

# 다층 셀룰라 비선형 회로망(CNN)을 이용한 고속 패턴 분류

論 文

52D-9-5

## Fast Pattern Classification with the Multi-layer Cellular Nonlinear Networks (CNN)

吳 泰 完\* · 李 惠 淨\* · 孫 弘 樂\*\* · 金 紛 蔚\*\*\*  
(Tae-Wan Oh · Hye-Jung Lee · Hong-Rak Son · Hyong-Suk Kim)

**Abstract** – A fast pattern classification algorithm with Cellular Nonlinear Network-based dynamic programming is proposed. The Cellular Nonlinear Networks is an analog parallel processing architecture and the dynamic programming is an efficient computation algorithm for optimization problem. Combining merits of these two technologies, fast pattern classification with optimization is formed. On such CNN-based dynamic programming, if exemplars and test patterns are presented as the goals and the start positions, respectively, the optimal paths from test patterns to their closest exemplars are found. Such paths are utilized as aggregating keys for the classification. The algorithm is similar to the conventional neural network-based method in the use of the exemplar patterns but quite different in the use of the most likely path finding of the dynamic programming. The pattern classification is performed well regardless of degree of the nonlinearity in class borders.

**Key Words** : Pattern classification, parallel processing, optimality, exemplar patterns

### 1. 서 론

컴퓨터가 지각 능력에 있어서 인간을 아직 능가하지 못하는 중요한 요인의 하나는 그 기술적 핵심인 영상 패턴의 분류 및 인식 기술이 충분히 성숙하지 못한 점 때문이라고 할 수 있다. 지금까지 개발된 대표적인 패턴 분류 기술들로는 확률 통계기반 기술, 퍼지기반 기술 및 신경회로망 기반 기술들로 크게 분류할 수 있다. 확률 통계기반 패턴 분류 방법 [1-3]은 각 클래스를 대표하는 특징들을 이용하여 분류 대상이 특정 클래스에 속할 확률을 계산하는 방법이다. 그러나, 패턴 분류에 대한 에러를 최소화 할 적절한 특징들을 선택하는 일이 쉽지 않으며, 효율적 분류를 위해서 많은 수의 특징들을 사용해야 하기 때문에 확률을 계산할 함수의 차수가 매우 커져야하는 문제가 있다. 이와 같은 확률 통계적인 패턴 분류 방법보다는 경험적인 규칙들을 생성시키고 이들의 융합을 이용하는 방법도 발달했는데 이것이 퍼지 기반 패턴 분류 방법 [4-6]이다. 이 퍼지 기반 패턴 분류는 설치와 계산이 용이하다는 장점은 있지만, 표본 패턴에 대한 분석이나 인간의 경험들을 수집하여 적절한 퍼지 규칙을 생성시켜야 한다는 단점이 있다. 또한 퍼지 규칙들의 융합시 가중치 튜닝의 어려움도 감수해야한다. 신경회로망 기반 방법 [7][8]은 이와 같은 표본 패턴에 대한 분석이나 퍼지 규칙 생성 및 튜닝이 불필요한 기술이다. 학습해야 할 표본 패턴들을 외부에서 제시하기만 하면, 신경회로망은 인간과

유사한 방법으로 표본 패턴간의 상관관계를 학습을 통해서 파악하고, 패턴 분류를 위한 규칙을 신경회로망에 자동으로 생성시키게 된다. 이 분류기술은 표본 패턴들에 대한 사전의 분석이나 지식이 없이도 학습을 통해서 자동으로 생성시킬 수 있는 장점이 있다. 그러나, 이 방법의 단점은 학습 시 시간소요가 많다는 점과 지역 최소치에 빠져 학습이 어려울 수 있다는 문제들이다.

제안한 패턴 분류 방법은 신경회로망 기반 패턴 분류방식의 하나로 CNN(Cellular Neural Networks, CNN) [9][10]의 고속 병렬 처리를 사용하는 방식이다. 이 CNN은 기존의 신경회로망들과는 달리 학습기능이 퇴화하고 주로 인식처리기능을 하드웨어 구현이 가능하도록 발달시킨 회로망이다. 이 회로망은 2차원의 배열을 갖는 단층의 아날로그 프로세서들을 주로 사용해서 정보를 병렬 처리하지만, 복잡한 처리를 위해서는 다층의 CNN을 사용하기도 한다. 이 CNN은 외부에서 인가하는 선형 혹은 비선형 가중치 (템플릿)에 따라 많은 종류의 다양한 정보처리가 가능하다. Roska 등은 이 알고리즘을 범용의 영상처리 장치로 개발하였으며 [11][12], 최근 120x120개의 셀 배열을 갖는 CNN칩이 개발완료 단계에 있다. 이 CNN을 이용한 알고리즘은 표본 패턴을 사용한다는 점에서 기존의 신경회로망과 유사하지만, 학습을 하지 않는다는 점에서 기존의 신경회로망 기법과 크게 다르다. 따라서, 기존의 신경회로망이 갖는 학습성공의 불확실성 문제가 없이 성공적인 분류를 항상 보장할 수 있으며, 학습도 불필요하다. 한편, 동적계획법 (Dynamic Programming) [13]은 지역적인 단순 연산을 통해서 전체적인 최적화 해법을 찾는 알고리즘이며, 본 연구에서는 이 동적계획법을 CNN에 구현함으로써 CNN의 병렬 고속 계산 기능과 동적계획법의 최적화 기능을 결합하여 패턴 인식에 활용하였다. 이 패턴 분류 알고리즘에서는, 표본 패턴과 시험 패턴들을 최적 경로

\* 準 會 員 : 全北大 工大 制御計測工學科 碩士課程

\*\* 正 會 員 : 全北大 工大 電子情報工學部 工博

\*\*\* 正 會 員 : 全北大 工大 電子情報工學部 副教授 · 工博

接受日字 : 2003年 5月 28日

最終完了 : 2003年 7月 17日

계산 알고리즘에서의 목표지점 및 시작점들로 간주하여 최근 거리의 표본 패턴을 찾아내게 된다. 이 분류 방법에서는 클래스간의 경쟁을 이용하므로, 분류를 위한 최적화 특성을 유지하게 되며 패턴 분류 시 개별적 표본 패턴과의 거리 정보를 이용하게 되므로 클래스간에 고도의 비선형적 경계가 있는 경우에도 분류가 잘 이뤄지게 된다.

• 이 논문의 제2절에서는 본 알고리즘을 하드웨어 구현에 적합한 형태로 수정한 동적계획법을 소개하고, 제3절에서는 제안한 다층 CNN구조를 제안하였으며, 제4절에서는 제안한 비선형 템플릿을 소개하였다. 또한, 제5절에서는 다양한 거리값을 갖는 공간에서의 CNN기반 패턴 인식 시뮬레이션이며, 제6절은 결론이다.

## 2. Cellular Neural Networks (CNN)

최근 CNN은 그림1(a)와 같이 2차원 배열을 갖는 아날로그 병렬처리 회로로써, 각 격자점에는 각 노드의 지역적 연산을 담당하는 아날로그 연산처리 셀들이 배치되어 있다. 이 셀들은 주위의 8개 셀들과의 회로적 연결을 가지며 이 주변 셀들과 긴밀하게 정보교환을 통하여 처리하는 구조이다. 그림 1(b)는 CNN셀의 구조 및 주변 셀들과의 연결을 자세히 보이기 위한 1차원 CNN의 구조인데  $x$ 는 각 셀의 출력 상태이며,  $y$ 는 셀의 출력이고  $f(\cdot)$ 는 셀의 상태값을 출력으로 변환하는 비선형 출력함수로써 비선형 함수인 시그모이드 함수를 주로 사용한다. 또한,  $u$ 는 입력을 표시한다. 그림1(b)에서 각 연산 셀들의 입력으로는 자신의 위치에 해당하는 입력값 뿐 아니라 인접 셀들의 입력값들을 시냅틱 가중치들과의 컨볼루션에 의하여 입력하는데, 이 때 사용된 시냅틱 가중치 벡터를 A 템플릿이라고 한다. 그림1(a)의 2차원 구조에서는 시냅틱 가중치들이 8방향의 연결을 담당해야 하므로  $3 \times 3$ 의 매트릭스로 표현된다. 각 셀에는 또한 제작  $s$ 의 불균일을 고려하여  $z$ 로 표현된 bias 값은 인가할 수 있게 되어 있다. 각 셀의 출력은 입력된 모든 정보들을 합산하여 출력함수  $f(\cdot)$ 에 의해 연산한 결과이다.

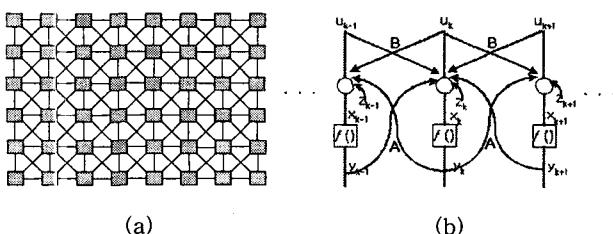


그림 1 CNN셀의 배열 (a) 2차원 연결 (b) 1차원 연결  
 Fig. 1 CNN Array (a) Connections of 2-D CNN  
 (b) Connections of 1-D CNN

이 연산 구조가 회로에 의해 구현되기 위해서는 입력 정보를 전류로 변환하여 커패시터에 합산하는 구조가 효과적이다. 이와 같이 동작을 하는 CNN셀의 전기적 등가회로는 그림 4와 같다.

이 등가회로에서와 같이 CNN셀은 전형적인 RC회로 구조로 표현되므로 템플릿 A 및 B에 의한 입력값과 내부 bias값  $z$ 를 고려한 회로의 동 특성식(dynamic)은 (1)처럼 1차 미분방정식으로 표현된다.

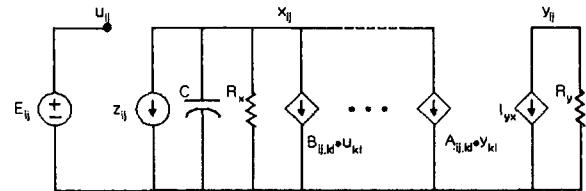


그림 2 CNN 셀의 전기적 등가회로 [9]

**Fig. 2** Electrical equivalent circuit of the CNN cell

$$\frac{dx(i,j)}{dt} = -x(i,j) + \sum_{kl \in N_r} A(ij, kl) y_{kl} + \sum_{k \in N} B(ij, kl) U(k, l) + z_{ij} . \quad (1)$$

여기서,  $x(i,j)$ 는 셀( $i,j$ )의 출력측 상태를 의미하고 템플릿  $A(i,j,kl)$ 과  $B(i,j,kl)$ 은 각각 셀( $i,j$ )와 셀( $k,l$ )간의 출력측 및 입력측의 템플릿이며,  $Z_{ij}$ 는 셀( $i,j$ )의 bias이다. 이 셀의 출력 함수는

$$y(i,j) = f(x(i,j)) \quad (2)$$

와 같이 표현되는데  $f$ 는 그림 1(b)와 같은 비선형 함수 (nonlinear function)이다.

### 3. 다층 회로망을 이용한 동적계획법(Dynamic Programming)의 구현

### 3.1 회로구현의 용이성을 위한 동적계획법의 수정

동적계획법은 각 노드에서의 지역적인 최소값 연산을 통해서 전체적으로 최적의 경로를 계산하는 효율적 계산 알고리즘이다.

만약,  $D(i,j)$ 와  $D(k,l)$ 를 각각 노드  $(i,j)$ 와 노드  $(k,l)$ 로부터 목적지에 이르는데 소요되는 최소 거리라고 하자. 또,  $d_{ij,kl}$ 를 노드  $(i,j)$ 로부터 노드  $(k,l)$ 에 이르는 지역적인 최소 거리라고 가정하면,  $D(i,j)$ 는  $D(k,l)$ 와  $d_{ij,kl}$ 를 이용해서 다음과 같이 표현할 수 있다.

$$D(i, j) = \min \{ d_{ii} + D(k, l), (k, l) \in R(i, j) \} \quad (3)$$

여기서,  $R(i,j)$ 는 노드 $(i,j)$ 주변의 모든 노드들의 집합이다. 식 (3)에서의 연산은 min과 가산연산인데, 일반적으로 min 연산은 max연산보다 회로가 복잡하므로, 식 (3)을 max를 사용한 연산으로 변환하는 것이 편리하다. 이를 위해서 기준값을  $I_{max}$ 라 하고  $y(i,j)$ 를  $I_{max}$ 와  $D(i,j)$ 간의 보수(Complement)로 표현하면,  $y(i,j)$ 는

$$v(i,i) = I_{\max} - D(i,i) \quad (4)$$

혹은

$$D(i,j) = I_{\max} - y(i,j) \quad (5)$$

으로 표현된다. 식 (5)를 (3)에 대입해서 정리하면

$$I_{\max} - y(i, j) = \min \{ d_{ij, kl} + I_{\max} - y(k, l); (k, l) \in R(i, j) \} \quad (6)$$

가 되며,  $I_{\max}$ 가 상수이므로, 식 (6)은

$$\begin{aligned} y(i, j) &= -\min \{ d_{ij, kl} - y(k, l); (k, l) \in R(i, j) \} \\ &= -\min \{ -(y(k, l) - d_{ij, kl}); (k, l) \in R(i, j) \} \end{aligned} \quad (7)$$

로 정리된다. 식 (7)에서 부의 부호가 min연산식 밖으로 나오면 min이 max로 바뀌게 되므로,

$$y(i, j) = \max \{ y(k, l) - d_{ij, kl}; (k, l) \in R(i, j) \} \quad (8)$$

와 같이 max연산이 된다. 식 (8)을 이용해서  $y(i, j)$ 가 구해진다면, 목적지까지의 최소 거리  $D(i, j)$ 는 식 (5)를 이용해서 구할 수 있다. 그런데, 목적지에서는 자신의 위치까지의 거리  $D(i, j)$ 가 0이므로, 이 관계를 이용하면, 노드의 위치가 목적지 여부에 따라 다음과 같이 정리할 수 있다.

$$y(i, j) = \begin{cases} I_{\max}; \text{ if } (i, j) \text{ is designated as the goal.} \\ \max \{ y(k, l) - d_{ij, kl}; (k, l) \in R(i, j); \text{ otherwise} \} \end{cases} \quad (9)$$

여기서,  $I_{\max}$ 값은 주변의 어느 값에 비해 크다는 점을 고려하여, 식 (9)를 간략화하면,

$$y(i, j) = \max \{ u(i, j), (y(k, l) - d_{ij, kl}); (k, l) \in R(i, j) \} \quad (10)$$

이고,  $u(i, j)$ 는

$$u(i, j) = \begin{cases} I_{\max}; \text{ if } (i, j) \text{ is designated as a goal} \\ 0; \text{ otherwise} \end{cases} \quad (11)$$

로 표현할 수 있다. 이 식에서 확인할 수 있는 바와 같이 (1)에서의 min함수가 회로구현이 용이한 max함수로 표현되었음을 알 수 있다.

### 3.2 제안한 다층 CNN

식 (10)로 표현된 변형된 동적계획법의 원리는 목표점에 부여한 기준값  $I_{\max}$ 가 모든 노드에 전파되는데 이 때, 각 노드에는 인접 노드 출력으로부터 지역적 거리값 만큼을 감한 결과가 입력되게 되며, 각 노드는 이 결과 중에서 최대값을 취하는 연산을 수행한다. 이 전파된 값은 목표점에서 최대가 되고, 목표점에서 멀어질수록 감소하게 된다. 우리는 이 전파되는 값은 거리 기준값(Distance Reference, DR)이라고 하고, 목표점에 인가한 원래의 기준값을 최대 기준값이라고 명명한다. 또한, 이 거리 기준값이 전파되어 0보다 큰 영역을 DR영역이라고 한다. 목표점에 인가한 거리 기준 최대값  $I_{\max}$ 값은 가능하면 큰 것이 좋다.

이렇게 DR필드가 형성되어 정상상태(Steady state)에 이르면 DR필드 내에서는 어떤 점에서도 노드의 출력  $y$ 를 이용해서 목표값까지 이르는 최소 거리를 식 (5)에 의해 구할 수 있다. 또한,  $(i, j)$ 를 최적 경로상의 한 점이라면, 최적 경로상의 다음 점은 식 (12)를 만족하는 점  $(k, l)$ 로 결정하면 된

다. 이와 같은 과정을 반복하여 목표점까지의 최소 거리의 경로를 구할 수 있다.

$$\left. \begin{array}{l} \text{Cell } (i, j) \in R(k, l); \text{ For the } (i, j) \text{ which is the} \\ \text{point on the predetermined optimal path.} \end{array} \right\} (a) \quad (12)$$

$$y(k, l) = y(i, j) + d_{ij, kl} \quad (b)$$

CNN에서 많은 셀들을 한 칩에 포함시킬 수 있게 하기 위해서 셀의 구조는 간단할수록 좋을 것이다. 따라서, 본 논문에서 사용한 방법은 식 (10)을 단순한 여러 개의 연산들로 분해하여 각기 다른 층에서 처리하게 하는 것이다. 이를 위해서 식 (10)의 양변에  $y_{ij}$ 를 더하면, 식 (10)은

$$2y_{ij} = \max \{ y_{ij} + y_{kl} - d_{ij, kl}; (k, l) \in R(i, j) \} \quad (13)$$

혹은

$$y_{ij} = \max \left\{ \frac{y_{ij} + y_{kl} - d_{ij, kl}}{2}; (k, l) \in R(i, j) \right\} \quad (14)$$

가 된다. 식 (14)에서 CNN의 한 층에서는 max연산만 수행하고 다른 층에서는 팔호 내부의 합산과 2로 나누는 일을 분담해서 처리하게 할 수 있다. 즉, max연산을 수행하는 층을 거리 계산층(Distance Computing layer, DC)이라고 하고, 팔호 내부의 연산을 하는 층을 중간층(Intermediate layer)이라고 하면, 각 층에서는 각각

$$y_{DC}(i, j) = \max \{ y_I(k, l); (k, l) \in R(i, j) \} \quad (15)$$

과

$$y_I(k, l) = \frac{1}{2} ( y_{DC}(i, j) + y_{DC}(k, l) - \frac{d_{ij, kl}}{2} ) \quad (16)$$

의 연산을 한다. 여기서,  $y_{DC}(ij)$ 과  $y_I(ij)$ 는 거리 계산(DC)층과 중간(I)층의 출력이다. DC층의  $(i, j)$ 위치에서 (15)식의 계산을 위해서는 8방향의  $(k, l)$ 에서의 (16)과 같은 계산 결과가 필요하며,  $(i, j)$ 와 인접한 셀에서도 (15)의 계산을 하기 위해서는 식 (16)의 계산이 필요하다. 즉, I층에서 DC층의  $(i, j)$ 와 그 인접 셀  $(k, l)$ 에 대한 계산 결과는 DC층의  $(i, j)$ 위치에서 (15)식 계산에 이용될 뿐 아니라, DC층의  $(k, l)$ 위치에서 (15)식 계산 시에도 I층의 계산 결과가 중복 이용되므로 연산이 효율적이다. 또한, 이 I층의 값은 최종 경로 결정시에도 한번 더 사용되어질 수 있다. 즉, 경로 결정을 위한 조건식 (12(b))는 DC층에서의  $y$ 값이므로 이 값을 (16)식에 대입하면, 경로 결정 조건식은 (17)식으로 절묘하게 단순화된다.

$$y_I(k, l) = y_{DC}(i, j) \quad (17)$$

이 식의 의미는 DC층의 출력과 같은 값을 갖는 I층의 셀이 있다면, 그 방향이 path의 방향이다. 이와 같이 path의 여부를 판단하는 일은 경로 결정층(PF layer)라고 하는 또 하나의 층에서 수행한다. 그럼 3은 위의 3층의 위치와 연결을 보여준다.

### 3.3 최적 경로 계산을 위한 CNN의 비선형 템플릿

최적 경로 계산을 위해서 각 층에서의 연산은 DC층에서

max연산, I층에서 빨셈, 나눗셈 및 PF층에서의 비교 연산 등이다. CNN에서는 이들의 연산 기능을 템플릿을 이용해서 수행해야 하는데, 다행히 max기능은 비선형 템플릿으로써 [14]에서 그 템플릿을 제안했으며, 빨셈 및 나눗셈 기능은 CNN의 선형 템플릿[15]에 의해 해결할 수 있다.

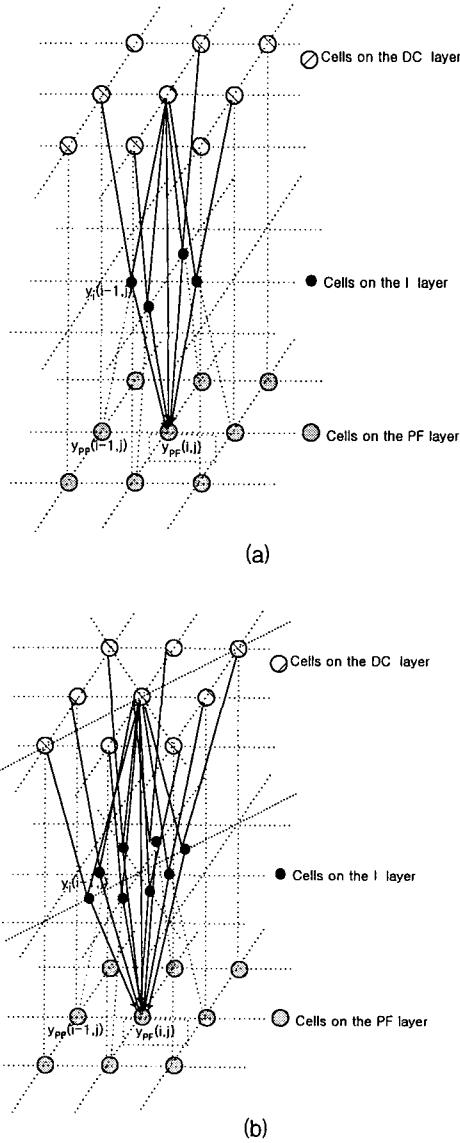


그림 3 제안한 다층 CNN구조에서의 셀 연결

(a) 4-연결 회로망 (b) 8-연결 회로망

Fig. 3 Connections of a cell in the proposed multi-layer CNN structure  
(a) 4 connected networks (b) 8 connected networks

나머지 템플릿은 PF층에서 경로를 표시하기 위해 식 (17)로 표현한 동등 여부 비교기능이다. 기준 거리값들의 분포가 완성되어 있는 한, 식 (17)을 만족하는 셀은 필히 존재하기 마련이며, 그 방향이 경로의 진행 방향이다. 그러나, 식 (17)을 만족했다고 해서 모든 셀의 위치가 경로 상의 셀의 위치가 되는 것은 아니며, 인접 셀이 시작점의 셀 위치이거나 경로 상의 셀이어야 한다는 조건을 만족해야 한다. 즉, 최적 경로는

$$(k, l) \in S(i, j) \text{ and } y_i(k, l) = y_{CC}(i, j) \quad (18)$$

의 조건을 만족하는 셀( $k, l$ )로 결정한다. 여기서,  $S(i, j)$ 는 ( $i, j$ )셀 주변에 있는 셀들의 집합을 의미한다.

이를 위해서 비선형 템플릿을 사용해야 하며, 이를 위한 CNN의 비선형 동특성 식은

$$\frac{dx_{PF}(i, j)}{dt} = \sum_{k=1}^{N_r} \widehat{D}_1(y_I(k, l) - y_{DC}(i, j))(y_{PF}(k, l) + 1) + \widehat{D}_2(u_{PF}(i, j) - y_{PF}(i, j)) + y_{PF}(i, j) + z_0 \quad (19)$$

이고,  $z_0$ 는 bias값으로써, (0.0, -1.0)의 범위이다. 여기서,  $\widehat{D}_1$ 은 조건( $k, l \in S(i, j)$ )의 만족 여부를 검사하기 위한 비선형 템플릿이고  $\widehat{D}_2$ 는  $y_I(k, l) = y_{CC}(i, j)$  여부를 검사하기 위한 비선형 템플릿이다. 이 비선형 템플릿들은 그림 4 및 5와 같이 정의한다.

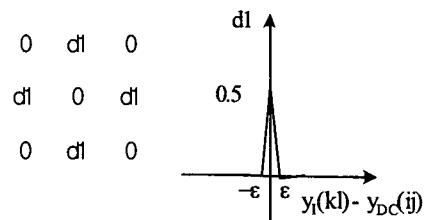


그림 4 경로 결정을 위한  $\widehat{D}_1$  비선형 템플릿

(a) 템플릿 (b) 비선형 함수

Fig. 4 Nonlinear template  $\widehat{D}_1$  for the path determination  
(a) template (b) nonlinear function

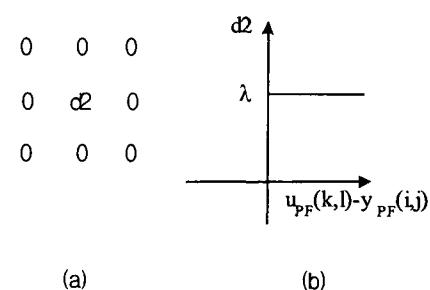


그림 4 경로 결정을 위한  $\widehat{D}_2$  비선형 템플릿

(a) 템플릿 (b) 비선형 함수

Fig. 4 Nonlinear template  $\widehat{D}_2$  for the path determination  
(a) template (b) nonlinear function

#### 4. 다층 CNN의 최적 경로 계산을 이용한 패턴 분류

##### 4.1 특징 공간에서의 거리값에 따른 패턴의 분류

제안한 패턴 분류는 CNN의 병렬처리 시스템과 동적계획법의 최적화 특성을 결합한 고속의 최적 경로 계산 알고리즘을 이용한 것이다. 이를 위해서 특정변수의 공간을 CNN 셀로 표현하고 최적 경로의 목적지 위치를 표본 패턴에 대

한 특징값들의 위치로 표시한다. 또한, 테스트 패턴의 위치를 최적 경로의 시작점으로 표시하여, 테스트 패턴의 위치셀로부터 목표 위치 셀까지 이르는 최적 경로를 구하여 각 테스트 패턴이 속한 적절한 그룹을 선택하게 하는 것이다.

가령,  $i$  번째 클래스의 집합을  $P_i$ , 이 집합 내의  $j$  번째 패턴을  $p_i(j)$ 라고 하면,

$$p_i(j) \in P_i, \quad 1 \leq i \leq M, \quad 1 \leq j \leq N_m \quad (20)$$

이다. 여기서,  $M$ 은 클래스 번호이고,  $N_m$ 은 각 클래스에 속하는 각 패턴의 번호이다. 또한, 테스트 패턴을  $P_t$ 라고 하고 학습용 표본 패턴을  $P_i(j)$ ( $j$  th pattern in the  $i$  th class)라고 하며, ( $i, j$ ) 위치의 표본 패턴으로부터 테스트 패턴까지의 거리를  $d_{t-ij}$ 라고 하자. 또한, 테스트 패턴과 가장 가까운 거리에 있는 표본 패턴의 클래스를  $k$ 라 하고, 이 때의 거리를  $D_{t-k}$ 라고 하면,  $D_{t-k}$ 는

$$D_{t-k} = \min \{d_{t-ij}, \quad 1 \leq i \leq M, \quad 1 \leq j \leq N_m\} \quad (21)$$

로 계산하며, 이 테스트 패턴은  $k$  번째 클래스에 속한다고 결정한다. 즉,

$$p_t \in P_k \quad (22)$$

가 된다.

#### 4.2 다층 CNN을 이용한 패턴 분류 알고리즘

4.1절에서의 패턴 분류 방법을 제안한 CNN구조상에서 수행시키기 위한 알고리즘은 그림 6과 같다. 이 알고리즘에서의 각 패턴들의 위치는 패턴들의 특징 좌표상의 위치이며, 이 위치는 CNN의 셀로 표현된다.

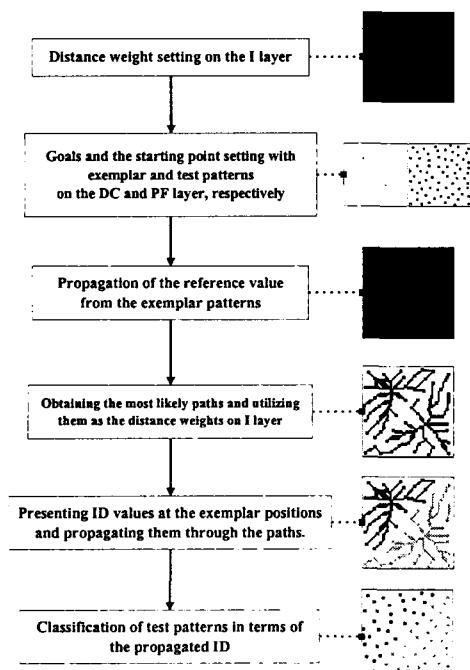


그림 6 제안한 알고리즘

Fig. 6 Flow diagram of the proposed algorithm

이를 위한 첫 번째 단계에서는 I층에 셀 간의 거리값을 인가하는 과정이고, 다음 단계는 DC층과 PF층에 각각 표본 패턴의 위치와 테스트 패턴의 위치를 각각 지정해주는 과정이다. 표본 패턴과 테스트 패턴의 위치 지정을 위해서 DC층에 위치한 모든 표본 패턴에 대해서 동일한 크기의 큰 거리 기준값  $I_{max}$ 를 인가하여 그 위치를 지정하고, PF층에 위치한 모든 테스트 패턴의 위치를 큰 값(+1)로 인가한다.

표본 패턴의 위치와 테스트 패턴의 위치가 지정되면 CNN은 DC층에 인가된  $I_{max}$ 를 I층에 있는 셀 간의 거리값 만큼 감소하면서 전파시킨다. 이 때, DC층의 각 셀에는 식 (15)과 같은 연산을 I층에서는 식 (16)과 같은 연산을 수행하게 된다. 한편, 이 거리 기준값들이 테스트 패턴의 위치에 이르면 테스트 패턴의 위치에서부터 시작하여 경로가 생성되기 시작한다. 이 때의 경로는 테스트 패턴의 위치나 형성된 경로에서만 이어갈 수 있도록 식 (18)을 만족해야 한다. 그런데, 만약 이 경로가 목적지 셀이라면, 식 (18)을 만족하는 셀이 주변에 더 이상 존재하지 않으므로 경로가 그 자리에서 멈추게 된다.

이렇게 얻어진 경로는 클래스의 식별값을 전달하기 위한 통로로 이용한다. 즉, 이 경로 상의 위치에는 셀 간 거리값 0을 인가하며 경로 밖의 셀 간 거리값은 큰 값 +1을 부여한 후, 각 표본 패턴의 위치에 표본 패턴의 클래스에 대한 식별값을 인가하면, 경로 상에서는 식별값의 감소 없이 테스트 패턴의 위치에 전달되게 된다. 이 식별값은 테스트 패턴이 어느 클래스에 해당하는지 알려준다. 이와 같은 패턴 분류의 전 과정이 CNN의 병렬 처리에 의해 수행되며 웅직계획법의 최적화 계산 특성을 포함하게 되므로 패턴들을 특징적으로 가장 가까운 클래스에 고속으로 분류할 수 있게 된다.

#### 5. 시뮬레이션

이 시뮬레이션에서는 많은 클래스를 가진 패턴들에 대해서 제안한 알고리즘에 의한 패턴 분류의 능력을 보였다. 또한, 클래스간에 고도의 비선형 경계선을 갖는 문제에 대해서도 이 알고리즘이 잘 동작할 수 있음을 보였다.

##### 5.1 여러 종류의 클래스를 갖는 문제

그림 7은 4개의 클래스를 갖는 문제로써, 그림 7(a)는 각 클래스의 표본 패턴들의 위치를 보여주고 그림 7(b)는 테스트 패턴들의 위치이다. 여기서, 각 셀 간 거리값은 모든 셀의 위치에서 동일하다고 가정한다. 동일한 크기의 거리 기준값들을 각 표본 패턴의 위치에 인가하면, 이 값들은 그림 7(c)와 같이 셀 간의 거리값 만큼 감소하면서 각 방향에 전파되게 된다. 이 거리 기준값이 테스트 패턴의 위치에 이르게 되면, 테스트 패턴의 위치에서 발원한 경로선이 식 (18)의 조건을 따라 발달하여 표본 패턴의 위치에 이르게 된다. 이 과정을 거쳐서 형성된 경로들은 그림 7(d)와 같다. 이렇게 구해진 경로들은 다시 I층에 셀 간의 거리값으로 인가하는데, 경로에 해당하는 셀 간 거리는 0으로 하고, 경로가 아닌 곳의 셀 간 거리는 +1로 인가한 후, 모든 표본 패턴의 위치에 각 클래스의 식별값을 인가하면 이 식별값들은 I층에 인가된 경로를 따라서만 전파되므로 각 테스트 패턴들의 위치에서는 해당 표본 패턴의 식별값을 그대로 읽어낼 수 있

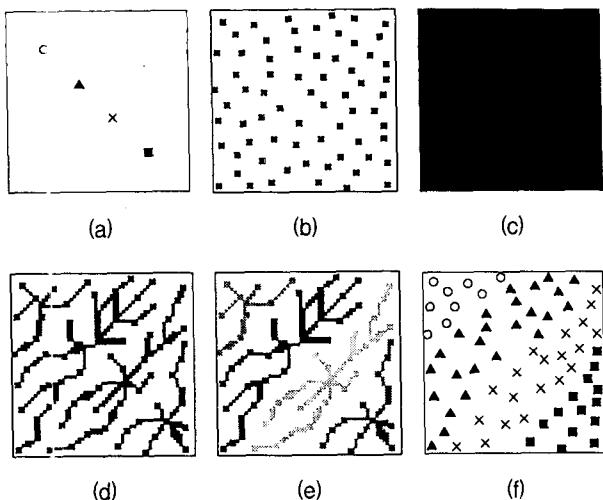


그림 7 여러 종류의 클래스를 갖는 패턴들의 분류 (a) 표본 패턴들의 위치 (b) 테스트 패턴 (c) 전파된 기준값 (d) 테스트 패턴으로부터 표본 패턴에 이르는 경로 (e) 경로를 따라 전파된 클래스의 식별값 (f) 테스트 패턴들의 분류 결과

Fig. 7 Classification of patterns of multiple classes  
(a) exemplar patterns (b) test pattern (c) propagated reference values (d) paths from the test patterns to the closest exemplars (e) class identification values propagated from the exemplar patterns through the paths in (d) (f) classified patterns

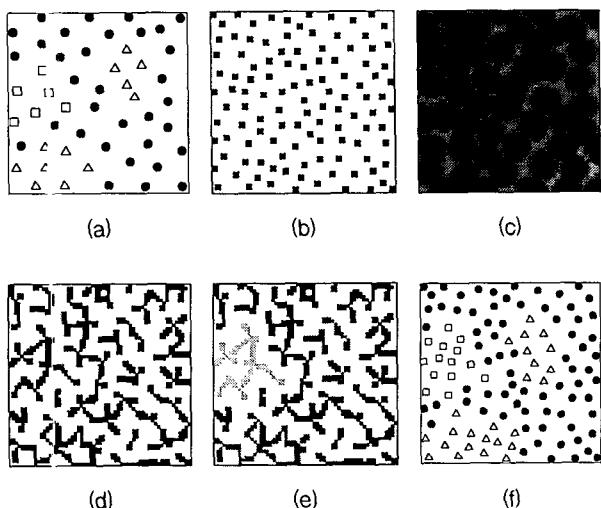


그림 8 클래스간의 경계가 매우 비선형인 패턴들에 대한 분류 (a) 표본 패턴들의 위치 (b) 테스트 패턴 (c) 전파된 기준값 (d) 테스트 패턴으로부터 표본 패턴에 이르는 경로 (e) 경로를 따라 전파된 클래스의 식별값 (f) 테스트 패턴들의 분류 결과

Fig. 8 Classification of the patterns with highly nonlinear class boundaries (a) exemplar patterns (b) test pattern (c) propagated reference values (d) paths from the test patterns to the closest exemplars (e) class identification values propagated from the exemplar patterns through the paths in (d) (f) classified patterns

다. 그림 7(e)는 그림 7(d)의 경로 위로 전파된 표본 패턴들의 식별값을 보여준다. 또한, 그림 7(f)는 이와 같은 과정을 거쳐 분류된 테스트 패턴인데 식별이 쉽도록 심볼로 표현한 결과이다. 결과에서 확인할 수 있는 바와 같이 테스트 패턴들은 Euclidian 거리값에 따른 분류기준에 합당하게 잘 분류되어 있음을 확인할 수 있다.

## 5.2 클래스간의 경계가 비선형인 패턴들에 대한 분류

일반적인 패턴 분류 문제에 있어서 클래스간의 경계가 비선형성이면 분류가 매우 어렵다. 그림 8은 클래스간의 경계에 큰 비선형성이 있는 문제에 대한 표본 패턴의 위치(그림 8(a))와 테스트 패턴의 위치(그림 8(b))를 보여준다. 또한, 그림 8(c)-8(e)는 각각 전파된 거리 기준값, 각 테스트 패턴들에서 구해진 최적 경로 및 패턴의 식별값들을 각각 보여준다. 또한, 이 문제에 대해서 패턴의 분류 결과는 그림 8(f)에 보여준다. 이 문제도 그림 7의 문제와 유사하며, 클래스 간의 비선형성으로 인해서 추가되는 어려움은 없었다.

## 6. 결 론

동적계획법을 다층 CNN의 아날로그 병렬 처리 알고리즘과 결합하여 패턴을 분류하는 방법을 제안하였다. 이 알고리즘은 CNN의 고속 병렬 처리 능력과 동적계획법의 최적화 능력을 함께 활용한 것이다.

이 패턴 분류 알고리즘에서는 표본 패턴과 테스트 패턴의 위치가 각각 최적 경로 계산문제에 있어서의 목적지와 시작점 위치로 간주된다. 제안한 분류 방법에서는 거리 기준값과 표본 패턴의 식별값들의 정보가 전파되는 과정에서의 클래스간 경쟁과 그 결과로 나타나는 최적화 특성을 이용하는 것이다. 또한, 이 알고리즘에서는 표본 패턴들의 특징이나 사전 지식이 없이도 패턴을 분류할 수 있다는 점도 장점이다.

제안한 알고리즘의 성능을 테스트하기 위해서는 다양한 시뮬레이션을 수행하였는데, 여러 종류의 클래스를 갖는 문제와 클래스 간의 경계선이 매우 비선형인 경우에도 추가적 어려움이 없이 성공적으로 분류가 이뤄짐을 확인할 수 있었다.

### 감사의 글

본 논문은 산업자원부, 전력연구원에서 지원하고 있는 전력산업연구개발사업의 연구결과입니다.

### 참 고 문 현

- [1] P. K. Patra, M. Nayak, S. K. Nayak, N. K. Gobbak, "Probabilistic Neural Network for Pattern Classification," Neural Networks, 2002. IJCNN'02. Proceedings of the 2002 International Joint Conf. on, vol. 2, pp. 1200-1205, 2002.
- [2] L. L. Ling, H. M. Cavalcanti, "Fast and efficient feature extraction based on Bayesian decision boundaries," Pattern Recognition, 2000. Proceedings.

- 15th International Conf. on, vol. 2, pp. 390-393, 2000.
- [3] T. Horiuchi, "Decision rule for pattern classification by integrating interval feature values," Pattern Analysis and Machine Intelligence, IEEE Trans. on, vol. 20, pp. 440-448, Apr. 1998.
- [4] H. M. Lee, C. M. Chen, J. M. Chen, Y. L. Jou, "An efficient fuzzy classifier with feature selection based on fuzzy entropy," Systems, Man and Cybernetics, Part B, IEEE Trans. on, vol. 31, pp. 426-432, Jun. 2001.
- [5] H. Ishibuchi, T. Nakashima, T. Murata, "Performance evaluation of fuzzy classifier systems for multidimensional pattern classification problems," Systems, Man and Cybernetics, Part B, IEEE Trans. on, vol. 29, pp. 601-618, Oct. 1999.
- [6] X. Chen, D. Jin, Z. Li, "Fuzzy petri nets for rule-based pattern classification," Communications, Circuits and Systems and West Sino Expositions, IEEE 2002 International Conf. on, vol. 2, pp. 1218-1222, 2002.
- [7] J. W. Go, G. H. Han, H. B. Kim, C. H. Lee, "Multigradient: A New Neural Network Learning Algorithm for Pattern Classification," Geoscience and Remote Sensing, IEEE Trans. on, vol. 39, pp. 986-993, May, 2001.
- [8] Y. L. Murphree, Y. Luo, "Feature Extraction for a Multiple Pattern Classification Neural Network System," Pattern Recognition, 2002. Proceedings. 16th International Conf. on, vol. 2, pp. 220-223, 2002.
- [9] L. O. Chua, and L. Yang, "Cellular Neural Networks: theory," IEEE Trans. on Circuits Systems, vol. 35, pp. 1257-1272, 1988.
- [10] L. O. Chua, and L. Yang, "Cellular Neural Networks: applications," IEEE Trans. on Circuits Systems, vol. 35, pp. 1273-1290, 1988.
- [11] T. Roska and L. O. Chua, "The CNN universal machine: an analogic array computer," IEEE Trans. on Circuits Systems II, CAS-40, pp. 163-173, 1993.
- [12] S. Espejo, R. Dominguez-Castro, G. Linan, A. Rodriguez-Vazquez, "A 64×64 CNN universal chip with analog and digital I/O," Electronics, Circuits and Systems, 1998 IEEE International Conf. on, vol. 1, pp. 203-206, 1998.
- [13] R. Bellman, "Dynamic Programming," Princeton, NJ: Princeton Univ. Press, 1957.
- [14] H. Kim, H. Son, T. Roska, L. O. Chua, "Optimal path finding with space- and time-variant metric weights with Multi-layer CNN," International Journal of Circuit Theory and Applications, vol. 30, pp. 247-270, Feb. 2002.
- [15] Analogical and Neural Computing Lab, "SimCNN-Multi-layer CNN Simulator for Visual Mouse Platform: Reference Manual version 2.2." Computer and Automation Institute(MTA SzTAKI) of the Hungarian Academy of Science, 1998.

## 저자 소개



오태원 (吳泰完)

1977년 2월 8일생. 2002년 전북대 제어계 측공학과 졸업. 2002년~현재 동 대학원 제어계측공학과 석사과정  
Tel : 063-270-2477, Fax : 063-270-2451  
E-mail : control@mail.chonbuk.ac.kr



이혜정 (李惠淨)

1979년 5월 11일생. 2003년 전북대 제어계 측공학과 졸업. 2003년~현재 동 대학원 제어계측공학과 석사과정  
Tel : 063-270-2477, Fax : 063-270-2451  
E-mail : docdagury@orgio.net



손홍락 (孫弘樂)

1973년 5월 26일생. 1996년 전북대 제어계 측공학과 졸업. 1998년 전북대학교 대학원 전기공학과 석사. 2003년 전북대학교 전자공학과 박사. 2000. 03~현재 전북대 메카트로닉스 연구센터 연구원  
Tel : 063-270-2477, Fax : 063-270-2451  
E-mail : hrson2@chol.com



김형석 (金炯奭)

1956년 1월 21일생. 1980년 한양대학교 전자공학과 졸업. 1982년 전북대학교 대학원 전자공학과 졸업. 1992년 University of Missouri, Columbia, Dept. of Electrical and Computer Eng. 박사. 1993. 09~현재 전북대학교 부교수  
Tel : 063-270-2477, Fax : 063-270-2451  
E-mail : hskim@moak.chonbuk.ac.kr