

論文98-35C-2-9

모듈구조 mART 신경망을 이용한 3차원 표적 피쳐맵의 최적화

(Optimization of 3D Target Feature-Map Using Modular mART Neural Network)

車晉宇*, 柳忠相*, 徐春源*, 金恩洙*

(Jin-Woo Cha, Chung-Sang Ryu, Choon-Weon Suh, and Eun-Soo Kim)

요약

본 논문에서는 3차원 표적 특징 맵을 적응적이고 실시간적으로 자기 조직화시키기 위해 ART 신경망의 적응적 클러스터링 기능과 SOM 신경망의 유사도 결정방법을 상호보완적으로 접목시킨 새로운 mART 신경망을 제안하고 이를 모듈 구조로 구성하였다. 제안된 신경망은 클래스별 모듈화 학습과 클러스터 병합 알고리즘을 적용하여 다중 클래스의 클러스터 발생을 억제하면서도 2차원 왜곡 불변성을 갖는 일반적인 특징 맵들을 효과적으로 조직화시킴으로써 3차원적으로 왜곡된 표적을 인식할 수 있게 해 준다. 제안된 신경망의 성능을 검증하기 위하여 14가지 전투기와 탱크 패턴으로 구성된 데이터베이스를 이용하여 표적 인식 실험을 행하고 그 조직화 특성과 인식결과를 제시하였다.

Abstract

In this paper, we propose a new mART(modified ART) neural network by combining the winner neuron definition method of SOM(self-organizing map) and the real-time adaptive clustering function of ART(adaptive resonance theory) and construct it in a modular structure, for the purpose of organizing the feature maps of three dimensional targets. Being constructed in a modular structure, the proposed modular mART can effectively prevent the clusters from representing multiple classes and can be trained to organize two dimensional distortion invariant feature maps so as to recognize targets with three dimensional distortion. We also present the recognition result and self-organization performance of the proposed modular mART neural network after carried out some experiments with 14 tank and fighter target models.

1. 서론

전 세계적으로 전략 무기 체계가 급속히 발전하여 적의 공격에 대응할 수 있는 시간이 수분 이내로 단축되고 있다. 이러한 현실에 비추어 자연 환경에서 임의의 형태로 움직이는 이동 표적을 실시간으로 식별하고 추적할 수 있는 시스템의 개발은 미사일 유도, 전투기 추적, 레이더 등과 같은 전략 방위 분야에서뿐만 아니

라 로봇 비전, 자동 감시, 항공관제 등 산업 분야의 핵심 기술 연구 차원에서 절실히 요구되고 있다.^[1-3]

이에 따라, 형태학적(syntactic) 패턴인식,^[4-5] 모멘트 불변 방법,^[6-7] 3차원 모델링^[8] 등 다양한 자동 표적 식별 방법이 소개되었으나, 영역화된 상태에서 2차원적인 회전, 크기 변화를 갖는 영상에 대해서만 어느 정도 만족할 만한 인식률을 얻고 있을 뿐, 3차원적인 회전, 크기 변화를 갖는 물체 인식의 경우에는 극히 제한된 환경에 대해서도 그 인식률이 매우 저조하다. 특히, 보는 각도에 따른 영상의 변화로 인해 기존의 상관계수 기반 자동 표적 식별 시스템의 경우 방대한 2차원 투영 영상 데이터베이스가 요구되며, 3차원

* 正會員, 光云大學校 電子工學科

(Dept. of Electronics, Kwangwoon Univ.)

接受日:1997年4月1日, 수정완료일:1998年1月30日

적 변화를 모두 고려한 데이터베이스가 확보된다 해도 그 엄청난 데이터베이스의 구축에 따른 비용과 데이터베이스에의 접근시간 문제로 인해 실용화가 어려운 상태이다. 3차원 모델 기반의 인식 시스템 역시 모델들로부터 3차원적인 모든 왜곡과 환경변화를 고려한 영상을 생성하는데 요구되는 계산량이 방대하여 실용화 관점에서 좋은 방법이 되지 못하고 있다. 그러나, 최근 활발한 연구가 진행되고 있는 신경망의 경우, 적응적인 특성과 함께 자기조직화 기능으로 인해 데이터베이스의 크기를 기존의 상관기반 방법들에 비해 1/100에서 1/500까지 줄일 수 있으며, 신경망 자체의 대규모 병렬처리의 장점을 이용할 수 있어 실시간적 접근도 가능한 것으로 분석되고 있다.^[3,9]

따라서, 본 논문에서는 대표적인 비지도 학습 신경망인 SOM(self-organizing map)의 유사도 판정 방법과 기존 ART(adaptive resonance theory) 신경망의 클러스터 병합 기술을 상호 보완적으로 접목시켜 패턴 구분 능력을 향상시킨 새로운 mART(modified ART) 신경망을 제안하였다. 또한, ART의 문제점으로 지적되고 있는 잉여 클러스터들의 생성을 억제하기 위하여 클래스에 따른 지도학습 개념을 도입하였고, 클래스별 모듈화 구조로 구성함으로써 하드웨어 구현이 용이하고, 인식 대상 표적이 추가되더라도 간단히 새로운 클래스 모듈만의 추가로 확장시킬 수 있도록 하였다. 이러한 접근방법은 제공되는 유사도 임계값에 의해 클러스터 분포 가변이 가능하므로 인식률과 신뢰도의 조정이 가능하고, 비지도 학습의 신경망을 모델로 했기 때문에, 지도학습 신경망에 비해 학습 시간이 짧아 온라인 학습이 가능하다.^[10]

본 논문에서는 14가지 비행기 및 탱크 모형 데이터베이스로부터 추출된 4,476개 2차원 왜곡 불변 특징 데이터를 이용하여 표적 인식 실험을 수행하고 제안한 다중 모듈 구조의 mART 신경망과 기존의 SOM 및 단일구조의 mART 신경망의 성능 비교를 위하여 그 결과를 제시하고자 한다. 2차원 투영 영상으로부터 회전 및 크기 변화등의 왜곡에 영향을 받지 않는 특징을 얻기 위해 단위원 정규화 및 극좌표변환 과정을 거치고 회전방향 투영 벡터를 추출하였다. 제안된 신경망의 자기조직화 특성을 분석하기 위해 3개 표적 클래스에 대해 12,216개의 확장 데이터베이스를 이용하여 실험하고 일정한 인식률을 얻는데 요구되는 클러스터 수를 제시하고자 한다.

II. 자동 표적 인식을 위한 mART 신경망

자동표적 인식(ATR;automatic target recognition) 시스템의 기본적인 구성은 그림 1과 같으며, 시스템의 궁극적인 목표는 각각의 기능들을 실시간적으로 구현하여 변화하는 전술상황에 적응적이 되도록 만드는 것이다.^[11]




그림 1. 기본적인 ATR 시스템 구성
Fig. 1. Basic configuration of ATR system.

ATR에 신경망을 도입함으로써 얻을 수 있는 장점은 대규모 병렬처리로 인한 실시간 처리가 가능하고 자동적인 지식 습득과 연속적인 시스템 개량이 가능하다는 점과 시스템 구현시 어떤 일정한 규칙을 갖도록 표적과 환경변화에 따른 데이터베이스를 얻기 위해 요구되는 엄청난 시간을 어느 정도 절약할 수 있다는 점이다.^[3]

최근 신경망 모델링 방법에 모듈 구조를 이용한 신경망이 발표되고 있으며 학습 속도와 안정성 면에서 개선을 보이고 있고, 패턴 인식 문제에 적용하여 보다 좋은 결과를 보이고 있다.^[11,12] 즉, 복잡한 문제를 여러 개의 간단한 문제로 나누어서 분산시킴으로서 학습시 수렴도가 높고, 모듈 구조의 신경망의 한 개 모듈은 단일 구조 신경망에 비해서 망의 크기가 작으므로 과도 학습(over-training)에 의한 망의 평준화로 인한 망의 기능 상실을 억제할 수 있다. 또한, 각 모듈은 다른 모듈과 독립적으로 병렬적인 학습이 가능하므로 클래스의 증가에 따른 모듈의 추가가 용이하며, 모듈 구조 신경망의 팬아웃이 단일 구조로 설계된 신경망에 비해 훨씬 적으므로 신경망 하드웨어를 구현할 때 매우 유리하다.

본 논문에서 제안한 mART 신경망은 SOM의 승자유전 결정방법과 ART의 유사도 테스트를 통한 클러스터 갱신 및 추가방법을 결합하여 모듈화한 신경망이다. 전체적으로 ART 신경망 학습 알고리즘을 기반으로 하여 이진 가중치의 연결 강도를 실수값으로 확장하고, 유사도 측정을 위해 벡터 사이의 각을 이용했으며, 지속적인 클러스터 생성과 유사 클러스터 생성을 억제하기 위해 학습 단계에서 클러스터를 병합하는

단계를 추가하였다. 또한, 다중 클래스 클러스터 생성 가능성을 줄이고 하드웨어 구현의 용이성을 높이기 위해서 신경망을 클래스별로 모듈화 하였다.

본 신경망의 학습 과정은 크게 두 개의 단계로 이루어진다. 첫 번째는 신경망에 입력 벡터를 입력하되, 지도 학습의 개념을 도입하여 지정된 클래스 모듈만을 활성화시켜 입력한 후 클러스터링하는 과정이고, 두 번째는 기억된 클러스터 중에서 유사한 클러스터들을 병합함으로써 불필요한 메모리의 낭비를 줄이는 과정으로 나뉘어진다. 신경망의 구조는 SOM이나 ART와 마찬가지로 단층으로 이루어져 있으며, 입력 노드가 n 개이며 출력 노드가 M 개일 때, 가중치 행렬은 $M \times n$ 으로 이루어진다. 전체 출력노드들은 각 클래스에서 요구되는 비율로 할당된다. 학습을 마치게 되면, 모든 패턴들을 신경망에 다시 입력하여, 각 출력 노드에서 최대로 발생하는 클래스 분포대로 비율을 주어 매칭 네트워크(matching network)를 구성하고 인식하게 된다. 매칭 네트워크는 클래스의 수가 C 라고 할 때, $C \times M$ 으로 이루어진다. 전체 mART 신경망과 각 모듈의 구조는 그림 2와 같으며, 각 모듈의 구조는 SOM의 구조와 동일하다.




그림 2. mART 신경망의 구조
Fig. 2. Architecture of mART neural network.

이상과 같은 학습과정을 단계별로 나누어 정리하면 다음과 같다.

[단계 1] 경계(vigilance) 임계값 ρ 와 병합(merge) 임계값 σ 를 0과 1 사이의 임의값으로 정하고, 병합 가중치로 사용할 계수 레지스터 $T_C(j=0, \dots, N)$ 를 0으로 설정한다. 또한, n 개의 입력 벡터와 $C \times M$ 개의 상층 출력 노드로 이어지는 $n \times M$ 크기의 가중치 행렬 W 는 식(1)이 만족하도록 초기화한다.

$$\sum_{i=1}^n \sum_{j=1}^M w_{Cij} = \frac{1}{\sqrt{n}} \quad (1)$$

여기에서 C 는 클래스 지표이다.

[단계 2] 입력 패턴의 해당 클래스 모듈만을 활성화시키고, 입력 노드에 단극성(unipolar) 입력 벡터 X_C 를 식 (2)에 의해 정규화하여 입력한다.

$$x'_{Ck} = \frac{x_{Ck}}{\sqrt{\sum_{i=1}^n (x_{Ci})^2}}, \text{ 단, } k=1,2,\dots,n \quad (2)$$

[단계 3] 해당 클래스에서 활성화된 모든 출력 노드들의 매칭 스코어 y_C 를 식(3)에 의해 계산한다.

$$y_{Cj} = \sum_{i=1}^n w_{Cij} x_{Ci} \quad \text{단, } j=1,2,\dots,M \quad (3)$$

이 단계에서, 최대값이 나오는 클러스터 m 은 식(4)에 의해 결정된다.

$$m = \underset{j=1,2,\dots,M}{\operatorname{argmax}} (y_{Cj}) \quad (4)$$

[단계 4] 유사도 판정은 식 (5)에 의해 행해지는데 여기에서 승자 뉴런 벡터와 입력벡터 사이의 각 \angle_m 은 식(6)과 같이 구한다.

$$\left| \frac{\angle_m}{\pi} - 1 \right| > \rho \quad (5)$$

$$\angle_m = \cos^{-1} \left(\frac{\sum_{i=1}^n w_{Cim} x_{Ci}}{\|W_{Cm}\| \cdot \|X_C\|} \right) \quad (6)$$

식 6에서 $\|W_{Cm}\|$ 과 $\|X_C\|$ 는 식(7) 및 식(8)과 같이 정의된다.

$$\|W_{Cm}\| \triangleq \sqrt{\sum_{i=1}^n w_{Cim}^2} \quad (7)$$

$$\|X_C\| \triangleq \sqrt{\sum_{i=1}^n x_{Ci}^2} \quad (8)$$

만약 식(5)의 부등식이 성립하지 않으면 변수 m 에 한 개의 자유 노드 지표를 부여함으로써 새로운 클러스터를 생성하게 된다.

[단계 5] 해당 클러스터와 가장 잘 정합된 패턴의 수를 나타내는 변수 T_{Cm} 을 증가시키고, [단계 4]에서 선택된 노드의 연결강도를 식 (9)에 의해 갱신한다.

$$w_{Cim}(t+1) = \frac{x_{Ci} + T_{Cm} \cdot w_{Cim}(t)}{T_{Cm} + 1} \quad (9)$$

[단계 6] 식 (9)에 의해 갱신된 연결강도를 [단계 2]에서와 마찬가지로 정규화 시킨다.

[단계 7] 이상의 클러스터링 작업이 끝나면, 식

(10)에 의해 해당 클래스 내에 포함된 다른 클러스터들과의 유사도 판정을 행한다.

$$\left| \frac{\angle_{m,n}}{\pi} - 1 \right| > \sigma \quad (10)$$

여기서

$$n = \underset{n=1, \dots, M, n \neq m}{\operatorname{argmin}} \cos^{-1} \left(\frac{\sum_{i=1}^n W_{Cmi} W_{Cni}}{\|W_{Cm}\| \cdot \|W_{Cn}\|} \right) \quad (11)$$

이다. 식 (10)의 판별식이 성립하지 않으면 [단계 2]로 건너 뛰어 새로운 입력을 받게된다.

[단계 8] 두 클러스터 W_{Cm} 과 W_{Cn} 을 합병하여 식 (12)와 같이 W_{Cr} 을 생성하고 이 클러스터의 계수 레지스터 T_{Cr} 을 식 (13)과 같이 설정한다.

$$W_{Cr} = \frac{W_{Cm} T_{Cm} + W_{Cn} T_{Cn}}{T_{Cm} + T_{Cn}} \quad (12)$$

$$T_{Cr} = T_{Cm} + T_{Cn} \quad (13)$$

두 클러스터 W_{Cm} 과 W_{Cn} 을 자유 노드 그룹에 포함시키고 다시 [단계 6]에서 [단계 8]까지의 과정을 반복한다.

[단계 9] [단계 2]에서 [단계 8]까지의 과정을 출력 노드들이 정상상태에 이를 때까지 반복한다.

III. 표적 식별을 위한 특징 추출

표적인식의 경우 3차원 영상이므로, 문자인식과 같은 2차원 패턴인식과는 달리 바라보는 3차원 각도 조합에 따라서 영상이 다양하게 변한다. 그렇기 때문에 가능한 한 데이터베이스의 크기를 줄이기 위해서 환경과 표적 변화에 불변성을 가지는 특징을 찾아야 하는데, 본 논문에서는 위치 및 크기 불변에 대한 것으로서 무게중심을 이용한 단위원 정규화 방법을 이용하고, 회전 및 거울반사 불변에 대해서는 극좌표(polar)변환을 이용한 특징추출 방법을 사용하였다.

입력데이터가 영역화되어 어떤 블록 안에 들어온다고 가정할 경우, 위치 및 크기불변에 대한 특징을 추출하기 위해서는 입력데이터를 일정한 형태로 만들 필요가 있다. 즉, 정규화를 수행하게 되는데, 표적의 폭과 너비를 기준으로 정규화를 할 경우, 추출되는 특징점의 클래스에 따른 직교성이 약하므로 무게중심을 기

준으로 한 단위원 정규화 방법을 이용하였다. 일단, 무게중심을 일정하게 구하기 위해서 입력 패턴의 명암을 일정하게 만들 필요가 있으므로, 입력 패턴을 실루엣(silhouette) 형태로 만든 후 무게중심을 구하고, 이 무게중심을 원점으로 이동시킨 후 영상 전체를 일정한 크기로 정규화시킨다. 다음에 표적의 정규화된 실루엣 영상의 경계(edge)를 추출하고 극좌표변환을 하게 된다. 이와 같이 표적의 실루엣 영상을 사용함으로써 표적영상의 명암변화에 따른 경계선 변화와 배경잡음에 민감하지 않은 특징을 추출할 수 있으며, 또한, 표적의 3차원 회전에 따른 구를 고려할 때, 관찰자 시각 방향의 수직인 구의 최대 단면을 기준으로 전반구와 후반구에 대해 대칭되는 표적의 쌍이 존재하므로, 표적변환의 경우의 수가 1/2로 감소된다.

단위원 정규화된 표적영상의 반지름이 R 이라고 할 때, $R \times 2\pi R$ 크기의 극좌표변환 영상을 얻게 되고, 이 영상을 원주방향으로 투영(projection) 시키면 투영 히스토그램을 얻을 수 있다. 이러한 과정을 거치므로써 임의의 기준 표적영상의 크기, 회전 및 거울반사된 변형영상들에 대해서 불변성을 얻게 된다. 그러나, 극좌표 변환한 패턴의 원주방향 투영 히스토그램 함수 $PHF(r)$ 은 중심축(원점)에 가까울수록 더 많은 비트가 할당되어 이 부분의 미세한 변화에도 $PHF(r)$ 의 변화 폭이 커지게 되므로, 본 논문에서는 식(14)와 같이 최외각 반지름 R 에 을 기준으로 하여 반지름 r 에 비례하도록 재구성하였다.

$$PHF(r)_{new} = PHF(r)_{old} \times \frac{r}{R} \quad \text{단, } 0 < r < R \quad (14)$$

이상과 같은 절차를 거쳐도 아직도 특징 맵은 영상 변화에 민감한 특성을 보이므로, 극좌표 영상에서 5×5 크기의 평균 필터(average filter)를 사용하여, 표적의 2차원 회전변화에 따라 발생하는 회전각 양자화 에러에 적응적인 특징을 얻을 수 있다. 그림 3은 이러한 관점에서 설계된 특징추출 방법의 처리과정이며, 그림 4는 이 과정을 A-10 전투기 표적 영상에 적용시킨 결과를 나타낸 것이다. 그림 4에서 상단 왼쪽 그림이 입력 패턴이고 상단 왼쪽 두 번째 그림이 실루엣 영상으로부터 무게중심과 최대 반경을 구한 것이다. 상단 오른쪽 두 번째 그림은 단위원 정규화된 패턴이고 상단 오른쪽 그림은 실루엣의 경계선을 추출한 패턴이다. 중단의 그림은 경계선 입력 패턴을 극좌표 변환하고

원주방향 투영 히스토그램을 구한 후 반지름비로 평탄화 시킨 $PHF(r)$ 을 나타낸 것이고 하단 그림은 상단의 극좌표 변환 패턴을 저주파 통과 필터를 거친 후 구한 $PHF(r)$ 을 나타낸 것이다. 본 논문에서는 이 히스토그램을 신경회로망의 입력 벡터로 사용하였다.




그림 3. 제안된 특징추출방법의 처리과정
Fig. 3. Processing procedure of the proposed feature extraction method.




그림 4. 사용된 특징추출방법을 적용한 예 (A-10)
Fig. 4. Example of applying the used feature extraction method to A-10.

그림 5는 특징추출방법을 위치, 크기, 회전변환, 거울반사된 다양한 Tornado 전투기 표적 영상들에 적용시킨 결과를 보여주고 있는데, 그림에서 보듯이 다양한 2차원 왜곡에 불변한 특징벡터가 추출됨을 확인할 수 있다.


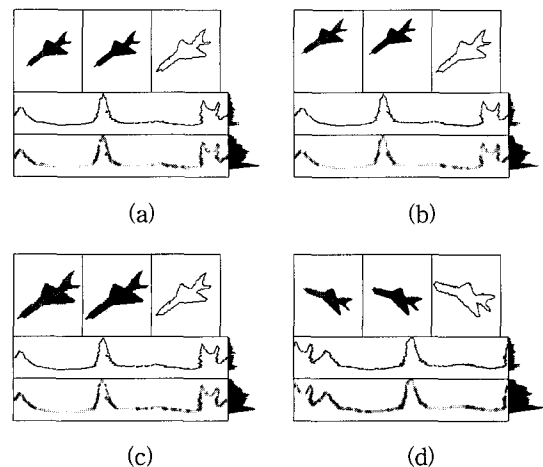


그림 5. 제안된 특징추출 방법의 불변성
(a) 기본 영상 (b) 이동된 영상 (c) 크기변환된 영상 (d) 45° 회전된 영상 (e) 72° 회전된 영상 (f) 반사된 영상
Fig. 5. Invariants of the proposed feature extraction method.
(a) Original image. (b) Translated image. (c) Scaled image. (d) 45° rotated image. (e) 72° rotated image. (f) Mirrored image.

IV. 실험 및 결과 분석

본 논문에서는 실험을 위해 전투기 9종, 탱크 5종의 3차원 모델을 다양한 시각(viewing angle)으로부터 2차원적으로 투영시킨 256 그레이 레벨(grey level)의 128×128 크기의 영상을 사용하였다. 표적 데이터베이스는 14기종 4,476개 패턴으로 구성된 일반 데이터베이스와 자기조직화에 의한 데이터베이스 축소 효과를 분석하기 위해 준비한 3개 클래스 12,216개 패턴으로 구성되어 있다. 이 데이터베이스의 구성 내용을 표 1에 보였는데, 탱크의 데이터베이스 크기가 전투기에 비하여 작은 이유는 전투기의 변화 범위는 전방향(all-side)인데 비해, 지상의 탱크는 상반구로 제한되기 때문이다. 그림 6에는 이해를 돕기 위해 F-16 전투기 데이터베이스의 일부를 보였다.




그림 6. 표적 데이터베이스의 예(F-16)
Fig. 6. Example of target database(F-16).

표 1. 표적 데이터베이스의 구성

Table 1. Construction of target database.

기종	기본 패턴 수	확장 패턴 수
A-10	343	5412
F-15	376	
F-16	451	
F-18	415	
Mig-21	430	
Mig-29	387	
Mirage 2000	353	
Su-27	464	
Tornado	334	
BMP-2	179	
M-203	151	4236
SAM Launcher	171	
T-72	214	2568
ZSU-23-4	208	
TOTAL	4476	12216

본 논문에서 제안한 모듈구조 mART의 신경망의 성능을 시험하기 위하여, 제시한 특징추출 방법을 사용하였으며, mART에서 모듈특성을 제외시킨 단일구조 mART와 동일 조건의 인식 결과를 비교하였으며 참고로 Kohonen의 SOM 신경망에 의한 결과도 함께 제시하였다. mART 신경망, 단일구조 mART신경망 모두 동일한 조건으로 주기 위해 입력벡터 64에 최대 출력 클러스터 600으로 동일한 망을 구성하였으며 4,476개의 일반 데이터베이스를 이용하여 학습 및 인식실험을 수행하였다.

표 2에서 보이듯이, 기존의 SOM을 이용할 경우에는 예상했던 바와 같이 클러스터 분류 기준이 없으므로, 설정된 망의 크기에 상관없이 클러스터 수가 25개로 고정되고 다중 클래스 클러스터가 발생되어 인식이 32.87%로 저조하게 나타났다. 반면, SOM과 ART를 결합한 mART의 경우 LVQ(learning vector quantization)와 비슷한 클래스 분류 기준을 가지므로 인식이 51.47%로 나타났고, 이를 모듈화하여 클래스내 클러스터 병합까지 시도한 경우 62.98%로 인식이 향상됨을 볼 수 있었다. 모듈 특성을 제외한 단일구조 mART의 경우는 여전히 다중 클래스 클러스터 생성 가능성을 보유하고 있기 때문에, 모듈특성을 갖는 mART에 비해 인식이 상대적으로 저조함을 알 수 있다. 그리고, 전투기에 비해서 탱크의 인식이

비교적 높게 나오는데, 이것은 데이터베이스와 관련하여 밝혔듯이, 입력 영상 변화 범위가 전 방향(whole direction)인 전투기와는 달리 탱크는 지표면에 고정되어 있어서 그 범위가 반구로 제한되기 때문에 나타난 결과로 분석된다. 클래스간에 구분성이 높은 좋은 특징추출 방법이라면, 굳이 모듈 특성을 부가하지 않더라도 높은 인식률을 보일 수 있지만, 모듈 특성을 부가함으로써 특징추출방법의 클래스 구분성이 모호하거나 그렇지 않은 경우에 대해서도, 인식 성능을 향상시킬 수 있는 것으로 분석된다.

표 2. mART, 단일구조 mART, SOM의 정 인식을 비교 (%)

Table 2. Comparison of recognition rate of mART, non-modular mART, and SOM (%).

신경망	다중모듈 mART	단일구조 mART	SOM
생성 클러스터 수	324	327	25
A-10	67.64	67.64	60.93
F-15	32.18	30.05	7.45
F-16	54.32	51.66	25.06
F-18	56.39	58.80	0.00
Mig-21	74.42	65.35	59.53
Mig-29	41.34	14.47	4.39
Mirage 2000	61.19	41.08	15.58
Su-27	63.15	47.20	32.97
Tornado	50.90	26.95	22.75
BMP-2	81.01	69.83	27.37
M-203	72.85	60.93	47.68
SAM Launcher	61.99	50.88	22.81
T-72	71.50	46.73	50.47
ZSU-23-4	92.79	88.94	83.17
평 균	62.98	51.47	32.87

그림 7은 클러스터 수에 따른 mART, 단일구조 mART, SOM의 인식을 나타내는 그래프이다. 그림에서 가장 위의 그래프가 모듈구조의 mART에 의한 것이고 아래 그래프는 단일구조 mART에 의한 것이다. 또한, SOM의 경우 클러스터의 증가도 없고 인식률의 증가도 거의 없으므로 "o" 으로 표현하였다. 이 그래프를 통해 학습시에 제공되는 유사도 임계치(ρ)에 따라 생성되는 클러스터 수와 인식이 달라짐을 확인할 수 있고, 클러스터 변화에 따라서도 mART가

비교된 신경망들에 비해 높은 인식률을 얻고 있으며, SOM과 동일한 25개 클러스터 수에서 단일구조 mART는 SOM 보다 현저히 낮은 인식률을 보이는 반면 모듈구조 mART의 경우 SOM에 비해 인식률이 향상되고 있음을 볼 수 있다.

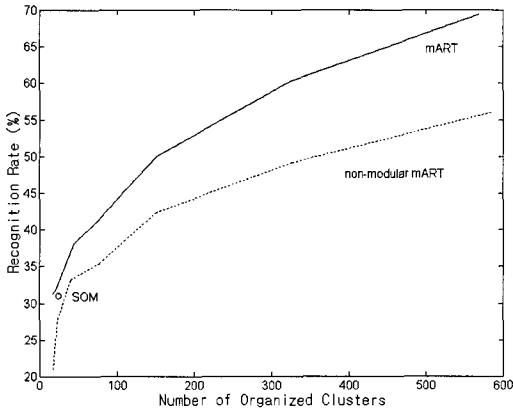


그림 7. 클러스터 수에 따른 mART, 단일구조 mART, SOM의 인식률 비교
 Fig. 7. Comparison of recognition rate of mART, non-modular mART and SOM with cluster number.

기존의 일반적인 정합 필터 개념에서 임의의 두 패턴간의 상호 상관치가 어느 한 패턴의 자기상관치의 $1/\sqrt{2}$ 배 이상이어야 동일 패턴으로 간주한다. 이 값은 빛의 세기 관점이나 전력 관점에서는 $1/2$ 이 되는 값이고 데시벨 관점에서는 3dB 하한값을 나타내는 것이다. 이 관점에서 조사해 보면, 대칭성이 없는 2차원 평면 패턴의 경우 패턴에 따라 $4\sim 5^\circ$ 이내의 회전에서만 동일한 패턴으로 분류된다. 이를 3차원으로 확장시켜 3차원 회전에서 5° ($\pi/45$ rad)회전마다 구표면에 위치를 정하게 되면, x, y, z의 3차원 축에서 비대칭인 축이 2개이상인 물체에 대해서 2,500개 정도의 경우의 수가 나온다. 그리고 각각의 위치에 대하여 4° 씩 90개의 평면 회전이 존재하므로, 다른 패턴들과 구분하기 위해 요구되는 한 패턴의 데이터베이스 구성 요소 수는 식(15)에 의해 총 225,000개에 이른다.

$$\left| \frac{2\pi}{\theta} \left\{ \frac{2\pi}{\theta} + 2 \left[\sum_{k=1}^{22} \frac{2\pi \sin(\theta k)}{\theta} \right] \right\} \right|_{\theta = \pi/45} \cong 225,000 \quad (15)$$

식(16)의 처음에 나오는 $2\pi/\theta$ 는 평면상의 회전에 따른 경우의 수이고 종괄호 내의 $2\pi/\theta$ 는 기준 대권을 따라 분할되는 경우의 수이다. 또한, 합으로 표시되는

수식은 기준 대권으로부터 양쪽 극(pole)으로 향하는 동안에 호의 크기가 작아지므로 이를 반영한 경우의 수를 나타내는 것으로 여기에서 k는 양쪽 극에서 기준대권까지의 각을 $\theta = \pi/45(4^\circ)$ 간격으로 분할하였을 경우의 각 영역을 나타내는 지수이다. 물론 이것은 동일한 가지거리의 표적에 대해서 만이므로 3차원 상에서 회전된 표적을 시각 불변으로 인식하기 위해서는 엄청난 크기의 데이터 베이스가 요구된다. 본 논문에서는 이러한 문제점들을 해결하기 위해서, 실제 영상을 이용하지 않고 특징벡터를 추출함으로써 입력벡터 자체의 크기를 줄였고, 단위원 정규화와 2차원 회전 불변 특징을 이용함으로써 요구 데이터 수를 1/90로 줄였고 또한, 실루엣 처리와 회전각 투영의 거울반사(mirroring) 불변 특성에 의해 다시 1/2 축소 효과를 얻었다. 마지막으로 신경망 자체의 통계적이고 적응적인 자기조직화 특성을 이용하여 데이터베이스를 최적화 시킴으로서, 95% 이상의 인식률을 얻는데 한 클래스당 약 600여개 클러스터로 조직화될 수 있음을 보였다.




그림 8. 데이터베이스 축소 효과
 Fig. 8. Downsizing effect of Database.

데이터베이스 감소 효과를 간단히 분석하기 위해, F-16, Mirage 2000, T-72기 등 3가지 표적의 1,018개 일반 데이터베이스와 좀 더 각도 편차를 줄여서 추출한 12,216개의 확장 데이터베이스를 이용하여 발생 클러스터 수에 따른 인식률을 조사하였다. 각각의 데이터베이스에 대해서, 동일한 인식률을 얻었을 때 요구되는 데이터베이스 비율을 그림 8에 나타내었다.

그림 8을 보면, 1,018개의 일반 데이터베이스의 경우 95%이상의 인식률을 위해서는 전체 데이터베이스 크기의 27%(272 클러스터)가 필요한데 비해서,

12,216개의 데이터베이스의 경우 8%(993 클러스터)정도의 데이터베이스로 동일한 인식률을 얻을 수 있었다. 이는 클래스를 구분하기 위해서 기본적으로 저장해야 할 클러스터 수가 있기 때문에 일반 데이터베이스로 학습시에는 요구되는 클러스터 비율이 높은 것으로 분석된다. 각각의 표적에 대해서 요구되는 클러스터 수를 살펴보면 일반 데이터베이스의 경우 평균 90개의 클러스터, 확장 데이터베이스에 대해서는 평균 330개의 클러스터가 필요할 따름이다. 그림 8의 결과로 미루어 보아 클래스당 225,000개 이상의 데이터베이스로 학습할 경우에는 상당한 데이터베이스 축소 효과가 있을 것으로 예상된다.

V. 결 론

본 논문에서는 3차원적 회전 및 위치 크기 변화에 불변한 표적 인식을 위하여 SOM 신경망의 승자누런 결정방법과 ART 신경망의 적응적인 실시간 클러스터 갱신 및 클러스터 생성방법을 결합한 새로운 mART 신경망을 제안하였다. 제안된 신경망은 온라인 학습이 가능하고 모듈 구조로 구성되어 다중 클래스의 데이터가 하나의 클러스터에 집중 할당되는 현상을 막을 수 있다. 14개 표적 클래스 식별 실험 결과 동일한 특징을 사용하였을 경우 단일 구조 mART 신경망은 51.47%의 정인식률을 보인 반면 모듈 구조로 확장하였을 때 단일 mART 신경망과 비슷한 수의 클러스터가 생성되도록 유사도 레벨을 조정하였을 경우에도, 62.98%의 정인식률을 나타내어 구현 가능성뿐만 아니라 인식률도 크게 향상됨을 알 수 있었다. 참고적으로 기존의 Kohonen 신경망의 인식 결과와도 비교하였는데 클러스터 수가 25개로 동일할 경우에 단일 구조 mART는 거의 인식이 어려운 상황이었으나 모듈 구조로 구성한 경우에는 정인식률 평균 32.87%의 SOM에 비해 평균 34.13%로 근소한 향상을 보여주었다.

제안된 모듈 구조 mART 신경망의 자기조직화 성능을 검증하기 위한 3개 표적 식별 실험에서 95%의 인식률을 얻었을 때, 1,018개 패턴의 기본 데이터베이스에 대해서는 27%인 272개 클러스터가 생성되었고, 12,216개 패턴의 확장 데이터베이스에 대해서는 8%에 해당하는 993개만이 생성되어 제안된 신경망의 자기조직화 능력이 매우 우수함을 보였다.

이와 같은 결과들을 통해, 3차원 표적의 경우 실제

로 같은 표적이라 하더라도 전투기의 가변익이나 탱크의 포탑 등의 움직임에 따른 다양한 변형이 존재하여 복잡한 특징 추출 방법이 요구되기는 하겠지만, 제안된 다중 모듈 구조의 mART 신경망이 자동 표적 식별 장치, 자동 제품 분류 시스템 등의 최종적인 특징 맵 관리 및 식별 부분에 폭넓게 적용될 수 있을 것으로 기대된다.

참 고 문 헌

- [1] Bir Bhanu, "Automatic Target Recognition : State of the Art Survey", IEEE Transactions on Aerospace and Electronic systems, vol. AES-22, no. 4, July 1986.
- [2] Eun-Soo Kim, *Real-Time Target Recognition System*, ADD Research Report, Dec. 1996.
- [3] Michael W. Roth, "Survey of Neural Network Technology for Automatic Target Recognition", IEEE Transactions on Neural Networks, vol. 1, no. 1, March 1990.
- [4] K. C. You and K. S. Fu, "Distorted shape recognition using attributed grammars and error-correcting techniques", Comput. Graphics Image Process. 13, 1-16, 1980.
- [5] K. S. Fu, *Syntactic Pattern Recognition and Applications*, Prentice-Hall, New Jersey, 1982.
- [6] M. K. Hu, "Visual pattern recognition by moment invariants", IRE Trans. Information Theory IT-8, 179-187, 1962.
- [7] S. A. Dudani, K. J. Breeding and R. B. McGhee, "Aircraft identification by moment invariants", IEEE Trans. Comput. C-26, 39-46, 1977.
- [8] R. A. Brooks, "Model-based three-dimensional interpretations of two-dimensional images", IEEE Trans. Pattern Anal. Mach. Intell. PAMI-5, 140-150, 1983.
- [9] Eun-Soo Kim, Chung-Sang Ryu, "Target Feature Map Data Base System

- based on RBF SOM”, Proc. of Joint Conference & Exhibition on Artificial Intelligence, Neural Network, and Fuzzy Systems, Apr. 1995.
- [10] Eun-Soo Kim, Jin-Woo Cha, Chung-Sang Ryu, “Three-Dimensional Target Recognition using mART Neural Networks”, Proceeding of SPIE, vol. 3069, Apr. 1997.
- [11] Alexander Waibel, Hidefumi Sawai, Kiyohiro Shikano, “Modularity and Scaling in Large Phonemic Neural Networks”, IEEE Trans. on Acoustic, Speech, and Signal Processing, vol. 37, no 12, pp. 1888-1896, 1989.
- [12] Robert A Jacobs, Michael I. Jordan, “A Competitive Modular Connectionist Architecture”, NISP 3, 1991.
- [13] Lilly Spirkovska, “Three-Dimensional Object Recognition using similar Triangles and Decision Trees”, Pattern Recognition, vol. 26, no. 5, pp. 727-732, 1993.
- [14] S. O. Belkasim, M. Shridhar, M. Ahmadi, “Pattern Recognition with Moment Invariants: A Comparative Study and New Results”, Pattern Recognition, vol. 24, no. 12, pp. 1117-1138, 1991.

저 자 소 개

車 晉 宇(正會員) 第 34 券 D編 第 7 號 參照,
 현재 금성정보통신연구소 연구원, 주
 관심 분야는 신경망, 비전 시스템 등
 임

柳 忠 相(正會員)
 1997년 광운대학교 대학원 전자공학과 박사학위 취득
 (논문제목: 광상관기와 모듈화 신경회로망을 이용한 이
 동표적 식별 및 추적 시스템), 현재 서울산업대학교 전자
 계산소 근무

徐 春 源(正會員) 第 31 券 A編 第 6 號 參照,
 현재 광운대학교 전산원 강사

金 恩 洙(正會員) 第 33 券 D編 第 7 號 參照,
 현재 광운대학교 전자공학부 교수