

회전 및 이동 영상을 이용하는 모듈 구조 신경망 기반 필기체 숫자 인식

임 길 택[†] · 남 윤 석^{††} · 전 성 일^{†††}

요 약

본 논문에서는 필기체 숫자 인식을 위한 방법으로서 회전과 이동 영상을 이용하는 모듈 구조의 신경망 기반 인식 방법을 제안한다. 전체 숫자 패턴 공간은 서로 중첩되는 여러 개의 작은 군집으로 나뉘어지는데, 이 군집들 상에서 전문가방으로 동작하는 MLP 신경망들이 구현된다. 그리고 군집마다 구현된 MLP들을 결합하기 위하여 게이팅망을 또한 MLP로 구현하였다. 학습 단계에서는 입력 숫자 영상에 회전과 이동의 디터링 연산을 가함으로써 얻은 새로운 숫자 영상들을 이용하여 학습 한다. 인식 단계에서는 입력 영상만을 인식하지 않고 입력 영상과 회선 및 이동된 영상들을 이용하여 인식한다. 이 과정에서 여러 개의 인식기 출력값들이 계산되는데, 이들을 다양한 방법을 이용하여 결합함으로써 최종 인식을 한다. 실험 결과 개안한 필기체 숫자 인식 방법이 우수한 인식 성능을 보임을 알 수 있었다.

Handwritten Numeral Recognition Based on Modular Neural Networks Utilizing Rotated and Translated Images

Kil-Taek Lim[†] · Yun-Seok Nam^{††} · Sung-Il Chien^{†††}

ABSTRACT

In this paper, we propose a modular neural network based classification method for handwritten numerals utilizing rotated and translated images of an input image. The whole numeral pattern space is divided into smaller spaces which overlap each other and form multiple clusters. On these multiple clusters, multiple multilayer perceptrons (MLP) neural networks, specialized in those clusters, are constructed. Thus, each MLP acts as an expert network on the corresponding cluster. An MLP is also used as a gating network functioning as a mediator among the multiple MLPs. In the learning phase, an input numeral image is dithered by two geometric operations of translation and rotation so that new numeral images similar to original one are generated. In the recognition phase, we utilize not only input numeral image, but also newly generated images through the rotation and the translation of the original image. Thus, multiple output values for those generated images were combined to make class decision by various combination methods. The experimental results confirm the validity of the proposed method.

1. 서 론

일반적으로 인식 대상 패턴들이 매우 복잡한 결정

경계를 이루는 경우 간단한 구조로는 높은 인식률을 얻기가 매우 힘들다. 따라서 이러한 복잡한 인식문제들을 해결하기 위해서 최근의 연구들은 다중 특징 및 다중 인식기를 이용하는 복잡한 구조를 가지는 인식시스템에 대한 연구로 진행되어 왔다[1-7]. 이러한 다중 인식기에 대한 연구는 크게 다음과 같이 나눌 수 있

† 정회원 · 한국전자통신연구원 우정기술연구부 신임연구원
†† 정회원 · 한국전자통신연구원 우정기술연구부 우정전자등록팀장
††† 정회원 · 경북대학교 전자전기공학부 교수
논문접수 2000년 2월 15일. 심사완료 2000년 5월 29일

다 첫째, 다중 특징을 이용하여 각 특징별로 인식기를 구현한 후 인식기들을 결합하여 인식률을 향상시킨다. 이 경우 각 인식기는 각 특징에 대해서 전문가망으로 동작하는데 서로 다른 폐턴공간에서 구현된 인식기를 통합하여 인식한다[8-10]. 둘째, 다중 인식기는 서로 다른 알고리즘이나 구조로 구현되어 결합된다[11, 12]. 셋째, divide and conquer의 방법을 적용하여 대분류 후 상세분류를 통해 인식을 하는데 이 경우 폐턴공간을 보다 작은 공간으로 나누고 각 인식기들은 나누이진 특정한 폐턴공간내에서 동작하게 된다[13-15].

문자 인식에 대한 연구는 작성된 문자의 형태에 따라서 필기체와 인쇄체 인식, 그리고 인식 대상 클래스 수에 따라서도 인식의 난이도가 다르므로 인식 대상에 따라 다양한 방법이 적용되어왔다. Kimura [12] 등은 필기체 숫자 인식에서 두 가지 알고리즘을 이용하여 인식기를 구현하였는데, 사용하는 특징에 따라 통계적 인식기와 트리 인식기를 구현하여 결합하였다. 다중 특징을 이용하는 연구로 Shrihari 등[9]은 다섯 종류의 특징에 대해 각각의 신경망 인식기를 구현하고 결합하였다 Cao 등[13]은 다중특징과 단단계인식 방법을 이용하여 필기체 숫자 인식 시스템을 구현하였다. 인식 방법은 인식 단계별로 서로 다른 특징을 이용하여 대분류 후 상세분류 과정을 거쳐 인식을 하는 형태이다. Suen 등 [16]은 다중 전문가 시스템을 제안하였는데 4개의 알고리즘을 이용하여 각각의 전문가 시스템을 구현하고 이를 결합하여 높은 인식률을 얻었다. Togawa 등[17]은 3단계로된 계층적 구조의 인식 방법으로 다중 LVQ (learning vector quantization)를 이용하여 간지 인식시스템을 구현하였다. 이 방법에서는 각 LVQ방에 대해 유사 폐턴간의 분별력을 높이기 위해 각 군집마다 서로 다른 수용 영역을 가지게 한 것이다 특징이다. Itawa 등 [18]은 하나의 스템망 (stem network)과 다수의 브렌치망 (branch network)으로 이루어진 CombNet-II를 제안하였다. 스템망은 입력 폐턴과 각 군집 대표벡터간의 유사도에 따라 대분류를 하고 상세분류기로서 MLP (multilayer perceptrons)를 이용하는데, 스템망의 출력이 브렌치망의 출력과 결합되어 인식이 된다.

본 논문에서는 케이팅망과 모듈화된 MLP 구조를 가지며 입력 숫자 영상에 회전과 이동 연산의 디더링 (dithering) 방법을 이용하는 필기체 숫자인식 방법을 제안한다. 필기체 숫자 인식기의 구현을 위해 전체 폐

턴 공간을 서로 중첩하는 보다 작은 공간으로 나누고 다중 군집을 구성한다. 초기 다중 군집의 구성은 SOM (self organizing map) 망을 이용하였는데 각 군집의 반경에 따라 서로 중첩하게 하여 새로운 군집을 만들었다. 구성된 각 군집에 대해서 전문가망으로 동작하는 MLP를 구현하고 이를 결합시키기 위해 케이팅 기능의 MLP를 구현한다. 학습단계에서 각 군집을 담당하는 전문가 MLP들과 케이팅망은 각각 분리되어 학습이 된다. 이 단계에서 각 학습 문자들에 대해 회전과 이동의 두 가지 디더링 과정을 수행함으로써 확장된 학습문자 집합이 생성된다. 인식 단계에서는 입력된 숫자 영상에 대해 케이팅망이 각 군집 MLP들의 출력값을 가중함으로써 각 클래스에 대한 신뢰도값이 출력된다. 이 단계에서는 기존의 방법들과 달리 입력 영상만을 인식하지 않고 입력 영상과 그것의 회전 및 이동된 영상들을 이용하여 인식한다. 이 과정에서 각 영상을마다 인식기의 출력값들이 서로 틀리며, 인식 결과도 다르게 나타날 수 있다. 본 논문에서는 이러한 서로 다른 여러 개의 인식기 출력값들을 다양한 방법으로 결합함으로써 최종 인식을 하였다. 인식실험은 무제약 필기체 숫자에 대해서 이루어졌는데 제안한 인식시스템이 매우 높은 인식률을 보였다.

2. 군집의 생성과 확장

2.1 SOM망을 이용한 초기 군집의 생성

대규모의 문자인식에 대한 전략 중 하나로 'divide and conquer' 방법이 많이 적용되어 왔다[15]. 이러한 전략을 위해서는 군집화 과정이 필요인데 K-means [19], SOM [20] 등의 알고리즘이 많이 이용된다. 본 논문에서는 학습 폐턴들에 대해 SOM 알고리즘을 이용하여 초기 군집을 구성하였다. 학습 후의 SOM망 출력노드들은 학습 문자집합의 확률 분포를 나타내게되고 군집의 대표 벡터로 사용될 수 있다. N_T 개로 이루어진 학습 샘플 집합을 $S = \{X_k, k=1, 2, \dots, N_T\}$ 이라 할 때 이 집합은 M 개의 분리된 부분집합 $S_i, i=1, 2, \dots, M$ 으로 나누어진다. 이 때 부분집합 S_i 를 군집 i 라 한다. 입력문자들을 군집에 레이블링하기 위해서는 출력노드와의 유사도를 계산하는데 군집 i 의 대표벡터를 SOM의 i 번째 출력노드에 해당하는 w_i 벡터로 할 때 다음과 같이 계산된다.

$$d_i(X_k) = \|X_k - w_i\| = \sqrt{\sum_{n=1}^N (x_n - w_{in})^2} \quad (1)$$

이 식에서 N 은 패턴의 차원이며 w_n 은 군집 대표벡터의 n 번째 성분이다. 그러므로 가장 매칭이 잘되는 출력노드는 다음과 같이 결정된다.

$$d_m(X_k) = \min_i d_i(X_k), i=1, 2, \dots, M \quad (2)$$

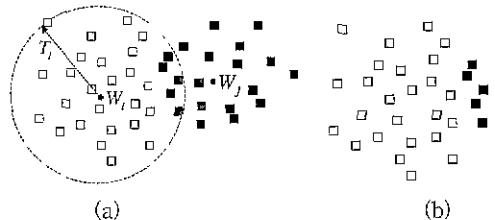
위 식을 계산하면 입력 패턴벡터 X_k 는 군집 m 에 속하게 된다. S 의 모든 패턴벡터에 대해 레이블링 과정을 거치면 S 는 M 개의 분리된 집합으로 나누어진다.

2.2 군집의 확장

제충적이며 모듈 구조를 가지는 일반적인 문자인식기는 대부분 후 상세분류 과정을 거쳐 인식을 하게 된다. 이 경우 대부분 단계에서 일어나는 오류는 상세 분류 단계까지 전파가 된다 실제 S 에 속하는 패턴이 S 상에서 학습된 인식기에 입력될 때 인식결과는 완전히 잘못될 것이다. 그러므로 이러한 오류를 감소시키기 위해서는 군집화 단계에서 많은 주의가 요구된다. 일반적인 군집화 형성하는 방법은 샘플 패턴공간을 서로 중첩되지 않게 즉, 군집원들이 충복되지 않게 분리되게 나누게 된다. 그러나 본 논문에서는 군집들이 위치하는 샘플 패턴공간을 서로 중첩되게 나누는 방법으로 군집을 확장하였다 즉, 어떤 특징 군집 S_i 의 영향권 내에 들어올 수 있는 다른 군집의 패턴들을 군집 S_i 의 원소로 함으로써 군집 S_i 를 확장하는 것이다 SOM의 각 출력노드에 의해 정의될 수 있는 샘플 집합 S_i 는 반경 T_i 에 따라 식 (3)과 같이 \tilde{S}_i 로 확장된다.

$$\tilde{S}_i = \{X_k | \|X_k - W_i\| \leq T_i, k=1, 2, \dots, N_T\} \quad (3)$$

여기서, $T_i = \max \|X_k - W_i\|$, for $X_k \in S_i$ 이다. 이와 같은 과정을 그림 1에 개념적으로 나타내었다 (그림 1)의 (a)에서 흰 사각형으로 표현된 패턴은 W_i 에 가깝고 검은 사각형으로 표현된 패턴은 W_j 에 가깝게 위치한다 따라서 군집 S_i 는 흰 사각형 패턴들을 포함하고 S_i 는 검은 사각형 패턴을 포함한다 (그림 1)의 (a)를 보면 S_i 에 있는 5개의 패턴들이 T_i 에 의해 정의되는 흰 사각형 패턴 영역에 위치하므로 (그림 1)의 (b)와 같이 \tilde{S}_i 에 새롭게 추가된다.



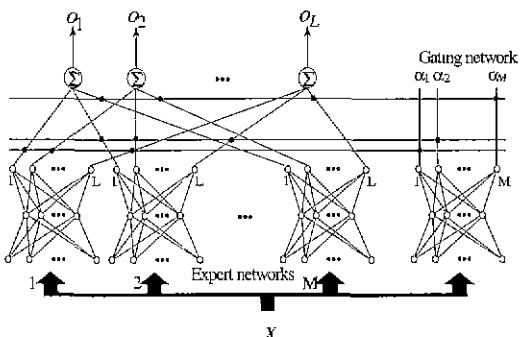
(그림 1) S_i 와 확장된 \tilde{S}_i . (a) S_i : 흰 사각형들 S_i , 검은 사각형들 (b) \tilde{S}_i .

3. MLP 모듈 구조의 문자인식기

본 논문에서는 확장된 각 군집마다 MLP 신경망을 적용하는 모듈구조의 숫자 인식기로 무제약 필기체 숫자 인식을 한다. M 개의 확장된 특정 군집에 대해서 M 개의 MLP들이 학습되어 해당 군집에 대해서 상세분류 기로서 동작한다. 즉, 각 MLP는 해당 군집에 대한 전문가망으로 동작한다. 그러므로 입력이 된 숫자가 해당 MLP이외의 MLP에 의해 인식된다면 그 인식 결과는 잘못될 가능성이 매우 많다. 따라서, 적절한 MLP의 설정을 해주는 MLP 선택기, 즉 게이팅망(gating network)이 필요하다. 이를 위해서 본 논문에서는 MLP를 이용하여 게이팅망을 구현한다. 이때 게이팅망의 출력노드의 개수는 전체 군집 천문가 MLP의 수와 같아야 한다. 이러한 동작을 하는 인식기의 전체 구조를 (그림 2)에 나타내었다. (그림 2)의 인식기에서 어떤 특정 클래스 i 에 대한 인식기의 출력값은

$$o_i = \sum_{k=1}^M o_i^k f_i^k \quad (4)$$

와 같다. 여기서 o_i 는 클래스 i 에 대한 출력값이고,



(그림 2) 제안된 인식기의 구조

a^k 는 k 번째 군집에 대한 계이팅망의 출력값으로써 입력 패턴이 k 번째 군집에 속할 가능성을 나타낸다. f_i^k 는 k 번째 MLP의 클래스 i 에 대한 출력값을 나타낸다. (그림 2)의 인식기의 결정규칙은 a_m 이 식 (5)와 같이 계산될 때 입력패턴의 클래스는 m 으로 결정된다

$$o_m = \max o_i, i=1, 2, \dots, L \quad (5)$$

4. 입력 숫자 영상의 디더링

필기체 숫자는 필기 형태와 도구, 그리고 환경 등에 따라 매우 많은 변형을 보인다. 이러한 무제약 필기체 숫자에 대한 완전한 인식을 위해서 고려될 수 있는 것 중 하나는 변형되어 나타날 수 있는 모든 숫자 형태를 확보하는 것이다. 그러나 실제의 경우에 있어서 이러한 대처방법은 불가능하므로 입력 문자에 대한 비선형 정규화 방법[21] 그리고 영상결합모델 방법 [22]등이 연구되었다. 본 논문에서는 필기체 숫자 패턴에 대해 비선형 정규화 방법은 적용하지 않고 회전과 이동 연산을 통한 디더링을 함으로써 확보되는 학습 숫자 집합을 확장하고자 하였다.

4.1 입력 영상의 회전

숫자 영상 $f(x, y)$ 는 $f'(x', y')$ 로 생성된다. θ 만큼 회전된 좌표는 회전되어서

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} \quad (6)$$

와 같이 얻어진다.

4.2 입력 영상의 이동

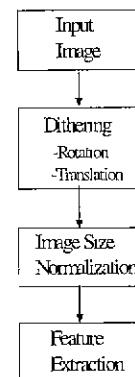
숫자 영상 $f(x, y)$ 는 $f'(x', y')$ 로 생성된다. 수평과 수직방향으로 각각 dx , dy 만큼 이동되는 좌표는

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} x \\ y \end{bmatrix} + \begin{bmatrix} dx \\ dy \end{bmatrix} \quad (7)$$

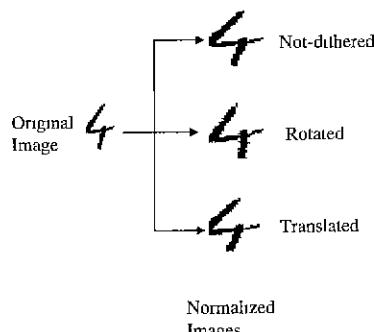
와 같이 얻어진다.

입력 숫자 영상은 특징벡터의 형태로 변환되어서 인식기에 입력되는데 특징추출과정은 (그림 3)과 같다. 디더링된 영상의 최소 외접사각형 내의 영상에 대해 크기 정규화를 한 후 특징이 추출된다. 영상의 좌표는

입력 영상의 최소 외접사각형의 좌상 꼭지점인 ($x=0$, $y=0$)가 원점이 된다. 이동의 경우에 디더링된 영상의 최소 외접사각형은 입력영상의 최소 외접사각형과 같다. 즉, x 또는 y 가 0보다 작거나, 입력영상의 최소외접사각형의 넓이나 높이보다 큰 영역에서는 특징이 추출되지 않고 무시된다. (그림 4)에 입력 문자 영상에 디더링을 가했을 때 예를 나타내었는데, 회전 영상은 원시 영상을 10° 회전한 후 크기 정규화를 한 것이고, 이동 영상은 원시 영상을 좌로 2화소, 즉, $dx = -2$, $dy = 0$ 로 이동한 것이다. 이동 영상은 원시영상의 원쪽 2 화소들을 제거하고 오른쪽 2화소에는 흰화소로 채운 것이다. 실제의 경우에는 접촉된 인접 문자들을 분리해낼 때 화소의 제거 현상과 회전 현상은 자주 일어나는 현상이다. 2가지 디더링 방법으로 생성된 새로운 문자 영상들은 실제의 경우에서도 동일한 클래스로 나타날 가능성이 있는 것을 알 수 있다.



(그림 3) 특징 추출과정

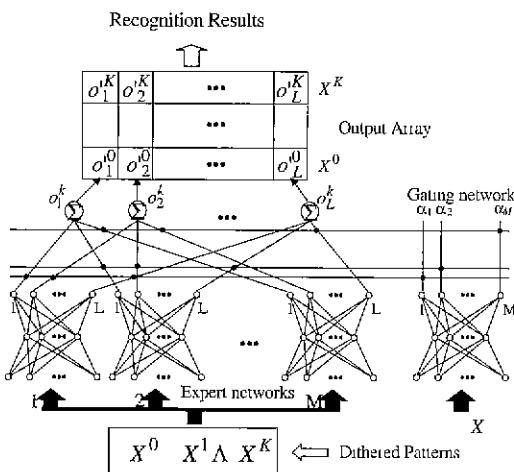


(그림 4) 영상 디더링의 예

5. 디더링 영상을 이용한 인식

구현된 인식기에 입력된 숫자가 학습에 사용된 숫자와 유사하다면 인식기는 높은 출력값을 나타낼 것이다. 그러나 학습에 사용된 숫자와 매우 다른 형태를 가지는 숫자들에 대해서는 인식성능이 저하될 가능성이 높게 된다. 본 논문에서는 이러한 문제점에 대처하기 위해, 인식단계에서 기준의 다른 방법과 다르게 입력 숫자만을 이용하지 않고, 입력 숫자 영상과 그것의 회전 및 이동된 영상을 이용함으로써 인식성능을 높이고자 한다.

입력 패턴에 대해 K 개의 디더링 숫자들이 생성되어 인식기에 입력된다. 원시 입력 문자와 각각의 디더링 숫자들은 (그림 5)와 같이 인식기에 입력되어 그 출력값들이 출력 베열에 저장된다. 이러한 $K+1$ 개의 출력벡터 값들을 이용하여 최종 인식 클래스를 결정하기 위해서 다양한 방법들을 이용한다.



(그림 5) 제안된 인식기의 인식 방법

인식기의 출력값들을 결합하는 각 방법들을 설명하기 위한 심볼들은 다음과 같다. 디더링 숫자 X^k 가 입력될 때 클래스 i 에서의 출력값은

$$o_i^k = \sum_{m=1}^M \alpha_m f_i^m(X^k) \quad (8)$$

와 같다. 여기서 M 은 전체 MLP의 수와 같다. 디더링된 각 문자들에 대한 각 MLP의 출력값들은 출력 베열에 변환되어 저장되는데 이들은 결합방법에 따라 결합된다.

o_i^k 의 변환된 값을 o'_i^k 로 두고, $A = \{1, 2, \dots, L\}$ 을 L 개의 클래스 레이블의 집합으로 정의한다. 또한 입력 숫자 X 를 디더링한 후 생성된 모든 숫자들에 대한 출력값들을 결합한 후의 인식 클래스를 $D(X)$ 로 정의한다. 예를 들어 주어진 X 가 클래스 j 로 분류될 때 $D(X) = j$ 가 된다. <표 1>에 본 논문에서는 사용한 디더링 된 패턴들에 대한 인식기 출력값들을 결합하는 다양한 방법들을 나타내었다.

<표 1> 인식기 출력값의 결합 방법 요약

Methods	o'_i^k	Decision
method I-1	o_i^k	
method I-2	$\frac{1}{s^k} o_i^k$	
method II-1	$(o_j^k - o_{j'}^k) \delta_{jj'}$	
method II-2	$\frac{1}{s^k} (o_j^k - o_{j'}^k) \delta_{jj'}$	$D(X) = j,$ if
method II-3	$(\frac{1}{s^k} o_i^k + (1 - o_{j'}^k / o_j^k)) \delta_{jj'}$	$j = \arg \max_{i \in A} \sum_{k=0}^K o_i^k$
method III-1	$\delta_{jj'}$	
method III-2	$o_j^k \delta_{jj'}$	
method III-3	$\frac{1}{s^k} o_j^k \delta_{jj'}$	

출력값들을 결합하는 가장 간단한 방법은 출력 베열에 있는 출력값들을 단순히 합하는 것이다(방법 I-1). 이 경우에는 변환값은

$$o'_i^k = o_i^k \quad (9)$$

와 같다. 최종 인식 결과는 식 (10)과 같이 주어지는데 본 논문에서 사용하는 모든 방법에 대해 동일한 결정 함수가 이용된다.

$$D(X) = j, \text{ if } j = \arg \max_{i \in A} \sum_{k=0}^K o_i^k \quad (10)$$

즉, A 에 속하는 1에서 L 까지의 모든 클래스에 대한 출력값들 중 가장 높은 출력값을 가지는 클래스를 인식 결과로 취한다. 방법 I-2에서는 출력값 o_i^k 를 정규화하여 결합한다. 즉,

$$s^k o'_i^k = o_i^k \quad (11)$$

가 된다. 여기서 $s^k = \sum_{i=1}^L o_i^k$ 로 k 번째 디더링된 패턴에

대한 스케일로서 $\frac{1}{s^k} \sum_i o_i^k = \sum_i o_i^k = 1$ 이 된다.

방법 II에서는 세 종류의 결합방법이 있는데 주어진 입력 패턴에 대한 인식 신뢰도지수에 따라 출력값들이 결합된다. k 번째 디터링 숫자에 대한 신뢰도를 r_f^k 라 할 때 신뢰도는 방법 II-1에서

$$r_f^k = o_j^k - o_{j'}^k \quad (12)$$

와 같다. 여기서 $o_j^k = \max_{j \in A} o_j^k$ 으로 X^k 에 대한 L 개의 출력값 중 최대값이며 $o_{j'}^k = \max_{j \in A_2} o_j^k$ 는 두 번째 큰 값으로 j' 는 최대값의 인덱스이며 j^2 는 두 번째 최대값의 인덱스이다. 이때 $A_2 = A - \{j^*\}$ 이다. 방법 II-1에서의 변환값은

$$o_i^k = r_f^k \delta_{ij} \quad (13)$$

으로 하였다. 이때 $i=j$ 이면 $\delta_{ij}=1$ 이고, 그렇지 않으면 $\delta_{ij}=0$ 이다. 이 방법에서는 주어진 디터링 문자에 대해 인식시스템 출력 최대값을 신뢰도지수로 바꾸고 나머지 값들은 0으로 두는 것이다. 방법 II-2에서는 방법 I-2와 같은 정규화 과정을 거친다. 즉,

$$o_i^k = \frac{1}{s^k} r_f^k \delta_{ij} \quad (14)$$

이 된다. 방법 II-3에서는 Takahashi 등이 [23]에서 제시한 신뢰도 지수를 사용한다. 이 경우에

$$r_f^k = \frac{1}{s^k} o_j^k + (1 - o_j^k / o_{j'}^k), \quad (15)$$

$$o_i^k = r_f^k \delta_{ij} \quad (16)$$

와 같이 하였다.

방법 III-1에서는 인식기의 출력값들을 결합하는 다른 방법으로 보우팅을 사용한다. 이를 위해서 변환값은 최대값의 경우에 1이 되고 그렇지 않은 경우에는 0이 된다. 그러므로 변환값은

$$o_i^k = \delta_{ij} \quad (17)$$

이 된다. 이 방법을 조금 변형한 것이 방법 III-2와 III-3으로 각각 식 (18)과 (19)에 따라 o_i^k 가 계산된다.

$$o_i^k = o_j^k \delta_{ij} \quad (18)$$

$$o_i^k = \frac{1}{s^k} o_j^k \delta_{ij} \quad (19)$$

방법 III-2는 방법 III-1을 출력값으로 가중한 것이다. 방법 III-3은 정규화하여 가중한 것이다.

6. 인식실험

6.1 SOM을 이용한 군집 생성과 군집의 확장

본 논문의 실험에 사용한 데이터는 Concordia대학교의 필기체 숫자 데이터베이스이다. 이 데이터베이스는 0에서 9까지의 숫자가 각 600자씩 6000자로 구성되어 있다. 이 중 상위 4000자는 학습에 사용하였고 하위 2000자는 테스트에 사용하였다. SOM을 이용하여 초기 군집을 만들 때 입력 특징으로는 144차원으로 된 숫자영상의 기울기 벡터[34]에서 추출된 54차원의 주성분벡터[25]로 하였다. 출력노드는 36개이며 0.85의 초기학습률로 100회 반복 학습하였다.

6.2 군집별 전문가 MLP의 학습

확장된 군집들에서 학습되는 MLP들은 모두 동일한 구조를 가진다. 입력 특징으로는 숫자 영상의 기울기 벡터에 대한 주성분 벡터를 사용하는데 군집 생성에서 와 다르게 144차원으로 되어있다. 입력 노드의 개수는 144이며 출력 노드의 개수는 10개이며 은닉층의 노드 수는 30개이다. 목표벡터는 입력 패턴의 클래스에 해당하는 성분은 1로 두고 나머지 성분은 0로 하였다. 학습률은 0.1로 하였고 관성항은 0.7 최대 학습 반복 횟수는 100회로 제한하였다.

입력 숫자 영상을 디터링할 때 θ 는 5와 10로 두어 4개의 세로운 숫자 영상을 만들어 내었다. θ 를 이렇게 둔 이유는 학습 숫자 영상들을 직접 관찰해보면 5° 이하로 회전시킬 경우 영상의 변형이 두드러지지 않으며 10° 보다 크게 회전시킬 경우 변형이 너무 크다고 판단되었기 때문이다. 이동의 경우는 dx 와 dy 를 2로 제한하였다. 이 경우 25개의 조합이 존재하게되는데 $\max(|dx|, |dy|)$ 가 2보다 작은 경우를 제외하였다. 이동 변이가 작을 때는 입력 영상의 변화가 작아 디터링의 효과가 거의 나타나지 않기 때문이다. 그러므로 이동의 경우는 16개의 세로운 조합이 가능하여 전체 20개의 디터링 영상이 생성될 수 있다. 실제 실험에 있어서 이들을 모두 저장한 다음에 학습을 하게 된다면 매우 큰 메모리가 필요하고 학

습 속도가 엄청나게 느려지게 된다. 그러므로 본 논문의 실험에서는 이들을 오프라인으로 미리 생성시키지 않고 원시 영상을 가지고 매 학습 반복마다 θ 와 dx , dy 를 랜덤으로 발생시켜 훈련을 하였다.

6.3 게이팅망의 학습

케이팅망의 학습에서 입력 특징은 군집생성의 경우와 마찬가지로 54차원의 주성분벡터이다. 따라서 입력 노드의 수는 54가 된다. 은닉층의 노드 수는 25개로 하였고 출력층의 노드는 군집의 개수인 36개가 된다. 학습률은 0.1이고 관성항은 0.7로 하였다. 목표벡터는 입력 패턴이 속하는 군집에 해당하는 성분은 1로 하고 나머지는 0으로 하였다. 어떤 패턴이 0번군집, 2번군집, 3번군집에 속한다고 하면 36차원의 목표벡터에서 처음 3개성분만 1이고 나머지는 0이 된다.

6.4 인식결과

<표 1>에 있는 각 방법에 대한 인식실험 결과를 <표 2>에 나타내었다. <표 2>의 두 번째 열에 나타낸 결과는 4개의 회전영상, 16개의 이동영상과 원시 입력영상 등 21개 ($k=0, 1, \dots, 20 : K=20$)의 영상을 사용한 경우이다. 인식 결과를 살펴보면, 방법 III-2와 III-3의 경우를 제외한 모든 다른 방법들이 98% 이상의 높은 인식률을 보이므로 어떠한 방법이 보다 낫다고 단언하기는 힘들다. 이러한 인식률들은 동일한 데이터베이스에 대한 다른 연구 결과들[1, 2]에 비해 우수한 성능이다.

〈표 2〉 인식기의 출력값 결합 방법에 따른 인식률

Methods	Recognition rate(%)	
	Full dithered images (K = 20)	Highly variational dithered images (K = 6)
method I-1	98.10	98.30
method I-2	98.05	98.30
method II-1	98.05	98.15
method II-2	98.05	98.20
method II-3	98.00	98.25
method III-1	98.10	98.05
method III-2	97.50	98.05
method III-3	97.90	98.15

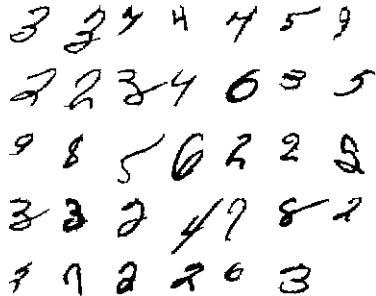
학습 단계에서 조금만 이동된 영상들은 배제하였지만 테스트에 사용된 16개의 이동 영상 중에서도 여전히 원시영상과 비슷한 형태를 가져 인식기의 출력값들이 유사하게 나타나는 경우가 있다. 또한 이동영상은 회전

영상에 비해 많이 생성되므로 최종 인식결과는 이동된 영상들에 보다 더 많은 영향을 받게 된다. 따라서, 변형이 많은 영상들만에 대한 인식성능을 알아보기자 이동 영상을 제한시켜보았다. 이때 $\theta = (+10, -10, +5, -5)$ 로 4종류로 하고 이동의 경우 (dx, dy) 는 $(-2, -2), (+2, +2)$ 의 2 가지로 하였다. 그러므로 7개의 영상($k = 0, 1, \dots, 6$, $K = 6$)이 생성되는데 이에 대한 인식 실험 결과를 <표 2>의 세번째 열에 나타내었다. 방법 III-1의 경우를 제외하고는 모든 방법들이 K 가 6인 경우의 인식률이 더 나음을 알 수 있다. 그런데 다른 방법들이 기각률 0%에서 인식률이 계산되는데 방법III-1의 경우는 기각률이 0.25%가 있어 인식률만의 비교로 이 방법의 인식 성능이 못하다고 단언하기는 힘들다.

다양한 방법들의 인식 결과를 살펴보면 $K=20$ 인 경우에는 이미 언급하였다시피 인식률이 비슷하게 나타나지만, $K=6$ 인 경우를 보면 방법 I 그룹이 다른 방법들 보다 우수함을 알 수 있다. 이는 방법 I 그룹에 비해서 방법 II와 III그룹이 사용하는 정보. 즉, σ^2 이 상대적으로 줄어들었기 때문으로 판단된다. 마찬가지 이유로 방법 III 그룹이 각 디더링 숫자에 대한 최고 출력값 정보만을 이용하는데 반해 방법 II그룹은 제 2 순위 최고값도 이용하므로 약간 인식률이 높게 나온 것으로 판단된다. 각 방법 그룹내에서 σ^2 의 정규화가 미치는 영향을 살펴보면 거의 무시해도 될 만한 것으로 나타남을 또한 알 수 있다.

인식기의 특성에 관한 예로써 방법 I-2를 적용했을 때의 혼동행렬을 <표 3>에 나타내었다. 또한 이 방법에서 오인식이 일어난 모든 숫자 영상의 예를 (그림 6)에 나타내었다. (그림 6)의 (b)는 혼동쌍으로 팔호안의 왼쪽의 숫자가 올바른 클래스이며 오른쪽의 숫자는 잘못 인식된 클래스이다. 오인식 숫자를 살펴보면 숫자 2와 3에서 특히 오인식이 많이 있었고 사람의 판단으로도 인식하기 힘든 경우 있다.

〈표 3〉 제안된 방법 |-2의 흐름 행렬



(a) 숫자 영상들

(그림 6) 인식 결과 오류 숫자

<표 4> 디더링의 효용성 테스트 실험 결과

Methods	Learning	Tesung	Recognition rate	Remark
LN-TN	No dithering	No dithering	96.20	
LN-TD	No dithering	Dithering	96.30	
LD-TN	Dithering	No dithering	97.95	
LD-TD1	Dithering	Dithering	98.30	method I-2
LD-TD2	Dithering	Dithering	98.20	method II-2
LD-TD3	Dithered	Dithering	98.25	method II-3

본 논문에서 제안된 인식 방법은 입력 영상만을 이용하는 것이 아니라 회전과 이동의 디더링 과정을 통해 원은 변형된 영상들도 이용하고 있다. 이러한 본 논문의 제안한 방법이 효용성이 있는지를 실험하여보았다. <표 4>는 디더링 방법의 효용성을 보여주는 것으로, 여기에서 'L'은 학습을 나타내며 'T'는 테스트, 즉, 인식을 나타낸다. 또한 'D'는 디더링, 'N'은 디더링을 하지 않았다는 것을 나타낸다. 인식단계에서 디더링을 하지 않은 경우들은 단순히 그림 2의 인식기의 출력값만으로 최종 인식을 하는 경우이다. 이 표를 살펴보면 학습 단계에서만 디더링을 행하는 LD-TN 방법이 인식 단계에서만 디더링을 하는 경우인 LN-TD 방법보다 우수하였다. 즉, 회전과 이동의 디더링 방법은 인식 단계에서 보다 학습 단계에서 디더링을 하는 것이 인식률이 보다 높음을 알 수 있다. 그러나, 학습과 인식 단계 모두에서 디더링을 한 경우인 LD-TD1, LD-TD2, LD-TD3의 인식률들이 가장 높음을 알 수 있다. 여기서 한가지 주목 할 점은 LD-TN의 경우 97.95%의 인식률인데, <표 2>의 방법 III-2와 III-3에서 $K=6$ 인 경우의 인식률은 LD-TN보다 높지만, $K=20$ 인 경우의 인식률은 이보다 낮게 나왔다. <표 2>의 실험 결과에서도 알 수 있었지만, 서

[3, 8] [3, 2] [7, 4] [4, 8] [7, 4] [5, 1] [9, 3]
[2, 8] [2, 8] [3, 4] [4, 9] [6, 0] [3, 5] [5, 3]
[9, 8] [8, 6] [5, 4] [6, 0] [2, 8] [2, 8] [2, 3]
[3, 2] [3, 2] [2, 8] [4, 1] [7, 9] [8, 4] [2, 8]
[3, 9] [7, 9] [2, 8] [2, 8] [6, 0] [3, 8]

(b) 혼동쌍 [올바른 클래스, 오인식된 클래스]

로 유사한 디더링 영상을 너무 많이 이용하면 인식률이 도리어 떨어짐을 알 수 있다.

7. 결 론

이 논문에서는 필기체 숫자를 인식하기 위하여 회전과 이동 영상을 이용하는 모듈 구조를 가지는 신경망 기반 인식 방법을 제안하였다. 인식시스템의 구현을 위해 전체 패턴 공간을 서로 중첩하는 보다 작은 공간으로 나누고 다중 군집을 구성하였다. 초기 다중 군집의 구성은 SOM 망을 이용하였는데 각 군집의 반경에 따라 서로 중첩하게 하여 새로운 군집을 만들었다. 구성된 각 군집에 대해서 전문가망으로 동작하는 MLP를 구현하고 이를 결합시키기 위해 게이팅 기능의 MLP를 구현하였다. 이때 각 MLP의 학습에 있어서는 학습 집합을 확장하고자 회전과 이동의 22가지 디더링 과정을 거쳐 생성된 패턴들을 포함하였다. 인식기의 동작은 입력된 문자에 대해 게이팅망이 각 군집 MLP들의 출력값을 가중함으로써 각 클래스에 대한 신뢰도 값을 출력한다. 본 논문의 인식 방법은 기존의 방법들과 달리 입력 영상만을 인식하지 않고 입력 영상에 대해서 회전과 이동의 두가지 디더링을 통하여 얻은 새로운 숫자 영상들을 인식하였다. 이때 여러 개의 인식기 출력값이 계산되는데 이들에 대해 다양한 방법들을 적용하여 결합함으로써 보다 높은 인식률을 얻고자하였다. 인식실험 결과 제안한 여러 가지 결합 방법들이 높은 인식률을 보임을 알 수 있었다. 특히, 인식시스템의 디더링 효용성에 관한 실험에서는 학습 단계에서의 디더링이 인식단계에서 보다 더 효과적이며 두 단계 모두에 디더링을 적용한 경우가 가장 좋은 성능을 보

임을 알 수 있었다.

참 고 문 헌

- [1] A. Krzyzak W. Dai, and C. Y. Suen, "Unconstrained handwritten character classification using modified backpropagation model," *Proc. of the First IWFHR*, Montreal, Canada, pp.155-166, 1990.
- [2] S. Cho, "Neural-network classifiers for recognizing totally unconstrained handwritten numerals," *IEEE Transactions on Neural Networks*, Vol.8, pp.43-53, 1997.
- [3] T. Akiyama and N. Hagita, "Automated entry system for printed documents," *Pattern Recognition*, Vol.23, pp.1141-1154, 1990.
- [4] J H Kim, K. Kim, and S Chien, "Korean and English character recognition system using hierarchical classification neural network," *Proc. of ICSMC*, Vancouver, Vol.1, pp 759-764, Oct. 1995.
- [5] D. Lee and S N Srihari, "A theory of classifier combination : the neural network approach," *Proc. of the Third ICDAR*, Montreal, Canada, pp.42-45, 1995
- [6] T. K. Ho, J. J. Hull, and S. N. Srihari, "Decision combination in multiple classifier systems," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.16, pp.66-75, 1994.
- [7] Y. S. Huang and C. Y. Suen, "A method of combining multiple experts for the recognition of unconstrained handwritten numerals," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.17, pp.90-94, 1995
- [8] K. Miyahara and F. Yoda, "Printed Japanese character recognition based on multiple modified LVQ neural network," *ICDAR*, Tsukuba, pp 250-253, 1993.
- [9] S. N. Srihari, "Recognition of handwritten and machine printed text of postal address interpretation," *Pattern Recognition Letters*, Vol.14, pp 291-302, 1993
- [10] Y. M. Baek, K. T. Lim, and S. I. Chien, "Off-line handwritten Hangul recognition based on multiple features and modular partially connected multi-layer perceptrons," *Proc. of IWFHR*, Taejon, pp.269-278, 1998.
- [11] L. Xu, A. Krzyzak, and C. Y. Suen, "Method of combining multiple classifiers and their application to handwritten numeral recognition," *IEEE Transactions on Systems, Man, and Cybernetics*, Vol 22, pp. 418-435, 1992.
- [12] F. Kimura and M. Shridhar, "Handwritten numeral recognition based on multiple algorithms," *Pattern Recognition*, Vol.24, No.10, pp 976-983, 1991.
- [13] J. Cao, M. Ahmadi, and M. Shridhar, "Recognition of handwritten numerals with multiple feature and multistage classifier," *Pattern Recognition*, Vol.28, No.2, pp.153-160, 1995.
- [14] A. Waibel, H. Sawai, and K. Shikano, "Modularity and scaling in large phonemic neural networks," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, Vol.37, pp.1888-1898, 1989.
- [15] B. S. Kang, S. I. Chien, and K. T. Lim, "Large scale pattern recognition system using hierarchical neural network and false alarming nodes," *Proc. of ICTAI*, Newport, California, pp 196-203, Nov. 1997.
- [16] C. Y. Suen, C. Nadal, R. Legault, T. A. Mai, and L. Lam, "Computer recognition of unconstrained handwritten numerals," *Proc. of IEEE*, Vol.80, No.7, pp. 1162-1180, 1992.
- [17] F. Togawa, T. Ueda, T. Aramaki, and A. Tanaka, "Receptive field neural network with shift tolerant capability for Kanji character recognition," *IJCNN*, pp.1490-1499, 1988.
- [18] A. Itawa, H. Kawajiri, and N. Suzumura, "Classification of handwritten digits by a large scale neural network 'CombNET-II,'" *IJCNN*, Singapore, Vol.1, pp.1021-1026, Nov. 1991.
- [19] M. Nadler and E. Smith, *Pattern Recognition Engineering*, John Wiley & Sons, New York, 1993.
- [20] T. Kohonen, "The self-organizing map," *Proc. of IEEE*, Vol 78, No 9, pp.1464-1480, 1990.
- [21] S. Lee and J. Park, "Nonlinear shape normalization methods for the recognition of large-set handwritten characters," *Pattern Recognition*, Vol.27, No.7, pp 895-902, 1994.

- [22] H. S. Baird, "Document image defect models," *IAPR Workshop on SSPR*, Murray Hill, NJ, pp.38~46, 1990.
- [23] H. Takahashi, "A neural network OCR using geometrical and zonal pattern features," *Proc. of ICDAR*, Paris, Vol 2, pp.821~828, 1991.
- [24] G. Srikantan, S. W. Lam, and S. N. Srihari, "Gradient-based contour encoding for character recognition," *Pattern Recognition*, Vol.29, pp.1147~1160, 1996.
- [25] R. Gonzalez and R. Woods, *Digital Image Processing*, Addison Wesley, pp.148~156, 1989.

임 길 택

e-mail : ktlim@ewi.re.kr
1993년 경북대학교 전자공학과
(공학사)
1995년 경북대학교 전자공학과
(공학석사)
1999년 경북대학교 전자공학과
(공학박사)
1999년~현재 한국전자통신연구원 우정기술연구부
선임연구원
관심분야 : 패턴인식, 신경회로망, 영상처리 등



남 윤 석

e-mail : ysnam@etri.re.kr
1984년 아주대학교 산업공학과
(학사)
1989년 Polytechnic Univ (New York), Dept. of Industrial Engineering(공학석사)
1992년 Polytechnic Univ.(New York), Dept. of Industrial Engineering(공학박사)
1993년~현재 한국전자통신연구원 우정기술연구부
우정자동화팀장
관심분야 : 소프트웨어 공학, 패턴인식 등



진 성 일

e-mail : sichien@ec.kyungpook.ac.kr
1977년 서울대학교 전자공학과
(공학사)
1981년 한국과학기술원 전자공학과
(공학석사)
1988년 카네기멜론 대학교 전자
공학과 (공학박사)
1988년~현재 경북대학교 전자전기공학부 교수
관심분야 : 영상처리, 컴퓨터비전, 패턴인식 등