

목표물의 고속 탐지 및 인식을 위한 효율적인 신경망 구조

원 용 관[†] · 백 용 창[†] · 이 정 수[†]

요 약

목표물 탐지 및 인식은 신경망의 적용이 활발한 하나의 분야로서, 일반적인 형태인식 문제들의 요구 사항에 추가적으로 translation invariance와 실시간 처리를 요구한다. 본 논문에서는 이러한 요구 사항을 만족하는 새로운 신경망의 구조를 소개하고, 이의 효과적인 학습 방법을 설명한다. 제안된 신경망은 특징 추출 단계와 형태 인식 단계가 연속(Cascade)된 가중치 공유 신경망(Shared-weight Neural Network)을 기본으로하여 이를 확장한 형태이다. 이 신경망의 특징 추출 단계는 입력에 가중치 창(weight kernel)으로 코릴레이션 형태의 연산을 수행하며, 신경망 전체를 하나의 2차원 비선형 코릴레이션 필터로 볼 수 있다. 따라서, 신경망의 최종 출력은 목표물 위치에 첨예(peak)값을 갖는 코릴레이션 평면이다. 이 신경망이 갖는 구조는 병렬 또는 분산 처리 컴퓨터로의 구현에 매우 적합하며, 이러한 사실은 실시간 처리가 중요한 요인이 되는 문제에 적용할 수 있음을 의미한다. 목표물과 비목표물간의 숫자상 불균형으로 인하여 초래되는 오경보(false alarm) 발생의 문제를 극복하기 위한 새로운 학습 방법도 소개한다. 성능 검증을 위하여 제안된 신경망을 주차장내에서 이동하는 특정 차량의 탐지 및 인식 문제에 적용하였다. 그 결과 오경보 발생이 없었으며, 중형급 컴퓨터를 이용하여 약 190Km로 이동하는 차량의 추적이 가능한 정도의 빠른 처리 결과를 보여 주었다.

Efficient Neural Network Architecture for Fat Target Detection and Recognition

Yong Kwan Weon[†] · Yong Chang Baek[†] · Jeong Su Lee[†]

ABSTRACT

Target detection and recognition problems, in which neural networks are widely used, require translation invariant and real-time processing in addition to the requirements that general pattern recognition problems need. This paper presents a novel architecture that meets the requirements and explains effective methodology to train the network. The proposed neural network is an architectural extension of the shared-weight neural network that is composed of the feature extraction stage followed by the pattern recognition stage. Its feature extraction stage performs correlational operation on the input with a weight kernel, and the entire neural network can be considered a nonlinear correlation filter. Therefore, the output of the proposed neural network is correlational plane with peak values at the location of the target. The architecture of this neural network is suitable for implementing with parallel or distributed computers, and this fact allows the application to the problems which require real-time processing. New training methodology to overcome the problem caused by unbalance of the number of targets and non-targets is also introduced. To verify the performance, the proposed network is applied to detection and

[†] 정 회 원: 한국통신 전송기술연구소
 논문접수: 1997년 7월 1일, 심사완료: 1997년 9월 5일

recognition problem of a specific automobile driving around in a parking lot. The results show no faulse alarms and fast processing enough to track a target that moves as fast as about 190 km per hour.

1. 서 론

McCulloch와 Pitts에 의하여 인공 지능 신경망의 최초의 모델이 제안된 이후[1], 공학적 접근법과 인공 지능을 결합하는 많은 종류의 신경망들이 다양한 형태의 문제에 널리 적용되고 있다. 특히, 오류 역전(Error Back-propagation) 학습법의 개발로 다층 구조(Multi-layer) 신경망이 각종 형태 인식(Pattern recognition)의 문제에 성공적으로 활용되고 있다[2, 3, 4]. 이러한 폭 넓은 활용의 배경 중에는, 특정 문제 해결을 위해 신경망 내부의 특성 분석 및 해석이 특별히 요구되지 않는 점을 들 수 있다. 이보다는 신경망의 구조, 초기 조건, 신경소(Neuron)의 특성 및 학습법이 문제 해결의 성공에 주요 관건이다[2]. 그러나, 신경망에 대한 이론적 연구 및 적용 사례에 대한 수 많은 연구에도 불구하고, 이들을 포함하여 아직까지도 해결되지 않은 많은 문제점들이 있다[3].

목표물 탐지 및 인식은 신경망의 적용이 활발한 하나의 분야이며[5], 일반적으로 목표물 탐지 및 인식 시스템은 일상적인 형태 인식 문제들의 요구 사항들 외에 다음과 같은 두 가지의 추가적인 요구 사항이 있다:

- 1) Translation invariance,
- 2) 실시간 처리(Real-time processing).

첫번째 요구 조건은 목표물의 위치 이동에 따른 문제를 해결하기 위하여 필수적이다. 즉, 목표물이 입력 영상 내의 어떠한 위치에 존재하든 탐지의 결과는 동일하여야 한다. 이 요구 조건을 충족 시키기 위하여, 신경망 시스템으로 입력 영상 전체를 탐색(Scanning)하는 방법이 일반적으로 사용되고 있다[5, 6]. 그러나 이러한 방법들은 목표물을 탐지하기까지 너무나 긴 시간이 소요되어 실시간 처리가 불가능하다. 이러한 문제를 해결하기 위해 전처리 방법을 이용하여 목표물 존재 가능성이 높은 위치를 선별한 후 신경망 시스템으로 탐지하는 방법을 사용하기도 한다[5].

본 논문에서는 "특정 문제의 해결을 위하여 어떠한 구조의 신경망이 적절한가?"라는 질문에 대한 하나의 예로, 목표물 탐지 및 인식에 매우 적합한 새로운 신


경망의 구조를 소개하며 이의 효과적인 학습 방법을 설명한다. 이 신경망은 Translation invariant의 특성을 갖는 가중치 공유 신경망(Shared-weight Neural Network)을 기본 구조로 가지며[7], 실시간 처리가 가능하도록 병렬 또는 분산 처리 컴퓨터를 이용한 구현에 적합한 구조를 갖도록 확장하였다. 시스템의 성능을 검증하기 위하여, 주차장 내에서 이동하는 특정 차량을 탐지하는 문제에 적용하였다. 그 결과 오경보(False alarm)의 발생은 없었으며, 대단히 유사한 차량을 구별하는 능력을 보여 주었다. 특히, 모의 실험에서 중형급 컴퓨터를 이용하여 고속으로 움직이는 차량의 추적이 가능하였으며, 병렬 처리 컴퓨터와 같은 고속 처리 시스템을 사용하거나 다수의 중형급 컴퓨터로 시스템을 구현할 경우 빠른 이동 목표물의 탐지 및 추적이 가능함을 보여 주었다.

2. 가중치 공유(shared-weight) 신경망 구조 및 동작

2.1 신경망 구조

(그림 1)에 나타난 가중치 공유 신경망의 원래 목적은 신경망에 구조적인 제한(Structural constraint)을 가하여 자유도(DOF: degree of freedom)를 줄임으로써 보다 나은 성능을 얻고자함에 있다[7]. 가중치 공유 신경망 $W = (F, C)$ 는 특징 추출 신경망(F)과 형태 분류 신경망(C)의 두 종류가 Cascade로 연결되어 구성된다. 형태 분류 신경망(C)은 일반적으로 널리 알려진 다층 신경망(C; multi-layer neural network)이다[4].

특징 추출 (Feature extraction) 신경망(F)은 2차원 배열로서 지역적 연결(Local connectivity)을 갖는 2차원 전방향 다층(Feedforward multi-layer) 신경망으로 볼 수 있다. 이 신경망의 각 층은 공유된 가중치 창(SWK: shared-weight kernel)과 입력 정보간의 코릴레이션 형태의 연산으로 특징을 추출하게 된다. 즉, 공유된 가중치 창(SWK)을 이용한 코릴레이션 형태의 연산에 의하여 지역적인 특징을 추출하고, 다음 상위 층에서는 이 지역적인 특징들로부터 다시 동일한 코릴레이션 형태의 연산 방법의해 고차원(High order)



(그림 1) 가중치 공유(shared-weight) 신경망의 구조
(Fig. 1) Architecture of shared-weight neural network.

의 특징을 얻어낸다. 각층은 특징 지도(Feature map)라 불리는 하나 또는 그 이상의 2차원 코릴레이션 출력력을 갖는다. 이때, 하나의 특징 지도에 속한 모든 신경소는 하나의 가중치 값을 공유한다.

하나의 특징 영역에 속한 신경소 j 의 출력은


$$O_j = f(\text{net}_j) \tag{1}$$

$$\text{net}_j = \sum_{i \in D[j]} w_{ji} O_i + \text{bias}_j \tag{2}$$

에 의하여 계산된다. f 는 Sigmoid 함수이고, bias_j 는 입력이 항상 1인 하나의 가중치로 볼 수 있다. w_{ji} 는 신경소 i 와 j 간의 가중치를 나타내는데, 동일한 특징 영역내의 모든 신경소 j 는 w_j 를 공유한다. 즉, 신경소 p 와 q 가 동일한 특징 영역에 속하면, $w_p = w_q$ 이다. 또한, 신경소 j 의 출력 계산에 관련되는 모든 신경소 i 는 신경소 j 의 영역 $D[j]$ 에 포함된다((그림 1) 참고). 주목할바로, 특징 추출 신경망(F)의 각 신경소들이 서로 다른 bias 를 가질 경우, 완전한 Translation invariant의 특성을 갖지 못한다.

2.2 자동 목표물 인식을 위한 동작

형태 인식을 위하여 고안된 가중치 공유 신경망은 입력이 어떤 형태군(Class)에 속하는가를 판별한다. 그러나, 목표물 인식에서는 입력 영상의 어느 위치에 목표물이 존재하는가를 알아내어야 한다. 이를 위하여, 형태 인식을 위해 학습된 신경망을 이용하여 입력 영상 전체를 탐색(scanning)하면서, 목표물의 형태군에 해당하는 출력 신경소에 의하여 형성되는 2차원 배열의 값을 분석함으로써 목표물의 위치를 찾을 수 있다[6]. 즉, 2차원 출력 배열의 각 요소들의 위치는 입력 영상의 각 화소(Pixel)들과 대응하며, 그 값은 입력 영상의 해당 위치에 목표물이 존재할 가능성을 나타낸다. (그림 2)는 이러한 동작을 하는 신경망을 나타내고 있다.



(그림 2) 형태군 구분을 위한 신경망으로 입력 영상을 탐색하여 목표물의 위치를 파악. (x, y) 는 신경망의 입력 영상의 중심 위치를 나타냄.

(Fig. 2) Locating the target by scanning input image with a neural network trained for pattern recognition. (x, y) represents the center of the image of the neural network input.

(그림 2)에서 나타난 신경망의 동작은 다음과 같은 Pseudocode로 기술된다:

```

FOR all pixels  $(x, y)$  in the input image,
  Present the subimage  $R \times C$  centered at  $(x, y)$  to the network;
  Compute the output of all feature maps;
  Compute the output of the feedforward network;
  Save the output of the target class neuron at  $(x, y)$  in output array;
END,
    
```


이 방법에 의하여 구현된 목표물 인식 시스템은 한 입력 위치에 대하여 $(R \times C)$ 번의 동일한 특징 추출 연

산을 수행함으로 대단히 비효율적이다. 특히, 목표물 인식이 실시간 또는 이에 가깝게 이루어져야 할 경우 이 시스템은 활용의 불가능 해진다. 다음 절에서는 이러한 문제를 해결하기 위한 새로운 신경망의 구조를 제안한다.

3. 코릴레이션 신경망의 구조 및 동작

3.1 코릴레이션 신경망의 구조

앞 절에서 논의된 바와 같이, 탐색의 방법을 이용하면 입력 영상의 한 화소는 (RxC-1)번의 불필요한 계산에 관여된다. 한편, RxC sub-image의 위치와는 무관하게 하나의 특징 지도는 동일한 가중치 창을 공유하므로, 단 한번의 계산으로 (RxC-1)번의 불필요한 계산을 하지 않아도 된다는 점에 착안하여 좀더 효율적인 시스템을 구현할 수 있다. 즉, 형태 인식을 위한 가중치 공유 신경망의 가중치 창을 이용하여 전체 입력 영상을 코릴레이션 형태로 단 한번만 연산을 하고, 그 결과는 입력 영상과 동일한 크기의 특징 지도로 만들어진다. 이 방법으로 구현된 신경망 F의 구조가 (그림 3)에 나타나 있다.



(그림 3) 효율적인 특징 추출 신경망(F)의 구조
(Fig. 3) Efficient architecture of feature extraction neural network.

3.2 코릴레이션 동작


일반적인 신경망들처럼 (그림 2)에서 특징 지도의 각 신경소들이 각기 다른 bias를 갖는 경우, 완전한 translation invariance를 얻기 위한 (그림 3)의 구현은

대단히 복잡해진다. 따라서, 각 신경소의 bias들이 동일한 값을 가지도록 하기 위하여 식 (2)는 다음 식 (3)으로 대체되어야 한다.

$$net_j = \sum_{i \in D(j)} w_{ji} O_i + bias_p \tag{3}$$

이 식에서 p 는 신경소 j 가 속한 특징 지도를 나타내는 index이다. 또한, 각 특징 지도의 공통적인 bias 역시 제거될 수 있는데, 이는 가중치 공간의 차원이 하나 줄어들음을 의미한다.

특징 추출 신경망 F의 최종 층과 다층 신경망의 첫 은닉층(Hidden layer) 간의 구조 역시 동일한 방법으로 이루어질 수 있다. 즉, (그림 2)의 첫 은닉층에 속한 신경소의 가중치 벡터를 가중치 공유 창(SWK)으로 보면, 하나의 신경소는 입력 영상과 동일한 크기를 갖는 하나의 2차원 출력을 만들어 내며, 이 2차원 출력은 신경망 C의 특징 지도에 상응한다. 다른 은닉층에서는 하위 은닉층의 출력에 1x1의 공유 가중치 창으로 코릴레이션 연산을 수행하여 2차원 배열의 출력을 얻는다. 이때 사용된 1x1 공유 가중치 창은 (그림 1)의 은닉 신경소가 갖는 가중치 값이다. 최종 2차원 배열의 출력 역시 신경망 C의 최종 은닉층에 형성된 2차원 출력에 대하여 동일한 연산을 통하여 얻어진다. (그림 4)는 이러한 코릴레이션 동작을 수행하는 신경망의 구조를 나타내고 있다.



(그림 4) 코릴레이션 동작의 수행을 위한 다층 신경망의 새로운 구조
(Fig. 4) New architecture of multi-layer neural network for correlational operation

이 방법으로 구현된 목표물 인식 시스템은 Translation invariant하며, 불필요한 모든 연산을 제거할 수 있다. 이러한 코릴레이션 신경망의 동작 원리는 다음과 같은 Pseudocode로 기술된다.

```
FOR all feature maps  $F_j$ ,  $j=1, \dots, f(\text{No. of feature maps})$ 
  Compute the correlation output of all nodes in  $F_j$ ;
END,
FOR all hidden layer maps  $H_k$ ,  $k=1, \dots, h(\text{No. of hidden neurons})$ ,
  Compute the correlation outputs of all neurons in  $H_k$ ;
END,
FOR all neurons in the output image,
  Compute the correlation output value;
  Compute the corresponding intensity value;
END,
```

4. 학습 방법

제 3절에서 기술한 코릴레이션 신경망은 단순히 2차원 구조를 갖는 다층 구조 신경망(2 dimensional multi-layer feedforward neural network)으로 볼 수 있다. 따라서, 오류 역전파 학습 방법을 이용한 기울기 강하(Gradient descent) 방법으로 학습을 시킬 수 있다. 즉, 목표물이 존재하는 위치에 해당되는 출력 배열의 신경소는 그 출력 값이 1이 되도록 학습을 시키는 방법이다. 그러나, 원하는 출력 값이 1인 신경소와 0인 신경소와의 숫자적 대비가 너무나 큰 차이를 보임으로써, 학습의 결과는 목표물을 찾는 방향보다는 목표물이 없음을 알리는 방향으로 수렴하게 된다. 이는 각 형태군들의 구성원들 간에 숫자적 대비가 클 경우, TSE(total-sum-error)를 최소화하는 학습 방법으로는 피할 수 없는 문제점이다.

이러한 문제점을 해결하기 위한 하나의 방법으로 목표물이 포함된 sub-image와 비목표물에서 추출된 sub-image를 같은 숫자만큼 모아서 (그림 1)의 가중치 공유 신경망의 학습을 수행한 후, 학습된 신경망의 가중치 창의 값은 (그림 3)과 (그림 4)의 신경망에 이식된다[6]. 그러나, 이 방법은 대단히 다양한 변화를 갖는 비목표물에 대한 정보를 충분히 보여주지 못하여 많은 오 경보를 발생하였다. 이 문제점은 목표물과

비목표물의 균등한 확률을 가지고 입력 영상으로부터 직접 Random하게 선택하는 방법을 이용하여 해결하였다[8]. 본 연구에서는 이 학습법을 이용하여 off-line으로 (그림 1)의 가중치 공유 신경망을 학습시켜 여기에서 얻어진 가중치 창의 값들을 (그림 3) 및 (그림 4)의 코릴레이션 신경망에 이식하였다.


5. 목표물 인식의 적용

코릴레이션 신경망의 성능을 검증하기 위하여, 주차장의 특정 차량(Chevrolet Blazer)을 인식하는 문제에 이를 적용하였다[8]. 총 30여분 분량의 비디오 테이프로부터 16개의 256×256 (i.e., $M=N=256$) Gray scale 영상을 취하여 시스템의 학습용으로 사용하였다. (그림 5)는 이 학습용 영상들의 예를 나타내고 있으며, 목표물로 지정된 차량은 주차장의 중앙부에서 약 20도 간격으로 회전을 하고있다. 특히 주목할 바는, 학습에 이용된 영상 내의 목표물은 일부의 가리워짐이 없이 완전히 노출 되었다.

가중치 공유 신경망의 입력 영상은 50×80 (i.e., $R=50, C=80$)의 sub-image이다. 미리 설정된 목표물의 중심에서 7×7 의 창 내에 sub-image의 중심이 위치할 수 있도록 목표물의 sub-image를 취하였다. 비목표물 영상은 목표물이 전혀 포함되지 않는 모든 영역으로부터 50×80 의 sub-image를 취하였다. 특정 추출 신경망 F 는 2개의 feature map을 갖는 하나의 층으로 구성되고, 가중치 창은 5×5 (i.e., $p=q=5$)의 크기를 사용하였다. 형태 분류 다층 신경망 C 는 2개의 신경소를 갖는 하나의 은닉 층으로 구성되었다. 2개의 출력 신경소는 각각 목표물과 비목표물의 class를 나타낸다. 시스템은 학습 반복이 4000회 또는 TSSE(total-sum-squared-error)가 0.5보다 작을 경우 학습을 완료하였으며, 학습률(Learning rate)는 0.05로, momentum은 0.8로 설정하였다.

5.1 인식 성능

학습이 완료된 시스템은 주차장을 주행하고 다니는 목표물 차량의 인식에 적용되어 그 성능을 시험하였다. (그림 6)은 시험 영상들 및 각 시험 영상에 대한 시스템의 출력 배열들을 8-bit Gray-scale 영상으로 변환한 예들로서, 출력 영상의 밝은 화소(pixel)는 해당



(그림 5) 시스템의 학습에 이용된 영상의 예들
(Fig. 5) Some images used for training the system.



(그림 6) 시스템의 성능 시험에 이용된 영상들(위)과 출력 영상들(아래)
(Fig. 6) Some images used for testing system performance and corresponding output images.



(그림 7) 후 처리를 이용하여 얻은 목표물 조준점(흰점)을 superimposed 시킨 결과
(Fig. 7) Target-aim-points obtained by a post-processing and superimposed on the input images.



(그림 8) 유사한 차량과의 구별 능력을 보여준 결과의 예
 (Fig. 8) Demonstration of an ability to discriminate a similar vehicle.

위치에 목표물이 존재할 가능성이 높음을 나타낸다. (그림 7)과 8은 출력 영상을 수리적 형태학의 Ultimate erosion[9]을 이용한 후처리를 통하여 목표물 조준점 (TAP: target-aim-point)을 얻은 후, 이 조준점을 입력 영상에 겹쳐 놓았다.

목표물 인식 성능 시험 결과에서 주목할만한 사실은 목표물의 가리워짐에 대한 시스템의 인식 능력이다. 즉, 학습에 사용된 목표물은 가리워짐이 없었음에도 일부가 가리워진 목표물의 인식도 가능함을 보여준 것이다. 또한, (그림 8)의 결과가 보여 주고 있듯이, 목표물과 대단히 유사한 차량(Jeep Cherokee)을 구별해 내는 능력도 보여 주고 있다. 이러한 능력과 더불어 오 경보가 전혀 발생되지 않았다는 점도, 이 시스템의 큰 장점이다.

목표물 인식에 널리 이용되고 있는 코릴레이션 필터 시스템들(예: matched filter[8], SDF[10], MACE[11])을 이용하여 동일한 영상 데이터에 대한 결과와 비교해 보면, 본 논문에서 제안한 코릴레이션 신경망 시스템이 훨씬 우월한 결과를 나타내고 있다. 예를 들면, 코릴레이션 필터 시스템들은 대략 30%의 오 경보를 발생하고 25% 정도의 탐지 실패율을 나타낸 반면, 제안된 시스템은 오 경보 없이 95% 이상의 탐지율을 보여주었다[8].

5.2 처리 속도

인식의 성능과 더불어 간과되어서는 안될 중요한 요소가 인식의 속도이다. 처리 속도의 상대적 비교를 위하여, 먼저 제 2절에 소개된 구조를 갖는 가중치 공유 신경망으로 인식의 속도를 측정하였다. 그 결과 하나의 영상 Frame을 처리하는데 약 460초가 소요되었다. 따라서, 이와 같이 입력 영상 전체를 탐색하는 방

법을 움직이는 목표물에 대한 탐지 및 인식 문제에 적용하기가 매우 곤란하다.

본 연구에서는 두 가지 방법으로 코릴레이션 신경망을 구현하였다. 먼저, 133 MHz DEC Alpha 3000 한대에 구현한 결과, 초당 약 5 frame의 영상을 처리할 수 있었다. 또 하나의 방법으로, 두개의 특징 지도를 두 대의 133 MHz DEC Alpha 3000에 각각 하나씩 구현하여 이들이 병렬로 계산을 수행하도록 하였다. 이렇게 계산된 결과는 신경망 C 부분에 대한 계산에 이용되며, 이 계산 역시 동일한 방법으로 수행되었다. 그 결과, 두 대의 컴퓨터간 데이터 통신을 위한 최적화를 고려하지 않았음에도 불구하고, 초당 약 9 frame 정도를 처리할 수 있었다. 이는 카메라가 영상을 포착하는 시간을 제외할 경우 시간당 약 190 km로 주행하는 목표물의 실시간 추적이 가능함을 의미한다.

6. 결 론

본 논문에서 제안한 코릴레이션 구조 신경망은 목표물의 탐지 및 인식에서 요구되는 translation invariant의 특성과 고속의 처리에 알맞은 구조이다. 특히, 고속 처리를 얻기 위해서는 병렬 처리 시스템이나 분산 컴퓨터 시스템을 이용하여 구현이 가능하다. 인식률의 성능면에서는 일부가 가리워진 목표물도 감지할 수 있으며, 목표물 인식에서 대단히 중요한 요소인 오 경보의 발생이 없었다.

시스템의 폭 넓은 활용을 위하여, 영상 인식의 일반적인 문제로 알려진 조명의 밝기 변화에 대한 문제점의 해결이 강구 되어야 할 것이다. 간단한 방법으로는 전처리를 통하여 얻은 Edge를 이용하는 방법이 있다. 또한, 목표물의 추적에 이용할 경우 추적 대상

의 크기 변화에 대한 문제점 역시 해결 되어야 할 것이다.

더욱 향상된 인식 속도를 얻기 위해서 몇 가지의 방법이 고려 될 수 있다. 첫째로, 목표물의 크기를 작게 설정하여 한 영상이 담을 수 있는 영역을 넓히면 훨씬 더 고속의 목표물 인식이 가능하다. 둘째 방법으로는 병렬 처리 컴퓨터를 이용하여 시스템을 구현하는 방법이다. 기본적으로 시스템의 동일한 층은 모든 계산이 상호 독립적이므로, 병렬 처리 방법의 결과는 대단한 고속 인식을 가능케 할 것이다. 또 하나는 본 연구에서 시도한 것처럼, 다수의 분산된 컴퓨터들을 이용하여 효과적으로 시스템을 구축하는 방법이다 있다. 또한, 필기체 문자의 인식에 적용된 예처럼, 특징 추출 신경망 F에서 down-sampling을하여 특징을 추출하면[7], 특징 추출을 위한 계산량이 크게 줄어들어 좀더 고속의 처리를 기대할 수도 있다.

참 고 문 헌

[1] W. McCulloch and W. Pitts, "A Logical Calculus of the Ideas Immanent in nervous Activity." *Bulletin of Mathematical Biophysics*, Vol. 5, pp. 115-133, 1943.

[2] J. Zurada, *Introduction to Artificial Neural Systems*, West Publishing Company, 1992.

[3] J. Hertz, A. Krogh and R. Palmer, *Introduction to the Theory of Neural Computation*, Addison-Wesley Publishing Company, Redwood City, 1991.

[4] D. E. Rumelhart and J. L. McClelland, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations*, Vol. 1, MIT Press, Cambridge, MA, 1986.

[5] Special Issue on Automatic Target Recognition, *Neural Networks*, Vol. 8, No. 7/8, 1995.

[6] Yonggwon Won and Bae-Ho Lee, "Fuzzy-Morphological-Feature-Based Neural Network for Recognition of Targets in IR Imagery," *Neural Network World*, Vol. 6, No. 4, pp. 485-496, 1996.

[7] Y. le Cun, L. D. Jackel, B. Boser, J. S. Denker, H. P. Graf, I. Guyon, D. Henderson, R. E.

Howard, and W. Hubbard, "Handwritten Digit Recognition: Application of Neural Network Chips and Automatic Learning." *IEEE Communications Magazine*, pp. 41-64, November, 1989.

[8] Y. Won, *Nonlinear Correlation Filter and Morphology Neural Networks for Image Pattern and Automatic Target Recognition*, Ph.D. Dissertation, University of Missouri, 1995.

[9] E. R. Dougherty, *An Introduction to Morphological Image Processing*, SPIE Optical Engineering Press, 1992.

[10] S. R. F. Sims, J. F. Epperson, B. V. K. Vijaya Kumar and A. Mahalanobis, "Synthetic Discriminant Functions Using Relaxed Constraints," in *Proc. SPIE Automatic Object Recognition IV*, Orlando, FL, April, 1993.

[11] A. Mahalanobis, B. V. K. Vijaya Kumar and S. Casasent, "Minimum Average Correlation Filters." *Applied Optics*, Vol. 26, No. 17, pp. 3633-3640, 1987.



원 용 관

1987년 한양대학교, 전자공학과(학사)

1991년 University of Missouri, Electrical and Computer Engineering (석사)

1995년 University of Missouri, Electrical and Computer Engineering (박사)


1987년~1988년 금성통신 근무

1992년~1993년 U.S. Postal Service 지원, 필기체 문자 인식

1994년~1995년 U.S. Air Force 지원, 자동 목표물 인식

1995년~1996년 한국전자통신연구소, 인공지능 연구실

1996년 7월~현재 한국통신, 전송기술연구소
관심분야: Image/Signal Processing, Pattern Recognition, Neural networks, Fuzzy logic, Video-On-Demand, Multimedia 서비스 개발



백 용 창

1985년 경북대학교, 전자공학과 (학사)
1989년 경북대학교, 전자공학과 (석사)
1989년~현재 한국통신, 전송기술연구소 근무
관심분야: 디지털 신호 처리, 멀티미디어 시스템



이 정 수

1980년 한양대학교 전자공학과 졸업(학사)
1982년 한국과학기술원 전기 및 전자공학과 졸업(공학 석사)
1989년 한국과학기술원 전기 및 전자공학과 졸업(공학 박사)
1980년~1991년 금성통신연구소 선임연구원
1992년~1993년 일본 NTT Human Interface연구소
1991년~현재 한국통신 전송기술연구소 VOD 연구팀장
관심분야: 영상통신 서비스, 영상처리, 컴퓨터비전