고리즘을 신경 회로망으로 구현한 것이 그림 3에 나와 있는 Hamming Net이다. Hamming Net은 두개의 Subnet으로 구성되어 있다. 하위의 subnet은 입력의 갯수인 N에서 Hamming Distance를  $\frac{1}{2}$  matching score를 계산하고 상위의 subnet은 고정된 가중치를 갖는 MAXNET으로서 입력과 가장 잘 일치하는 표본을 나타내는 노드만이

양의 출력값을 나타내고 나머지 노드들은 출력이 0이 되게 한다.

Hamming Net은 Hopfield Net에 비하여 다음과 같은 몇가지 장점을 가지고 있다. 첫째, Hamming Net은 이론적으로 최상의 최소 에러 분류기이므로 Hopfield Net의 성능은 Hamming Net의 성능을 능가할 수 없다. 실제로 같은 패턴을 가지고 실험했을 때 Hamming Net이 보다 많은 잡음을 포함한 경우에도 정확히 패턴을 인식하는 것을 관찰 할 수 있었다. 즉, 본 실험에서 사용된 4가지 패턴 인식의 경우 Hopfield Net은 약 30% 이내의 화소의 값이 바뀌었을 때만 제대로 동작했지만, Hamming Net은 48%의 화소의 값이 바뀌어도 제대로 동작하였다. Hamming Net의 두번째 장점은 Hopfield Net에 비하여 상대적으로 적은 수의 연결선만을

필요로 한다는 점이다. 예를 들면 10가지 부류의 입력 100개를 인식하기 위해서 Hamming Net 은 1,100개의 연결선을 필요로 하는데 반해서 Hopfield Net은 거의 10,000개에 달하는 연결선을 필요로 한다. 또한 Hamming Net의 연결선의 수는 입력의 수에 비례하여 선형적으로 증가하고 Hopfield Net의 연결선의 수는 입력의 수의 제곱에 비례하여 증가한다. Hamming Net을 사용한 실험 결과를 그림 4에 보였다. Hamming Net을 이용한 영상 인식 실험에서도 앞 절에서 사용한 4가지 패턴을 대상으로 하여 실험하였다. 그림 4의 (a) 부터 (g)는 MAXNET의 반복 계산 과정을 보여 주고 있다. 여기에서  $u[0] \sim u[3]$ 는 각 패턴에 해당하는 Hamming Net의 출력 노드의 값으로서 학습된 패턴과 입력 패턴 간의 matching score를 나타내며 최종적으로 가장 잘 일치하는  $u[1]$  이외에는 전부 0이 된다.




그림 3. Hamming Net의 구조

< Hamming Net Algorithm >

step 1. Assign Connection Weights and offsets

In the lower subnet :

$$w_{ij} = \frac{x_j^i}{2}, \quad q_j = \frac{N}{2}$$

$$0 \leq i \leq N-1, \quad 0 \leq j \leq M-1$$

In the upper subnet :

$$t_{kl} = \begin{cases} 1 & k = l \\ -\theta & k \neq l \end{cases}, \quad \theta < \frac{1}{M}$$

$$0 \leq k, l \leq M-1$$

$w_{ij}$  : connection weight  
from input  $i$  to node  $j$   
in the lower subnet

$t_{kl}$  : connection weight  
from node  $k$  to node  $l$

step 2. Initialize with Unknown Input Pattern

$$\mu_j(0) = f_t \left( \sum_{i=0}^{N-1} w_{ij} x_i - \theta_j \right)$$

$$0 \leq j \leq M-1$$

$\mu_j(t)$  : output of node  $j$  in the upper subnet at time  $t$

$x_i$  :  $i$ -th element of the input

step 3. Iterate Until Convergence


$$\mu_j(t+1) = f_t \left( \mu_j(t) - \epsilon \sum_{k=0}^{M-1} \mu_k(t) \right)$$

$$0 \leq j, k \leq M-1$$


This process is repeated until convergence.

step 4. go to step 2







(a)




(e)




(b)




(f)



(c)



(g)



(d)

그림 4. Hamming Net의 실험


### 3.3 역전과 학습과 다층 퍼셉트론을 이용한 물체 인식

패턴 인식이란 입력되는 패턴이 어떤 부류에 속하는 패턴이지를 분류 판별하는 것을 목적으로 한다. 전통적인 패턴 인식 특징 추출(Feature Extraction) 단계와 분류(Classification) 단계의 두 단계로 구성된 구조를 가지고 있다. 특징


추출 단계에서는 입력 패턴으로 부터 서로 다른 부류에 속하는 패턴을 잘 구별해 줄 수 있는 N개의 원소로 된 특징 벡터를 구한다. 이 때 사용되는 특징으로는 패턴의 구조등으로부터 휴리스틱(heuristic)에 의한 방법으로 구한 것 또는 모멘텀(momentum)이나 FT(Fourier Transform) 와 같이 수학적인 방법에 의해 구한 것이 사용된다. 문제에 따라 주어진 패턴을 분류하는데 적합한 특징을 선택하는 것이 패턴 인식 시스템 설계의 1차적 과제가 된다. 특징 벡터는 N차원의 특징공간을 이루며 유사한 패턴에 의하여 M개의 영역으로 구분된다. 분류 단계에서는 M개의 부류중에서 주어진 N개의 특징 벡터로 구성된 입력에 가장 잘 들어맞는 것을 찾아내는 작업을 수행한다.

신경회로망을 이용하여 패턴 인식 시스템을 구현하는데는 두 가지 방법이 있다. 첫째는 특징 추출 단계를 거치지 않고 입력 패턴을 직접 신경 회로망에 입력하여 패턴을 인식하도록 하는 방법 이고 또 다른 방법은 전통적인 패턴 인식 시스템의 구조에서 분류기 부분만을 신경회로망으로 대체하는 방법이다. 첫번째 방법은 특징 자체도 신경회로망에 의해 구해질 수 있다고 보는 방법으로 이상적이긴 하지만 영상의 해상도에 따라 많은 숫자의 노드가 필요하고 아울러 연결선의 갯수도 증가하기 때문에 실제 문제에 적용하기에는 어려움이 많다. 반면에 두번째 방법은 특징 벡터의 크기를 제한하여 소수의 입력만을 사용할 수 있기 때문에 현재 대부분의 패턴 인식 신경 회로망이 이를 채택하고 있다. 구체적인 예를 들자면 특징으로서 모멘텀으로부터 유도된 Moment Invariant(MI)를 사용하면 MI 자체가 물체의 위치변환, 회전변환, 크기변환에 무관한 성질을 가지고 있기 때문에 신경 회로망 분류기의 비선형적 의사 결정 기능과 잡음에 강한 성질과 결합되어 좋은 결과가 얻어짐이 보고 되었다<sup>(29)</sup>. 이 때 사용된 신경회로망은 역전파 학습 규칙에 의해 훈련되는 다층 퍼셉트론이다. 역전파 학습 규칙은 실제 출력값과 바람직한 출력값이 최소 제곱 에러를 갖도록 중간층의 노드를

갖는 다층 신경 회로망의 연결선의 가중치를 반복적으로 조정해 주는 일종의 gradient descent algorithm이다. 중간층 노드의 출력값의 에러는 책임 할당(credit assignment) 방식에 의해 상위 층 노드의 에러로부터 계산되므로 역전파란 이름이 붙었다. 역전파 학습을 사용하는 다층 퍼셉트론은 그 학습 규칙이 수학적으로 잘 정의되어 있고 입력 벡터 공간상에서 임의의 모양을 갖는 영역을 구분해 낼 수 있다는 장점때문에 현재 가장 많이 사용되고 있는 신경 회로망의 하나이다. 그림 5에 다층 퍼셉트론의 구조와 실험에 사용된 영상이 나와 있다.



(a) 다층 퍼셉트론의 구조



(b) 실험에 사용된 영상

그림 5. 다층 퍼셉트론의 구조와 실험 영상

실험과정에서는 5개의 도구를 7번씩 카메라로 영상을 잡아서 총 35개의 영상 데이터 베이스를 구축하고 각 물체당 한 개씩 5개의 영상을 표본으로 사용하여 다층 퍼셉트론을 학습시켰다. 학습이 완료된 후 표본을 포함한 35개의 영상에 대한 인식 결과가 표 1에 나와 있다.

표 1. 인식실험 결과

영상 물체	표본	변형1	변형2	변형3	변형4	변형5	변형6
플라이어(1)	1	1	1	2	1	2	1
니퍼(2)	2	2	1	2	2	2	2
스트리퍼(3)	3	3	3	3	3	3	3
드라이버(4)	4	4	4	4	5	4	4
칼(5)	5	5	5	5	5	5	4


### 3.4. Markov Random Field Model을 이용한 영상해석

영상의 해석은 영상내에 포함되어 있는 물체들을 식별하고 그들간의 공간적인 관계들을 분석함으로써 영상에 담겨 있는 물체 및 상황을 판단하는 것으로 정의될 수 있다.


Markov Random Field(MRF) 모델은 영상의 기본구조 (영역, 선등)를 노드로 하고 이들간의 공간적 인접성을 바탕으로 구성된 인접성 그래프(adjacency graph) 위에서 정의된다(그림 6). 주어진 영상에서 기본 구조들을 분리하여 내고 그들간의 공간적 인접성에 따라 인접성 그래프를 형성하고 나면, 영상의 해석은 그래프에서의 각 노드를 올바른 물체로 명명(labeling) 함으로써 이루어진다. 이 때, 각 노드의 명명은 그 노드가 나타내는 영상내에서의 구조와 명명된 물체와의 특성의 차이 및 인접한 노드들과의 모순성(inconsistency)을 최소화하도록 이루어지고, 이러한 최적화 문제를 풀기 위해 simulated annealing 기법이 적용된다. 이와 같이 MRF 모델을 바탕으로 한 영상 해석 기법은 모델을 영상의 기본 구조들로 구성된 그래프 위에서 정의하고 이들 simulated annealing과 같은 일반

적인 최적화 문제로 해결할 수 있기 때문에 영상 해석에 유용하다.

다음에는 MRF 모델을 그래프 위에서 정의하고 각 노드의 명명을 최적화하기 위한 클릭(clique) 함수 및 에너지 함수에 대해서 설명한다.



a. 가상적인 영상



b. 인접성 그래프

그림 6. 가상적 영상에 대한 인접성 그래프 및 영상해석

### MRF 모델의 정의

$G=(R, E)$ 를 분리된 영역의 집합  $R$  및 인접한 영역들을 잇는 선분의 집합  $E$ 로 구성된 그래프라고 하고  $n=\{n(R_i), i=1, \dots, N\}$ 를 각 영역  $R_i$ 에 인접한 영역들의 집합, 그리고  $I=\{I_1, I_2,$

... $I_n$ 를 각 영역에 부여된 명명들의 집합이라 하면, 영역  $R_i$ 가 어떤 물체로 식별될 가능성은 오직 영역  $R_i$ 에 인접한 영역들이 어떤 물체로 식별되었는가에만 영향을 받을 때  $I$ 를  $n$ 에 대한  $G$  위에서의 MRF라고 정의한다. 여기에서 중요한 것은 MRF를 위와 같이 정의하였을 때, 각 영역에 대한 명명의 인스턴스  $I$ 에 대한 확률밀도 함수  $P[I]$ 는 Gibbs Distribution의 형태를 가지며 영역의 명명은 이러한  $P[I]$ 를 최대화하는  $I$ 를 구하는 것이 된다. 즉,

$$P[I] = Z^{-1} \exp[-U(I)]$$

$$U(I) = \sum V_c(I) \text{ for all } c \text{ in } C(G, n)$$

$$Z = \sum \exp[-U(I')] \text{ for all instance } I'$$

여기에서  $U(I)$ 는 에너지 함수,  $V_c(I)$ 는 클릭 함수이고  $C(G, n)$ 은 그래프  $G$  및  $n$  위에서 정의된 클릭의 집합을 나타낸다. 결국  $P[I]$ 는 에너지 함수  $U(I)$ 를 최소화 시킴으로써 최대화될 수 있고, 이를 위해서는 다시 클릭 함수들의 합을 최소화시켜야 하므로 영상해석은 이들 클릭 함수를 어떻게 정의하는가의 문제로 귀결된다.

**클릭 함수의 정의**


클릭 함수는 단일 노드에 대한 함수와 다중 노드에 대한 함수로 구분되어질 수 있다. 단일 노드에 대한 경우에 있어서 클릭 함수는 영역  $R$ 에 부여된 물체의 특성 및 영역의 특성과의 차이에 대한 벌점(penalty)을 규정한다. 즉, 특성  $i$ 에 대한 영역  $R$ 의 특성 값을  $X_i(R)$ , 영역  $R$ 에 부여된 물체의 명명을  $I(R)$ , 각 물체의 특성에 관한 지식을  $K$ 라 하면, 이 벌점은  $B_i(I(R) : K, X_i(R))$ 로 표현될 수 있으며, 특성의 수가  $m$ 일 때 단일 노드에 대한 클릭 함수는

$$V_c(I(R) : K, X(R)) = \sum B_i(I(R) : K, X_i(R)),$$


$$i=1, \dots, m$$

으로 나타낼 수 있다. 이 때  $B_i$ 를 해당 클릭 함수에 대한 기저함수(basis function)라 한다. 따라

서, 다시 문제는 이러한 기저함수를 어떻게 규정하는가로 귀착된다. 여기에는 여러가지 방법이 있을 수가 있는데, 기본 원리는 측정된 영역의 특성값과 그 영역에 부여된 물체의 특성과의 차가 클수록 벌점의 값도 커져야 한다는 것이다. 이에는 Gaussian 함수, piecewise linear 함수 등이 이용될 수가 있다(그림 7).



a. Gaussian 함수



b. Piecewise Linear 함수

그림 7. 기저함수의 예

다중 노드에 대한 클릭함수는 매우 간단하게 정의될 수가 있다. 즉,  $I_c(R)$ 을 클릭  $c$ 를 이루는 영역들에 부여된 물체의 명명 벡터라 할 때,

클릭함수는

$$B_c(I_c(R) : K) = k(1 - P_c[I_c(R) | K])$$

로 정의될 수가 있고, 여기에서  $P_c$ 의 값은  $I_c(R)$ 에서 인접한 영역들간에 명명된 값들이 상호 모순성이 없을 때 1이고, 그렇지 않을 때 0으로 정의된다.

이렇게 정의된 클릭함수를 바탕으로 한 영상의 해석은 다음과 같다. 즉, 주어진 영상으로부터 기본구조 (영역)들을 분리하여 내고 이들로부터 인접성 그래프를 형성한다. 형성된 그래프의 각 노드를 임의의 물체로 명명한 다음, 그래프에 존재하는 각 클릭에 대한 클릭 함수의 합을 구한다. 최종적인 영상해석 결과는 이 클릭함수 값의 합, 즉 에너지 함수값을 최소화하는 영역들의 명명이 된다. 그러나, 각 노드에 부여 가능한 모든 명명에 대해 클릭함수의 값을 구하는 것은 노드의 수가 하나씩 증가할 때마다 엄청난 양의 계산량의 증가를 가져온다. 따라서 이를 해결하기 위한 방법으로 simulated annealing 기법을 적용할 수가 있다.

### Simulated Annealing

Simulated Annealing 기법은 combinatorial optimization이 포함된 문제를 해결하기 위한 방법으로서 많이 이용되어 왔다. 이를 위에서 언급한 문제에 적용하여 보기로 한다.

초기에 인접성 그래프의 각 노드를 임의의 물체로 명명하고 초기 매개변수  $T_0$ 의 값을 정한다. 이로부터 클릭함수의 합으로 정의된 초기 에너지 함수값  $E_0$ 를 구한다. 그래프의 각 노드를 차례로 방문하면서 방문된 노드를 임의의 물체로 명명한 후 다시 에너지 함수값  $E_k$ 를 구한다. 만약 에너지 함수값이 감소하였으면 새로운 명명을 받아들이고 그렇지 않을 경우 새로운 명명을  $p = e^{-\Delta E/T}$ 의 확률을 가지고 받아들인다. 그래프의 모든 노드에 대해 이 과정을 거친 후 매개변수  $T$ 의 값을 일정 비율만큼 감소시킨다. 다시 이로부터 위의 과정을 에너지 함수값이 더 이상

줄어들지 않을 때까지 반복한 후 각 노드에 부여된 물체의 명명을 최종적인 영상해석 결과로 받아들인다.

### 3.5 Boundary Contour System (BCS)을 이용한 영상 이해

기계 시각을 구현하기 위해 개발되어온 많은 인공지능 알고리즘들을 살펴보면 대부분의 알고리즘들이 특정 응용 분야에만 적용이 가능하다. 이러한 알고리즘들은 단일한 정보만을 - 예를 들자면 모서리, 곡률, 그림자 정보, 디스패리티 (disparity) 등 - 다루도록 설계되어 있다. 더우기 이들 알고리즘들은 위의 예와 같이 각각 상이한 정보를 다루는데 있어서도 서로 다른 수학적 이론에 기반을 두고 있으므로 이들 알고리즘들을 결합하여 하나의 범용적인 컴퓨터 시각 시스템을 구현하기는 무척 힘들다. 현재의 컴퓨터 시각 알고리즘들에 있어서는 다른 종류의 정보는 인식의 애매성을 감소시키는데 도움이 되기 보다는 종종 그와 반대로 인식에 방해가 되는 잡음의 역할을 하기도 한다. 하지만 대부분의 실제 영상들은 한 영상의 각 부분마다 서로 다른 종류의 알고리즘에 적합한 정보를 포함하고 있는 것이 보통이다.

인간이 어떤 장면을 바라 볼 때 인간의 두뇌는 여러가지 국부적이고 애매한 시각 정보를 결합하여 신속하고 정확하게 전체적으로 일관성이 있고 애매하지 않은 표상을 만들어 낸다. 이러한 사실은 다음과 같은 질문을 떠오르게 한다: 다양한 시각 정보들을 협동적으로 이용하여 3차원 세계로부터 얻어진 실제 영상을 인지하기 위하여 필요한 새로운 원리와 메카니즘은 무엇인가? Grossberg를 비롯한 일단의 학자들이 이러한 질문에 답하고 범용적인 컴퓨터 시각 시스템을 개발하기 위해서 신경 회로망 이론에 기초한 새로운 시각 시스템의 구조에 관하여 최근 활발히 연구하고 있으며 그 중 하나가 바로 BCS이다. 이 새로운 시각 시스템 구조는 경계선, 무늬, 그림자, 거리, 운동 등의 다양한 영상 정보들을 협동적으로 결합하여 실시간 안에 form-

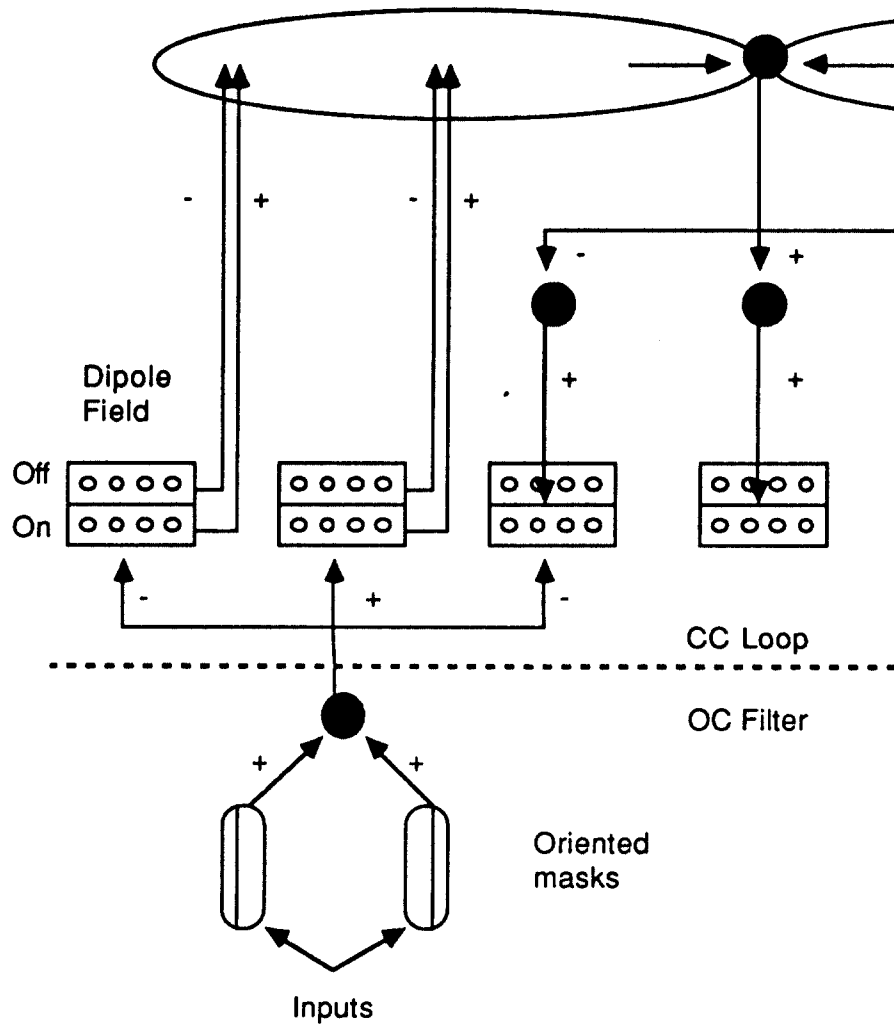


그림 8. BCS의 개략적 구조




그림 9. 시각의 경계선 완성 효과를 볼 수 있는 그림

-and-color-in-depth라고 불리우는 일관된 표상을 생성하는 과정을 설명하고 있으며 이 결과 얻어진 표상이 기존의 단일 정보만을 이용하여 얻어진 표상보다 더 유용함을 보여준다.

BCS는 그림 8과 같은 구조를 가지고 있으며 영상의 경계선과 무늬 그리고 그림자가 진영역을 분할하고 그룹지어지는 작업을 신경 회로망의 역동성을 이용하여 수행한다. BCS 이론의 기본적인 개념은 표면 인지의 심리학적인 실험으로부터 근거하고 있다. 인간은 망막의 정맥이나 맹점으로 부터는 아무런 시각적인 자극을 받지 못하는

대도 이러한 불연속점의 존재를 느끼지 못한다. 이로 미루어 보아 망막의 자극의 이들 불연속점을 지나 연결되는 메카니즘이 존재한다고 생각된다. 여기에는 경계면 완성과 특징 충전의 두가지 메카니즘이 개입하고 있다. 그림 9에 나와 있는 예에서 볼 수 있는 현상이 BCS의 경계선 완성 과정이다.

BCS는 방향성을 띄면서 상호 작용을 하는 작용을 하는 두 개의 연결된 서브 시스템이 계층적으로 구성되어 있다. 하부 서브 시스템을 방향성 명암 대비 필터 (Oriented Contrast Filter) 라고 부르고 상부 서브 시스템은 협동-경쟁하는 루프(Cooperative-Competitive Loop)라고 부른다. 이들의 구조와 동작원리에 대해서 자세히 설명하면 다음과 같다.(그림 8 참조)

방향성 명암 대비 필터는 영상의 서로 다른 명암대비에 반응하는 방향성 감각 영역의 두 개의 연속된 단계로 이루어져 있다. 첫번째 단계에는 위치와 방향은 같지만 서로 정반대의 명암 대비 방향에 반응하는 두 개의 감각 영역이 존재한다. 두번째 단계에 있는 감각 영역은 첫번째 단계의 감각 영역들의 출력을 받아 들어서 첫번째 단계와 위치 및 방향은 같지만 명암 대비의 방향에는 무관하게 활성화된다. 이와 같은 두 단계의 처리 과정을 거침으로써 방향성 명암 대비 필터는 방향성 명암 대비의 방향에는 좌우되지 않으나 그 양에는 민감한 출력을 생성해 낸다.

협동-경쟁하는 루프는 공간적으로 작은 범위에서 경쟁하는 단계와 공간적으로 큰 범위에서 협동하는 두 개의 단계로 이루어져 있다. 이 두 경쟁하는 단계와 협동하는 단계 사이의 피드백 작용에 의해서 우리가 목적으로 하는 경계선 완성효과를 얻게 된다. 방향성 명암 대비 필터의 출력은 협동하는 단계의 해당하는 위치에 있는 세포를 활성화 시키고 인접한 세포들은 억제시킨다. 다시 말하자면 이러한 기능은 중심 강화 주변 약화(on-center off-surround) 구조라고 할 수 있다. 경쟁하는 단계의 순수한 효과는 그림 10에서 볼 수 있는 말단부 단절 효과이다.




그림 10. 말단부 단절 효과

경쟁하는 단계의 출력은 다음 단계인 공간적으로 큰 범위에서 협동하는 단계, 즉 경계선 완성 과정의 입력으로 사용된다. 협동하는 단계의 세포들은 입력 영역의 크기가 다르고 그림 11과 같은 모양을 갖는 양극(Bipole) 세포들로 구성되어 있다. 이들이 협동 작업을 하여 경계선을 완성해 나가는 과정이 그림 12에 나와 있다.




그림 11. 양극 세포의 모양




그림 12. 경계선 완성 작업 과정

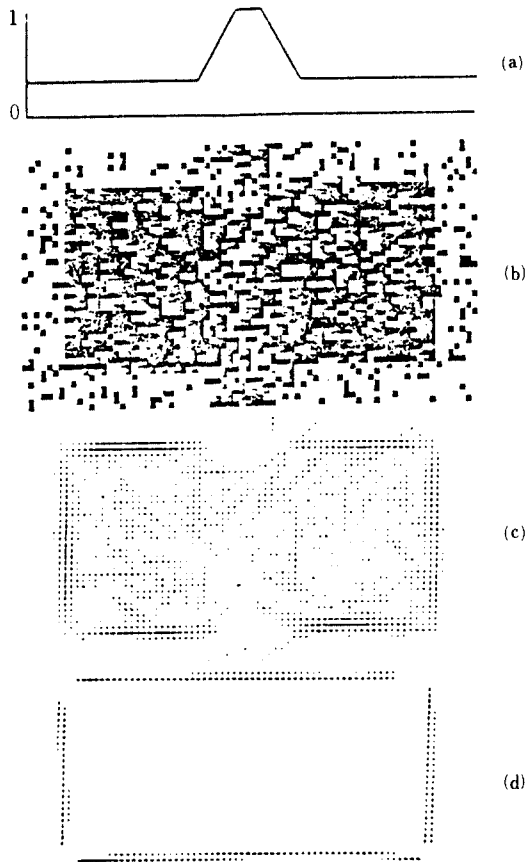


그림 13. BCS의 실험 결과

그림 12에서 1번 경로에 의해 활성화된 경계선 완성 신호는 2번 경로를 따라 피드백되어 중앙에 경계선을 만들고 이는 또 3번 경로에 의해 전파되어 4번 경로의 경계선 완성 신호를 발생시킨다. 이러한 과정을 거쳐서 1번 경로들 사이에

연속된 경계선이 만들어지게 된다.

BCS를 컴퓨터로 시뮬레이션하여 잡음이 포함된 영상에서 물체를 분리해낸 실험 결과가 그림 13에 나와 있다.

#### 4 결론

신경 회로망은 고도의 병렬처리 구조, 적응형 학습 능력, 결함 극복 능력, 모델 지식의 내재적 표현능력 등의 특성을 가지고 있어 기존의 폰노이만 형의 컴퓨터로 처리하기 힘든 여러가지 문제를 해결할 수 있는 능력을 가지고 있다. 신경 회로망의 효과적인 응용이 가능한 여러 분야 중에서도 특히 컴퓨터 시각 및 영상처리는 근본적으로 다량의 정보가 고속으로 처리되어야 하고 알고리즘이 대부분 국부적인 윈도우 기법의 연산이며, 잡음 및 변형에 민감하지 않아야 하는 등 기존의 컴퓨터로 효과적인 수행이 힘든 분야이다. 현재 컴퓨터 시각 및 영상처리를 위한 많은 신경회로망 모델들이 제안되어 성능이 입증된 바 있다. 하지만 아직 대부분의 실험은 simulation에 불과하고 실용화되기 위해서는 신경 회로망 하드웨어가 개발되어야 할 것이다.

#### 參 考 文 獻

1. Wei Li and Nasser M. Nasrabadi, "Review on applications of neural network to computer vision", *SPIE*, vol, 1004, pp. 104~111, 1988.
2. R. Brooks and T. Binford, "Representing and reasoning about partially specified scenes", *Proceedings : Image understanding workshop*, pp. 41~47, SAI, April 1979.
3. D. Marr and T. Poggio, "From understanding computation to understanding neural circuitry", *Neural-sciences Res. Prog. Bull.*, vol, 15, pp. 470~488, 1977.
4. 고병기, "신경망을 이용한 인쇄체 한글 문자의 인식", 석사 학위 논문, 한국과학기술원, 전산학과, 1982. 2



5. M. A. Arbib and A. R. Hanson, *Vision, Brain, and Cooperative Computation*, MIT Press, Cambridge, Massachusetts, 1987.
6. I. Aleksander and M. J. D. Wilson, "Prospects for Adaptive Window Architectures", *SPIE Architectures and Algorithms for Digital Image Processing*, vol. 596, pp. 74~81, Cannes, France, 1986.
7. S. Grossberg and E. Mingolla, "A neural network architecture for preattentive vision: multiple scale segmentation and regularization", *Proceedings of the IEEE First Int. Conf. on Neural Networks*, vol. 4, pp. IV-177- IV-184, San Diego, California, June 21~24, 1987.
8. J. M. Oyster and J. Skrzypek "Computing shape with neural networks: a proposal", *Proceedings of the IEEE First Int. Conf. on Neural Networks*, vol. 4, pp. IV-335- IV-334, San Diego, California, June 21~24, 1987.
9. John G. Daugman, "Complete Discrete 2-D Gabor Transforms by Neural Networks for Image Analysis and Compression", *IEEE Trans. on Acoustics, Speech, and Signal processing*, vol. 36, no. 7, pp. 1,169~1,179, July 1988.
10. J. Zhang and J. W. Modestino, "A Markov Random Field Model-Based Approach to Image Interpretation", *SPIE*, vol. 1199, pp. 328~339, 1989.
11. M. T. Tenorio and C. S. Hughes, "Real time noisy image segmentation using an artificial neural network model", *Proceedings of the IEEE First Int. Conf. on Neural Networks*, vol. 4, pp. IV-357- IV-363, San Diego, California, June 21-24, 1987.
12. J. M. Oyster and J. Skrzypek, "Computing shape with neural networks: a proposal", *Proceedings of the IEEE First Int. Conf. on Neural Networks*, vol. 4, pp. IV-335- IV-344, San Diego, California, June 21-24, 1987.
13. G. Eichmann, M. Jankowski, and M. Stojancic, "Shape description with an associative memory", *SPIE Hybrid Image Processing*, vol. 638, pp. 76~82, 1986.
14. D. E. Rumelhart and J. L. McClelland, *Parallel Distributed Processing, I and II*. MIT Press, Cambridge, Mass., 1986.
15. D. J. Burr, "experiments on Neural Net Recognition of spoken and Written Text", *IEEE Trans. on Acoustics, Speech, and Signal Processing*, vol. 36, no. 7, pp. 1,162~1,168, IEEE, July 1988.
16. B. Window and R. Winter, "Neural Nets for Adaptive filtering and Adaptive Pattern Recognition", *Computer*, pp. 25~39, IEEE, March 1988.
17. K. Fukushima and S. Miyake, "Neocognitron: A new algorithm for pattern recognition tolerant of deformations and shifts in position", *Pattern Recognition*, vol. 15, no. 6, pp. 455~469, Pergmon Press Ltd. Great Britain, 1982.
18. K. Fukushima, "A Neural Network for Visual Pattern Recognition" *Computer*, pp. 65~75, IEEE, March 1988.
19. G. A. Carpenter and S. Grossberg, "The ART of Adaptive Pattern Recognition by a Self-Organizing Neural Network", *Computer*, pp. 77~88, IEEE, March 1988.
20. R. A. Menssner and H. H. Szu, "Distorted Character Recognition via an Associative Neural Network", *Proceeding of SPIE on Intelligent Robots and Computer Vision*, vol. 726, pp. 73~79, 1986.
21. K. P. Unnikrishnan, A. S. Pandya, and E. Harth, "Role of Feedback in Visual Perception", *The Proceedings of the IEEE International conference on neural networks*, vol. 4, pp. IV-259- IV-267, SOS Printing, San Diego, CA, June 21-24, 1987.
22. W. L. Reber and J. Lyman, "An artificial neural system design for rotation and scale invariant pattern recognition", *Proceedings of the IEEE First Int. Conf. on Neural Networks*, vol. 4, pp. IV-227- IV-283, San Diego, California, June 21-24, 1987.
23. G. Krishnan and D. Walters, "Psychologically plausible features for shape recognition in a neural network", *IEEE Int. Conf. on Neural Networks*, vol. 2, pp. II-127- II-134, San Diego, California, July 24-27, 1988.

24. G. Z. Sun, H. H. Chen, and Y. C. Lee, "Learning stereopsis with neural networks", *Proceedings of the IEEE First Int. Conf. on Neural Networks*, vol. 4, pp. IV-345- IV-355, San Diego, California, June 21-24, 1987.
25. C. V. Stewart and C. R. Dyer, "A connectionist model for stereo vision", *Proceedings of the IEEE First Int. Conf. on Neural Networks*, vol. 4, pp. IV-215- IV-223, San Diego, California, June 21-24, 1987.
26. Y. T. Zhou and R. Chellappa, "Computation of Optical Flow Using a Neural Network", *IEEE Int. Conf. on Neural Networks*, vol. 2, pp. II-71- II-78, San Diego, California, July 24-27, 1988.
27. M. A. Cohen and S. Grossberg, "Absolute Stability of Global Pattern formation and Parallel Memory storage by Competitive Neural Networks" *IEEE Trans. Syst. Man Cybern. SMC-13*, pp. 815~826, 1983.
28. J. J. Hopfield, "Neural Networks and Physical Systems with Emergent Collective Computational Abilities", *Proc. Natl. Acad. Sci. USA*, vol. 79, pp. 2,254~2,588, April 1982.
29. A. Khotanzad and J. H. Lu, "Distortion Invariant Character Recognition by a Multilayer Perceptron and Backpropagation Learning", *IEEE ICNN*, vol. 1, pp. 625~632, July 1988



梁玄承

저자약력

- 1976년 : 서울대학교 전자공학과 졸업
- 1981년~1982년 : 미국 Pennsylvania주립대학 Electro-Optics Lab연구원
- 1983년 : 미국Purdue대학교 전기공학과 석사
- 1986년 : : 미국Purdue대학교 전기공학과 박사
- 1983년~1986년 : 미국Purdue대학교 Robot Vision Lab연구원
- 1986년~1988년 : 미국Iowa대학교 전기및 컴퓨터 공학과 조교수
- 1988년 8 월~현재 : 한국과학기술원 전산학과 조교수
- 1990년 5 월~현재 : 한국과학기술원 인공지능연구센터 시각정보처리 연구실장