

論文96-33B-5-12

순환 배열된 학습 데이터의 이 단계 학습에 의한 ART2 의 성능 향상

(Performance Improvement of ART2 by Two-Stage Learning on Circularly Ordered Learning Sequence)

朴榮泰 *

(Young Tae Park)

요 약

적응공명이론 (Adaptive Resonance Theory: ART2) 은 새로운 패턴과 ART2 의 내부 Template 패턴과의 정합률이 높지 않을 경우 새로운 Template 패턴을 자동으로 생성할 수 있는 기능과 과거에 학습된 정보를 잊어 버리지 않고 새로운 정보에 신속히 대응할 수 있는 적응학습 기능을 가진 신경망분류기의 훈련과정으로서 무지도학습에 의한 Template 정합에 기초를 두고 있다. 본 논문에서는 훈련 데이터의 Template 형성을 위한 무지도학습과 훈련 데이터의 부류 정보에 의한 Template 의 세부 교정을 위한 지도학습으로 구성된 새로운 이 단계 학습 알고리즘을 제안한다. 일 단계로 무지도학습에 의해 형성된 초기 Template 패턴의 부류 정보에 의해 ART2 의 출력 노드의 부류를 결정하고 이 단계로 지도학습에 의해 훈련 데이터와 같은 부류에 속하면서 정합률이 가장 높은 Template 패턴을 훈련시킴으로써 인식률을 향상시킬 수 있다. 또한 훈련데이터의 순환 배열에 의해 ART2 의 분류능력을 극대화 시킨다. 제안된 알고리즘을 2545개로 구성된 실제의 적외선 영상에 적용시켜 실험한 결과, 제안된 이 단계 학습에 의한 ART2 는 신경망의 크기와 인식률을 측정 방법에 관계 없이 원래의 ART2 보다 우수한 인식 능력을 발휘했으며 이 단계 학습과정에 의한 ART2 의 설계가 효과적임을 보였다.

Abstract

Adaptive Resonance Theory (ART2), characterized by its built-in mechanism of handling the stability-plasticity switching and by the adaptive learning without forgetting informations learned in the past, is based on an unsupervised template matching. We propose an improved two-stage learning algorithm for ART2: the original unsupervised learning followed by a new supervised learning. Each of the output nodes, after the unsupervised learning, is labeled according to the category informations of the feature vectors associated with the node. In the supervised learning, each feature vector is used to reinforce the template pattern associated with the target output node belonging to the same category as the feature vector. Another modification is a circular ordering of the training sequence to prevent some dominant classes from exhausting a finite number of template patterns in ART2 inefficiently. Experimental results on a set of 2545 FLIR images show that the ART2 trained by the two-stage learning algorithm yields better accuracy than the original ART2, regardless of the size of the network and the methods of evaluating the accuracy. This improvement shows the effectiveness of the two-stage learning process.

I. 서 론

* 正會員, 慶熙大學校 電子工學科

(Department of Electronics Engineering Kyung Hee University)

接受日字: 1995年8月4日, 수정완료일: 1996年5月2日

Carpenter 와 Grossberg 에 의해 제안된 적응공명이론 (Adaptive Resonance Theory: ART2)^{[1][2]} 은 새로운 패턴과 ART2 의 내부 Template 패턴과의

정합률이 높지 않을 경우 새로운 Template 패턴을 자동으로 생성할 수 있는 기능과 과거에 학습된 정보를 잊어 버리지 않고 새로운 정보에 신속히 대응할 수 있는 적응학습 기능을 가진 신경망분류기의 훈련과정으로서 무지도학습(Unsupervised learning)에 의한 Template 정합에 기초를 두고 있다.

ART2는 입력 데이터에 따라 그 내부 구조를 자기 구성시키므로 훈련 데이터가 충분하지 않을 경우에도 주어진 데이터의 분포를 적절히 균사시킬수 있다. 다층 퍼셉트론의 훈련과정으로 널리 알려진 오류역전파 알고리즘^[3]과 달리 ART2는 학습된 정보를 잊지 않고 새로운 데이터에 대한 학습만으로 새로운 정보를 수용할 수 있는 장점을 가지고 있다. 또한 입력 출력 훈련 데이터를 반복적으로 사용하지 않고 ART2의 균사 능력을 발휘하는 자기 구성 특성을 가지므로 학습속도가 월등히 빠르다. 따라서 훈련 데이터의 크기가 작을 경우 발생하는 분류기의 바이어스의 크기도 줄일 수 있다. 새로운 데이터에 따른 신속한 적응학습은 Stable mode 와 Plastic mode 에 의해 이루어 진다. 입력 패턴과 ART2 내부의 층 사이의 연결 가중치의 형태로 존재하는 Template 패턴과의 정합률이 높을 경우 ART2는 Stable mode 로 동작하며 Template 패턴이 입력 패턴의 형태를 모방하는 방향으로 강화된다. 정합률이 낮을 경우 ART2는 Plastic mode 로 동작 하며 입력 패턴을 정합할수 있는 새로운 Template 패턴이 자동으로 형성된다. 즉, 인식 대상의 종류가 추가 되거나 입력 패턴이 과거에 학습된 패턴과 판이하게 다를 경우에 이를 자동으로 감지할 수 있다. Stable mode 와 Plastic mode 는 정합률과 Vigilance 파라메타^[2]를 비교하여 선택된다. ART2 내부의 Template 패턴들은 학습과정에서 급격히 변화하지 않으므로 LTM(Long Term Memory) 이라 불리며 출력층과 입력층 사이의 Top-down weight 와 Bottom-up weight 의 형태로 존재한다.

본 논문에서는 훈련 데이터의 부류 정보를 이용한 지도학습과 훈련 데이터의 순환 배열에 의해 ART2의 분류능력을 향상시킬 수 있는 이 단계로 구성된 새로운 훈련 알고리즘을 제안한다. 이 단계 학습 알고리즘은 무지도학습에 의한 Template 의 초기 형성과 지도학습에 의한 Template 의 세부 조정으로 구성된다. 무지도학습의 목적은 입력 패턴들의 균집화 특성에 따라 패턴의 분포를 균사화 시킬 수 있는 최소의 대표

패턴을 형성하는데 있으며 지도학습의 목적은 무지도 학습에 의해 형성된 Template 패턴 중 오인식된 입력 패턴과 관련된 Template 패턴을 수정하여 인식률을 향상시키는 데 있다.

본 논문의 구성은 다음과 같다. 2장에서 무지도학습에 의한 ART2의 학습과정을 요약하고, 3장에서 이 단계로 구성된 새로운 학습방식을 제시한다. 4장에서 원래의 ART2 와 제안된 방식에 의해 훈련된 ART2를 8 가지 종류의 적외선 군집영상에 적용시켜 인식능력을 비교하고 제안된 방식에 의해 ART2의 인식률을 대폭 향상시킬 수 있음을 보인다.

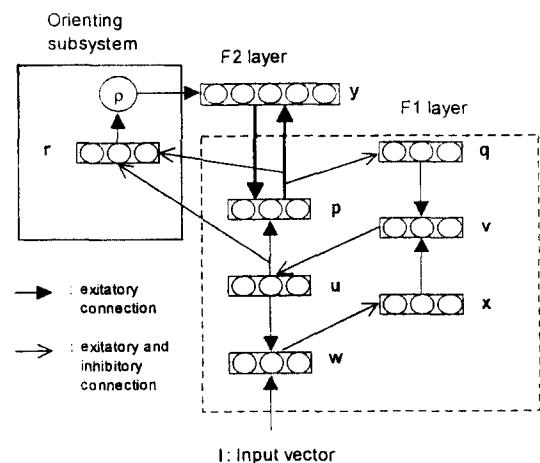


그림 1. ART2의 기본구조

Fig. 1. Basic architecture of ART2.

II. ART2의 기본구조

그림 1에서와 같이 ART2의 기본구조는 6개의 층으로 이루어진 입력층 F_1 , 출력층 F_2 와 Stable mode 및 Plastic mode 를 절환하는 부시스템으로 구성된다. 입력층 F_1 의 6개 층은 ART2 시스템의 모의실험을 위한 균사해^[2]에 의해 다음과 같이 동작한다.

$$w_i = I_i + a u_i \quad (1)$$

$$x_i = \frac{w_i}{\|w\|} \quad (2)$$

$$v_i = f(x_i) + b f(q_i) \quad (3)$$

$$u_i = \frac{v_i}{\|v\|} \quad (4)$$

$$p_i = u_i + \sum_j g(y_j) x_{ij} \quad (5)$$

$$q_i = \frac{p_i}{\|p\|} \quad (6)$$

I 는 입력 벡터, z_{ij} 는 j 번째 출력 노드와 i 번째 p 층 노드 사이의 top-down 연결가중치를 나타낸다. 궤환 파라메터 a 와 b 는 입력 패턴의 학습률을 정의하며 이들 값이 작을수록 Template 패턴이 입력 패턴에 의해 급격히 변화한다. $f(x)$ 는 다음과 같은 단계적 선형식에 의해 입력 패턴의 대비도를 신장시킨다.

$$f(x) = \begin{cases} 0, & 0 \leq x \leq \theta \\ x, & x > \theta \end{cases} \quad (7)$$

x, u, q 등의 입력층은 각각 w, v, p 층의 정규화된 출력을 생성한다. 입력층 u 의 출력은 입력 패턴이 Top-down 패턴에 의해 부분적으로 수정된 패턴을 생성하며 입력층 q 의 출력은 Template 패턴이 Bottom-up 입력 패턴에 의해 부분적으로 수정된 패턴을 생성한다. 출력층 F_2 에서는 최대의 출력을 가진 한개의 Winning node 가 선택된다.

$$g(y_j) = \begin{cases} d, & T_j = \max T_k \\ 0, & \text{Otherwise.} \end{cases} \quad (8)$$

T_j 는 j 번째 bottom-up 입력 패턴으로서

$$T_j = \sum_i p_i z_{ji} \quad (9)$$

로 주어진다. z_{ji} 는 i 번째 p 층 노드와 j 번째 출력 노드사이의 bottom-up 연결가중치를 나타낸다. r 층의 출력은

$$r_i = \frac{u_i + c p_i}{\|u\| + \|cp\|} \quad (10)$$

로 주어지며 부시스템에서는 u 층의 입력패턴과 p 층의 Template 패턴과의 정합률 $\|r\|$ 과 Vigilance 파라메터 ρ 를 비교하여 Stable mode 와 Plastic mode 를 자동 절환한다. $\|r\| > \rho$ 이면 입력 패턴이 J 번째 Winning node 와 관련된 Template 패턴과 정합이 이루어 졌음을 의미하며 J 번째 Template 는 다음과 같은 LTM 식에 의해 변형된다.

$$z_{Ji} = z_{ij} = \frac{u_i}{1-d} \quad (11)$$

$\|r\| < \rho$ 일 경우 입력 패턴과 ART2 의 Template 패턴들과의 정합이 이루어 지지 않았음을 의미하며 새로운 Template 가 LTM 식에 의해 형성된다.

무지도학습에 의한 ART2 의 훈련과정은 다음과 같다.

```

procedure Unsupervised_ART2
{
    initialize all layer outputs to zero;
    resonated = False;
    until (resonated) {
        counter = 1;
        while (counter = 1) {
            step1: apply an input pattern to the input layer;
            step2: until (the sublayer output values are stabilized)
                    propagate to the six sublayers;
            step3: calculate the r sublayer outputs using Eq. (10);
            step4: if ( \|r\| < \rho ) {
                    mark any active node as ineligible for
                    competition;
                    counter = 1;
                    go to step2;
                }
            step5: else if (counter = 1) {
                    counter = counter + 1;
                    propagate to the p sublayer using Eq. (5);
                    propagate to the F2 layer using Eq. (8);
                    set only the winning F2 node to nonzero
                    value;
                    propagate to the p sublayer using Eq. (5);
                    propagate to the q sublayer using Eq. (6);
                    go to step 3:
                }
            step6: else if (counter > 1) {
                    modify the bottom-up weights using Eq.
                    (11);
                    modify the top-down weights using Eq.
                    (11);
                    resonated = True;
                }
            }
        }
}

```

III. 순환 배열된 데이터의 지도학습에 의한 ART2 의 이단계 훈련

훈련 데이터의 순환 배열

무지도학습에 의한 ART2 의 훈련은 특징공간에서 입력 패턴들의 군집화 특성을 소수의 Template 패턴으로 표현하는데 그 목적이 있다. 입력 패턴의 무작위 추출에 의한 훈련은 특정 부류에 속하는 Template 패턴의 수를 지나치게 많이 형성하여 비효율적인 ART2 구조를 생성시킬 우려가 있다. 다음과 같은 순환 배열에 의하여 각 부류에 속하는 Template 의 수를 동일

하게 초기화 시킬 수 있다. 현재의 훈련에 사용된 입력 훈련 패턴이 ω_j 에 속할 경우 다음의 패턴은 ω_{j+1} 에 속하는 패턴 중에서 선택하고 이와 같은 과정을 반복하는 훈련 데이터의 순환 배열에 의해 모든 부류에 동일한 수의 초기 Template 패턴을 할당함으로써 훈련된 ART2의 성능이 특정 부류에 편중되는 것을 방지할 수 있다. 이와 같이 형성된 Template 패턴은 이 단계의 지도학습에 의해 조정되어 훈련 데이터의 분포 특성을 근사화시키면서 동시에 Template의 수를 줄일 수 있다.

지도학습에 의한 이 단계 훈련

훈련 데이터의 부류 정보가 주어질 경우 지도학습에 의해 분류기의 성능을 향상시킬 수 있다. 무지도학습에 의해 훈련된 ART2의 각 출력 노드의 부류는 그 노드에 속하는 입력 패턴의 부류 정보에 의해 결정된다. 이 단계의 지도학습에서는 입력 패턴과 각 출력 노드의 부류 정보를 이용해 ART2 내부의 Template 패턴을 재훈련함으로써 분류 능력을 극대화시킬 수 있다. 즉, 지도학습에서는 각 입력패턴과 같은 부류에 속하는 Template 패턴 중에서 최대의 정합률을 갖는 Template 패턴을 찾아 LTM 식에 의해 재훈련시킨다. 따라서 ART2에 의해 오인식된 패턴에 대해 최대 값을 갖는 출력 노드가 동일한 부류에 속하게 될 확률을 높이게 된다. 이 경우 무지도학습의 목적은 훈련 데이터의 특성을 살린 Template 패턴의 효율적인 초기화에 있으며 지도학습의 목적은 ART2의 훈련데이터에 대한 인식능력의 극대화를 이룩하는데 있다. 구체적인 이 단계 훈련과정은 다음과 같다.

```
procedure Two_stage_ART2
{
    for (all of the preordered training sequence)
        do Unsupervised_ART2;
    for (all of the preordered training sequence) {
        do Test_ART2;
        save the winning node J for each training
        vector;
    }
    label each F2 layer node;
    for (all of the preordered training sequence) {
        let the class label of the current training
        vector be  $\omega_j$ ;
        max_score = 0;
        for (all output nodes belonging to  $\omega_j$ ) {
            winning_node = current_output_node;
            apply an input pattern to the input layer;
```

```
            until (the sublayer output values are sta-
                bilized)
            propagate through the six sublayers;
            calculate the r sublayer outputs using Eq.
            (10);
            if (||r|| > max_score) {
                max_score = ||r||;
                J = winning_node;
            }
        }
        modify the bottom-up weights using Eq. (11);
        modify the top-down weights using Eq. (11);
    }
}
```

Test_ART2 과정은 Unsupervised_ART2 과정 중에서 Top-down 및 Bottom-up weight의 조정 과정 (step6)이 생략된 형태로서 각 입력 패턴에 대해 최대의 출력률을 갖는 Winning node를 결정한다. Unsupervised_ART2와 Two_stage_ART2의 차이점은 입력 패턴의 Winning node의 탐색 방식에 있다. Unsupervised_ART2에서는 출력 노드의 부류 정보에 관계없이 최대의 정합률을 보이는 노드를 Winning node로 결정하는 반면, Two_stage_ART2에서는 입력 패턴과 같은 부류에 속하는 출력 노드 중에서 Winning node를 결정한다. 이와 같이 서로 다른 기능을 가진 이 단계 훈련과정에 의해 ART2의 불필요한 Template는 제거하고 동시에 인식 능력을 극대화 시킴으로써 ART2를 효율적으로 훈련시킬 수 있다.

IV. 실험 결과 및 고찰

미 해군 연구소(U.S. Naval Air Warfare Center)에서 제공된 2541 개의 군함영상을 대상으로 원래의 ART2와 이 단계 훈련에 의한 ART2의 인식 능력을 비교하였다. 이들 군함 영상은 Destroyer(DD), Container(CONT), Civilian Freighter(C-F), Auxiliary Oil Replenishment (AOR), Landing Assault Tanker(LST), Frigate(FF), Cruiser(CGN), Destroyer with Guided Missiles(DDG) 등의 8 가지 종류로 구성된 적외선 영상이며 그림 2에 표본 영상을 나타낸다. 세그멘트된 영상을 수평축으로 투영시키고 물체의 크기에 따라 정규화하여 20 개의 Projection을 ART2의 입력 패턴으로 사용하였다. 군함 영상의 경우 물체의 방향이 수평축과 평행하므로 투영

된 영상은 원 물체의 형상을 그대로 유지한다. 물체의 방향이 일정하지 않을 경우 모멘트 함수^[5]를 사용하여 물체의 방향을 보상할 수 있다. ART2 내부의 부총 인 x, u, q 층에서 입력 패턴의 정규화를 자동으로 행 하므로 수직 방향의 정규화는 필요하지 않다. 그림 3 은 그림 2의 원 영상에 대해 표적분리와 정규화된 Projection 과정을 거친 입력 패턴을 표시한다.

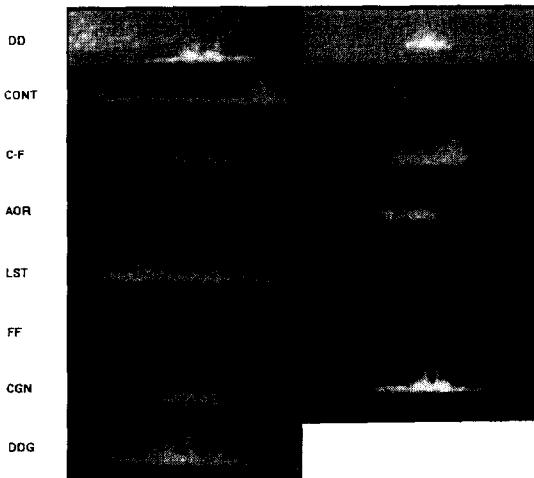


그림 2. 근거리의 군함영상

Fig. 2. Raw ship images at short distance.

이와 같은 전처리 과정을 거친 2541 개의 영상 패턴을 무작위로 이등분하여 한쪽 패턴은 ART2 의 훈련 과정에 사용하고 나머지 패턴은 ART2 의 인식률을 측정하는데 사용하였다. 이러한 인식률 평가방식은 홀드-아웃(Hold-out)방식으로 불린다. 인식률의 측정에 훈련 데이터를 재사용할 경우의 인식률 평가방식은 재삽입(Resubstitution) 방식으로 불린다. 본 논문에서 제안된 훈련 방식의 성능을 평가하기 위해 1) 원래의 ART2, 2) 무작위 배열된 훈련 데이터의 이 단계 훈련에 의한 ART2, 3) 순환 배열된 훈련 데이터의 이 단계 훈련에 의한 ART2 등의 3 가지 훈련 방식을 실험하였다. 이들 3 가지 방식을 각각 ART2, ART3, ART4 로 표기하기로 한다. ART2 의 파라메터인 a, b, c, d, θ 는 각각 10, 10, 0.1, 0.9 및 0 로 선택하고 vigilance 파라메터 ρ 는 0.995 를 사용했다. 출력 노드의 수를 20 에서 100 까지 변화시키면서 ART2, ART3, ART4 의 인식률을 측정하였다. 재삽입 방식과 Hold-out 방식을 사용한 결과를 그림 4(a) 와 그림 4(b) 에 도시한다. 출력 노드의 수가 40 이하일 경

우 ART3 가 ART4 보다 약간 높은 인식률을 보였으나 출력 노드의 수가 증가할수록 ART4 의 인식 능력이 ART2 와 ART3 보다 월등하다.

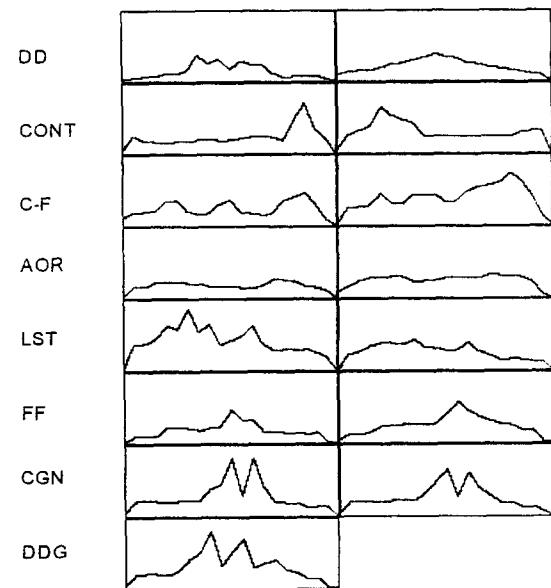


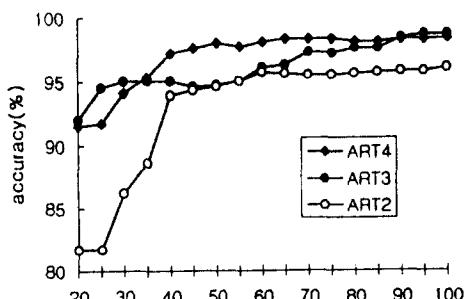
그림 3. 정규화된 군함의 투영영상

Fig. 3. Normalized and projected ship images.

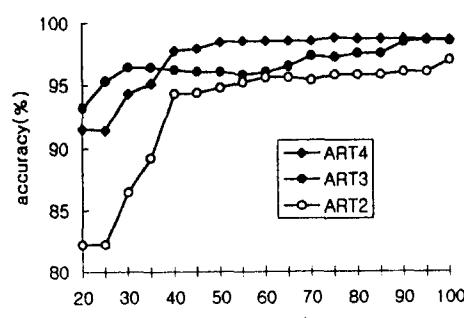
이것은 지도학습에 의한 이단계 학습과 훈련 데이터의 순환 배열이 ART2 의 성능을 향상시키는데 매우 효과적임을 나타낸다. 또한 ART4 는 출력노드 수의 증가에 따라 최적의 인식률을 갖는 구조로 빠르게 수렴함을 알 수 있다. 즉, 출력 노드의 수가 50 이상일 때 인식률은 더 이상의 향상을 보이지 않는다. 출력 노드의 수가 50 일 때 ART2, ART3, ART4 의 재삽입 인식률은 각각 94.6%, 94.7%, 98.0% 였고 hold-out 방식에서는 각각 94.8%, 96.0%, 98.4% 의 인식률을 보였다. ART4 내부에 형성된 Template 패턴을 그림 5 에 보인다. 각 열은 8 가지 종류의 군함영상을 의미하며 첫번째에서 네번째 행은 근거리, 원거리에서의 90° 및 30° 군함영상을 나타낸다. 다섯번째 이후의 행들은 Template 패턴을 나타낸다.

ART4 에 의해 오인식된 패턴을 그림 6 에 도시한다. DD 로 오인식된 FF 와 FF 로 오인식된 CGN 영상은 원거리에서 촬영되어 명료도가 떨어지는 영상들이다. 모델의 특성을 고려한 세그멘테이션 기법^[6]을 사용하면 인식률을 향상시킬 수 있을 것이다. 또한 CONT 로 오인식된 C-F 영상은 군함의 형태가 CO-

NT의 형태와 매우 흡사한 영상으로서 Ground truth table을 작성한 전문가의 착오로 C-F로 판정된 것이라 생각된다. 따라서 정확히 분류된 훈련데이터에 대해 이 단계 훈련과정을 적용한 ART2 시스템은 우수한 인식능력을 가진 패턴 인식 시스템으로서 사용될 수 있는 가능성을 보였다.



(a) 재삽입 방식



(b) Hold-out 방식

그림 4. ART2, ART3, ART4의 인식률 비교
Fig. 4. Comparison of recognition accuracy of ART2, ART3, and ART4.

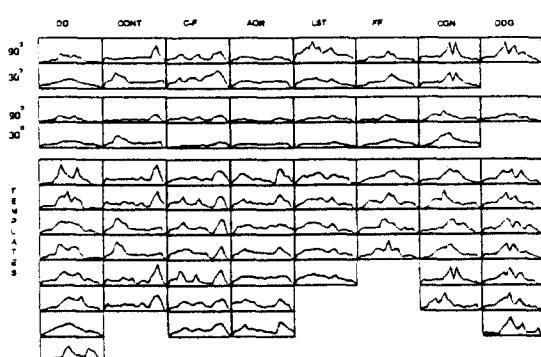


그림 5. 표본 패턴과 Template 패턴
Fig. 5. Representative patterns and template patterns.

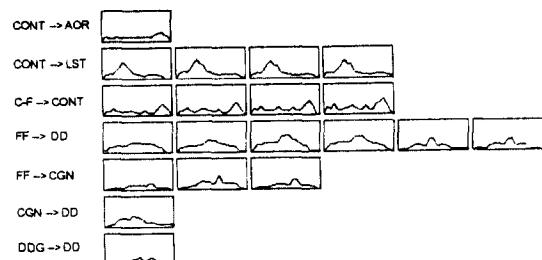


그림 6. 오인식된 패턴
Fig. 6. Misclassified patterns.

V. 결 론

본 논문에서는 훈련 데이터의 Template 형성을 위한 무지도학습과 훈련 데이터의 부류 정보에 의한 Template의 세부 교정을 위한 지도학습으로 구성된 새로운 이 단계 학습 알고리즘을 제안하였다. 이 단계 학습에 의한 ART2는 신속한 적응학습 능력과 Stability-plasticity switching 기능을 가진 신경망분류기로서 무지도학습에 의한 ART2에 비해 월등한 인식률의 향상을 피할 수 있다. 2545개로 구성된 실제의 군함영상에 대한 실험 결과, 제안된 이 단계 학습에 의한 ART2는 신경망의 크기와 인식률 측정 방법에 관계없이 원래의 ART2 보다 우수한 인식 능력을 발휘했고, 출력 노드의 개수가 50 일 때 각각 98.4% 및 94.8%의 정인식률을 보였다. 이와 같은 인식률의 향상은 이 단계 학습과정에 의한 ART2의 설계가 효과적임을 나타낸다.

참 고 문 현

- [1] G.A. Carpenter and S. Grossberg, "A Massively parallel architecture for a self-organizing neural pattern recognition machine," Computer Vision, Graphics, and Image Processing, 37, p. 54-115, (1987).
- [2] G.A. Carpenter and S. Grossberg, "ART2: Self-organization of stable category recognition codes for analog input patterns," Applied Optics, 26(23), p. 4919-4930, (1987).
- [3] D.E. Rumelhart, G.E. Hinton, R.J. Williams: "Learning internal representation by error back propagation", Parallel Distributed

- Processing: Explorations in the Micro-structure of Cognition. Vol. 1: Foundations. MIT Press (1986).
- [4] J. A. Freeman and D. M. Skapura, "Neural Networks: Algorithms, Applications, and Programming Techniques," CNS, (1991).
- [5] M.K. Hu: "Visual Pattern Recognition by Moment Invariants", IRE Trans. Inform. Theory IT-8, pp. 179-187 (1962).
- [6] B. Bhanu and R.D. Holben, "Model based segmentation of FLIR images," SPIE Applications of Digital Image Processing, p. 10-18, (1984).

저자 소개

朴榮泰(正會員) 第33卷 第3號 參照

현재 경희대학교 전자공학과

부교수