

k 근방 원형상에서 최근방 결정법에 의한 패턴식별

김응규[○] 이수종

한밭대학교 정보통신공학전공[○] 한국전자통신연구원 음성언어정보연구부

kimeung@hanbat.ac.kr[○], sjleetri@etri.re.kr

Pattern Classification using Closest Decision Method in k Nearest Neighbor Prototypes

Eung-Kyeu Kim[○] Soo-Jong Lee

Dept. of Infor. & Communication[○] Speech/Language Infor. Research Div., ETRI

요 약

클래스별 원형상(prototype)의 분포가 선형분리 불가능하고 동시에 분산이 서로 다르고 희박한 분포의 원형상에 있어서 입력패턴에 대한 고정밀도의 식별을 행하기 위해 클래스별 최근방 원형상과 그 k 근방 원형상에 있어서 노름(norm) 평균에 기초한 최근방 결정법에 의한 패턴식별방법을 제안한다. 제안하는 방법의 유효성을 평가하기 위해 인공적인 패턴과 실제 패턴에 대해 일반적인 k-NN법, 매해라노비스 거리(maharanobis distance), CAP, kCAP, SVM의 각각에 기초한 방법과 제안하는 방법을 적용하여 식별률에 의한 평가를 행하였다. 그 결과 특히, 원형상의 분포가 희박한 경우 제안하는 방법이 다른 방법들에 비해 높은 식별률을 나타냈다.

1. 서 론

선형분리가능한 패턴에 대한 패턴식별 방법중 k 근방결정법(k-NN method)에 기초한 방법이 있다[1]-[4]. 이 방법은 우선, 분류된 클래스 패턴(class pattern)인 원형상(prototype)과 입력패턴과의 거리에 따라 그 거리가 작은 순서로 k개의 원형상을 선택한다. 다음으로, 이 k개의 원형상중에서 클래스별 다수결을 취해 최대가 된 클래스를 입력패턴이 속하는 클래스로 한다. 각 클래스의 원형상 분포가 집중될 때 입력패턴과 최소거리가 각 클래스에 있어서의 원형상에 의한 식별경계가 정확한 해의 식별경계에 근사화하기 때문에 최근방 결정법 k=1에 의해 고정밀도 식별이 가능하게 된다.

또한, 클래스별 최근방 원형상 근방의 원형상 조밀의 차가 각 클래스에서 작게됨으로써 k 근방결정법 $k \geq 2$ 에 의해 그림 1과 같이 고정밀도 식별이 가능하게 된다. 그러나 각 클래스의 원형상 분포가 희박한 경우, 클래스별 최근방 원형상에 의한 식별경계가 정확한 해의 식별경계로부터 크게 이탈하기 때문에 최근방 결정법 k=1에서는 식별정밀도가 저하될 우려가 있다. 또한, 클래스별 최근방 원형상 근방의 원형상 조밀의 차가 각 클래스에서 크게됨으로써 k 근방 결정법 $k \geq 2$ 에서는 식별정밀도가 그림 2에서와 같이 저하될 우려가 있다.

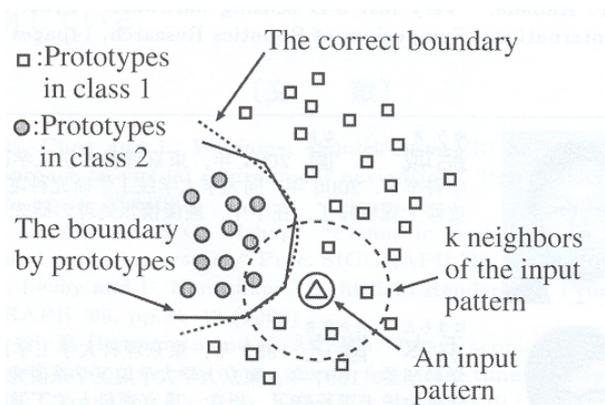


그림 1 각 클래스의 원형상 분포가 집중된 경우, 원형상에 의한 식별경계와 입력패턴근방의 원형상

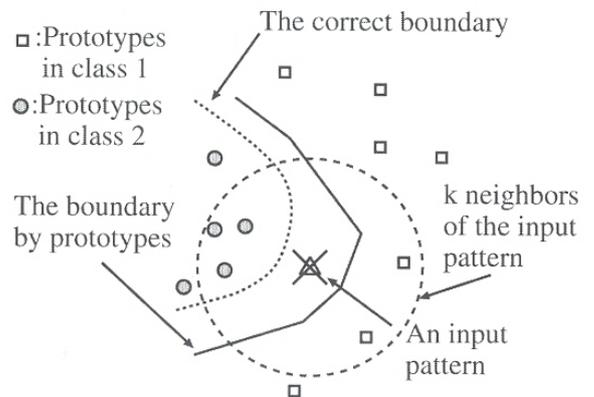


그림 2 각 클래스 원형상의 분포가 빈약한 경우, 원형상에 의한 식별경계와 입력패턴 근방의 원형상

각 클래스에 있어서 원형상의 조밀을 고려한 식별방법으로서 매해러노비스 거리(Mahalanobis distance)에 기초한 방법이 있다[5]-[8]. 이 방법은 각 클래스의 평균벡터와 입력패턴과의 거리를 각 클래스 전체의 공분산행렬에 의해 가중치 부가를 행하기 때문에 원형상의 분포가 타원인 경우는 적당하지만, 타원외 임의의 형상분포인 경우 식별정도가 저하된다고 생각된다. 또한, 선형분리가 불가능한 패턴에 효과가 있는 방법으로서 미타니(Mitani) 등은 각 클래스에 있어서 k 근방패턴의 평균과 입력패턴과의 거리를 이용하는 CAP(Classification using Categorical Average Patterns)법을 제안했다[9]. 단, 이 방법은 각 클래스에 있어서 k 근방패턴의 평균에 기초하여 입력패턴의 식별을 행하고 있기 때문에 패턴의 분포가 희박한 경우 각 클래스에 있어서 k 근방패턴의 평균이, 희박한 패턴의 방향으로 크게 이동하기 때문에 식별률이 저하될 우려가 있다. 더욱이 미타니 등의 방법을 커널화한 방법인 kCAP [10]와 SVM(Support Vector Machine)[11] 등의 방법도 제안되고 있다. 그러나 이들도 입력패턴을 식별할 때 각 패턴의 조밀정도에 차이가 있는 경우, 고차원 공간에 있어서 식별경계가 크게 이탈되기 때문에 식별률이 저하될 우려가 있다.

본 연구에서는 클래스별 원형상(prototype)의 분포가 선형분리 불가능하고 동시에 분포가 서로 다르고 빈약한 분포의 원형상에 있어서도 입력패턴의 고정밀도 식별을 행하는 것을 목적으로 한다. 여기에서 빈약한 원형상의 분포에 있어서 클래스별 최근방의 원형상에 의한 식별경계에 주목한다. 이 경우 정확한 해의 식별경계에 대해서 클래스별 최근방 원형상에 의한 식별경계는 광범위하게 분포하는 클래스의 원형상쪽으로 이동하는 경향이 있다. 따라서 입력패턴과 각 클래스에 있어서 원형상과의 거리에 기초한 식별을 행할 때, 어떤 클래스에 있어서 원형상의 분산이 클 수록 입력패턴과 그 클래스의 원형상 거리를 단축하는 듯한 가중치 부가를 행함으로써 고정밀한 식별가능성을 기대할 수 있다. 위에서 언급한 내용을 기초로, 본 연구에서는 입력패턴과 클래스별 최근방 원형상의 거리를, 클래스별 최근방 원형상과 그 k 근방의 원형상에 있어서 평균벡터와 그 평균벡터의 산출에 이용한 각 원형상과의 노름(norm)의 평균에 기초한 가중치 부가를 행하여 최근방 결정법에 의한 식별을 행한다.

이하, 2장에서는 제안한 방법의 알고리즘에 대해 설명하고, 3장에서는 인공적인 데이터와 실제 데이터에 대해서 기존의 방법인 k-NN법, 매해러노비스 거리, CAP, kCAP, SVM의 각각에 기초한 방법과 제안하는 방법과의 비교를 통해 제안하는 본 방법의 유효성을 평가한다. 4장에서는 결론 및 향후의 과제에 대해 기술한다.

2. 제안방법의 알고리즘

아래에 제안하는 알고리즘을 나타내고 각 단계별로 설명하면 다음과 같다.

[단계 1] 클래스별 최근방 원형상(prototype)의 결정
식별하는 입력패턴을 i , 클래스 c 에 있어서 m 번째의 원형상(prototype)을 $p_c^{(m)}$ 로 한다. 단, 클래스 c 에 있어서 원형상 수를 Num_c 로 하고, i , $p_c^{(m)}$ 은 각각 r 차원의 열 벡터로 한다. 여기서, 각 클래스 c 에 있어서,

$$p_c^{(a_c)} = \arg \min_{1 \leq a_c \leq Num_c} \|p_c^{(a_c)} - i\| \quad (1)$$

을 만족하는 $p_c^{(a_c)}$ 를 각 클래스 c 에 있어서 클래스별 최근방 원형상으로서 결정한다.

[단계 2] 클래스별 최근방 원형상(prototype)과 그 k 근방 원형상 집합의 결정

각 클래스 c 의 $p_c^{(a_c)}$ 에 대한 k 근방 원형상을 다음과 같이 결정한다. 우선, $p_c^{(a_c)}$ 와 그 k 근방 원형상의 집합을 $S_{ck} = \{\phi\}$ 로 해서, $p_c^{(a_c)} \in S_{ck}$ 로 한다. 다음으로, 클래스 c 에 있어서 전체 원형상의 집합 S_c 에 대해서,

$$p_c^{(j)} = \arg \min_{1 \leq j \leq Num_c, j \neq a_c} \|p_c^{(a_c)} - p_c^j\| \quad (2)$$

를 만족하는 $p_c^{(j)}$ 를 결정한다. 더욱이 S_c 로부터 (2)식

에 의해 결정한 $p_c^{(j)}$ 를 제외하고 $p_c^{(j)} \in S_{ck}$ 로 한다.

다시 S_c 로부터 (2)식을 만족하는 $p_c^{(j)}$ 를 결정한다. 이 처리를 k번 반복함으로써 각 클래스 c 에 있어서 클래스별 최근방 원형상과 그 k 근방 원형상의 집합 S_{ck} 를 결정한다.

[단계 3] 클래스별 최근방 원형상(prototype)과 그 k 근방 원형상에 있어서 평균과 노름(norm) 평균의 산출

여기에서는 우선, S_{ck} 에 포함되는 원형상의 평균벡터

$$m_c = \frac{1}{k} \sum_{p_c^{(j)} \in S_{ck}} p_c^{(j)} \quad (3)$$

을 산출한다. 다음으로, 다음에 산출한 m_c 를 이용해서

S_{ck} 에 포함되는 원형상의 노름(norm) 평균을 산출한다.

$$C_c = \frac{1}{k} \sum_{p_c^{(j)} \in S_{ck}} \|p_c^{(j)} - m_c\| \quad (4)$$

[단계 4] 입력패턴과 클래스별 최근방 원형상과의 노름 평균에 의한 가중치를 부가한 거리의 산출

여기에서는, 각 클래스 c 에 있어서 i 와 $p_c^{(a_c)}$ 와의

C_c 에 의해 가중치를 부가한 거리를 산출한다.

$$d_c = \frac{1}{C_c} \|p_c^{(a_c)} - i\| \quad (5)$$

[단계 5] 산출한 거리에 기초한 입력패턴의 식별

여기에서는 산출한 d_c 를 아래 식으로 평가해서,

$$d_g = \arg \min_{1 \leq g \leq n_c} d_c \quad (6)$$

(6) 식을 만족하는 d_g 를 산출한 g 클래스를 i 가 속하

는 클래스로서 결정한다. 단, 전체 클래스는 n_c 로 한다.

3. 제안방법의 유효성 평가

제안하는 방법의 유효성을 평가하기 위한 기존의 일반적 방법인 k-NN법, 매해러노비스 거리, CAP, KCAP, SVM의 각각에 기초한 방법과, 제안하는 방법을 인공적인 패턴과 실제 패턴에 적용하여 특성평가를 행한다. 실험에서는 일반적인 k-NN법[1], 매해러노비스 거리 [6], CAP[9], kCAP[10], SVM[11]과 제안하는 방법에 기초한 식별방법을, 각각 일반적인 k-NN법, 매해러노비스 거리, CAP, KCAP, SVM, 제안하는 방법(prop.)으로 표기하기로 한다.

3.1 인공패턴에 대한 실험

우선, 인공패턴에 대한 각 방법의 특성평가를 행한다. 여기에서는 두 클래스 패턴의 식별을 행한다. 두 클래스의 선형분리 불가능한 인공패턴을 생성하기 위해, 우선, 다음과 같은 초반구(super-hemisphere)를 사고한다.

$$x_n = \sqrt{r_c^2 - x_1^2 - x_2^2 - \dots - x_{n-1}^2} \quad (7)$$

단, x_1, x_2, \dots, x_n 은 n 차원 패턴의 벡터성분으로 하고,

r_c 는 각 클래스에 있어서 초반구의 반경으로 한다. 각

클래스에 있어서 패턴의 벡터는 (7)식의 x_1, x_2, \dots, x_n 을

만족하는 무작위(random)로 부여한 n 차원 벡터 $(x_1, x_2$

$, \dots, x_n)^T$ 의 각 성분에

$$p(d) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{d^2}{2\sigma^2}\right\} \quad (8)$$

의 확률분포를 만족하는 d 를 각각 부가하여 생성했다.

더욱이, 여기에서 패턴벡터의 차원수 n 은 2, 클래스 1

과 2에 있어서 (7)식의 r_c 는 각각 $r_1 = 3.5$, $r_2 = 1$, 또

한 (8)식에 있어서 σ 는 각각 0.70, 0.15로 하였다.

또한, 여기에서의 식별률 C_r 은

$$C_r[\%] = \frac{1}{C_{Num}} \sum_{i=1}^{C_{Num}} \left[\frac{1}{P_{Num}} \left\{ \sum_{j=1}^{P_{Num}} D(p_j^{(i)}) \right\} \times 100 \right] \quad (9)$$

로 한다. 단, C_{Num} 은 클래스의 수, P_{Num} 은 각 클래스

에 있어서 입력패턴의 수, $p_j^{(i)}$ 는 클래스의 번호가 i 이

고 입력패턴의 식별순서 번호가 j 인 입력패턴의 벡터,

$D(p_j^{(i)})$ 는 입력패턴 $p_j^{(i)}$ 가 정답이면 1, 정답이 아니면

0으로 한다. 여기서 $C_{Num} = 2$, $P_{Num} = 200$ 으로 한다.

더욱이 여기에서 각 방법의 파라메타(parameter)는 예

비실험에 의해 다음과 같이 결정하였다. k-NN에서는 k=

3, CAP에서는 k=7, kCAP에서는 k=7, 가우시안 커널함

수(Gaussian kernel)의 파라메타 $\alpha = 1.0 \times 10^{-8}$ 로,

SVM에서는 소프트 마진(soft margin)의 파라 메타

$\gamma = 5.0$, 가우시안 커널함수의 파라메타 $\alpha = 1.0$ 으로,

제안하는 방법 (Prop.)에서는 k=3으로 하였다.

그림 3에 각 클래스의 원형상(prototype)의 수에 대한

k-NN에 의한 식별률을 나타낸다. 원형상의 수가 증가

함에 따라 식별률이 저하되고 있음을 알 수 있다. 이것

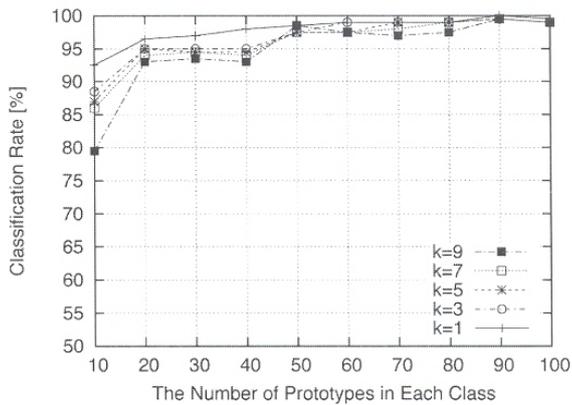


그림 3 각 클래스에 있어서 원형상의 수에 대한 식별률 (k-NN)

은 원형상의 수가 증가함에 따라 원형상에 의한 식별경계가 정확한 해의 식별경계와 멀어지게 되고, 또한 입력패턴과 최소거리가 되는 각 클래스에 있어서 원형상 근방의 원형상의 조밀정도의 차가 각 클래스에서 크게 됨으로써 식별률이 낮게 되었다고 생각된다. 또한, 원형상의 수가 적은 경우, 입력패턴과 최소거리가 되는 각 클래스에 있어서 원형상에 의한 식별경계가 정확한 해의 식별경계에 근사화함과, 또한 입력패턴과 최소거리가 되는 각 클래스에 있어서 원형상 근방의 원형상의 조밀정도의 차가 각 클래스에서 작게됨으로써 식별률이 향상되었다고 생각된다.

그림 4에 각 클래스의 원형상 수에 대해 제안하는 방법(prop.)에 의한 식별률을 나타낸다. 이 방법에 의한 식별률은 그림 3의 k-NN에 의한 식별률을 상회하고 있음을 알 수 있다. 더욱이 원형상의 분포가 희박할 수록 k-NN과 제안하는 방법과의 식별률 차가 크게됨을 알 수 있다.

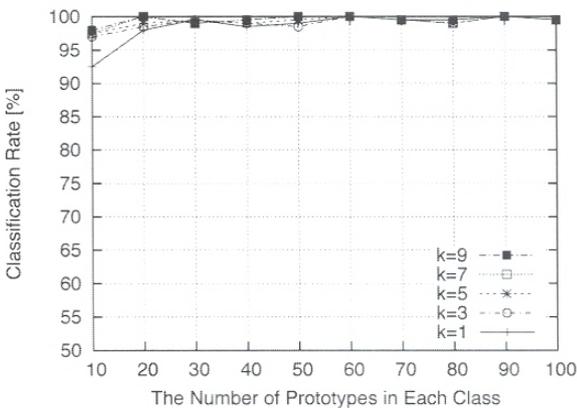


그림 4 각 클래스에 있어서 원형상의 수에 대한 식별률 (제안하는 방법)

이것은 각 클래스의 원형상중에서 입력패턴과 최단거리에 있는 원형상과 입력패턴과의 거리를, 각 클래스 원형

상중에서 입력패턴과 최단거리에 있는 원형상과 그 원형상과 동일한 클래스 근방의 원형상에 있어서 노름(norm)평균으로 가중치를 취함으로써 입력패턴과 최소거리가 되는 각 클래스에 있어서 원형상에 의한 식별경계를 정확한 해의 식별경계에 근사화할 수 있었기 때문으로 생각된다.

그림 5에 각 클래스의 원형상 수에 대한 매해라노비스(Mahalanobis), CAP, kCAP, SVM에 의한 식별률을 나타낸다. 매해라노비스외의 식별률은 비교적 고정밀도로 식별이 가능하다는 것을 알게된다. 단, 그림 4에서 제안하는 실험결과와 비교하면 원형상 수가 적은 경우에 제안하는 방법은 다른 방법과 비교해서 특히 유효함을 알 수 있다.

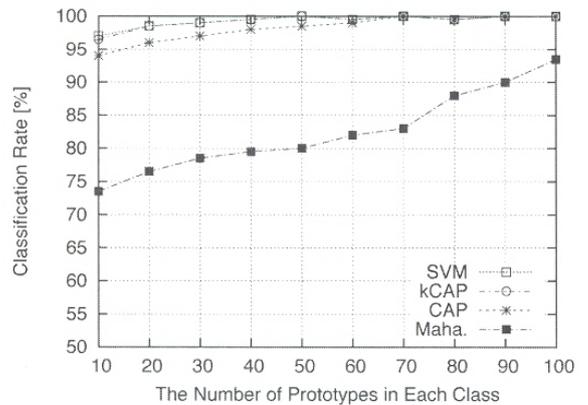


그림 5 각 클래스에 있어서 원형상의 수에 대한 각 방법의 식별률

다음으로, 차원수에 대한 각 방법의 식별률을 나타낸다. 더욱이 여기에서 각 클래스에 있어서 원형상의 수는 20개, 입력패턴은 각 클래스 100개로 하였다. 그림 6에 차원수에 대한 각각의 방법에 의한 식별률을 나타낸다.

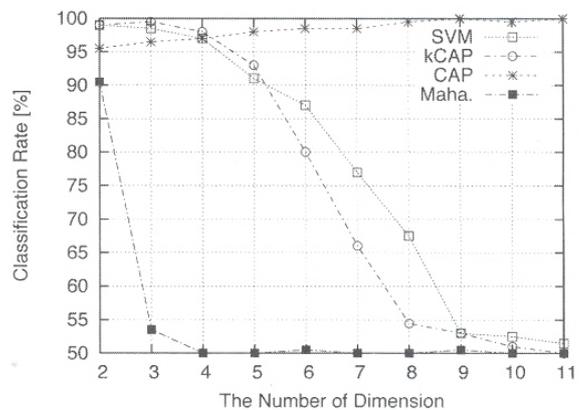


그림 6 차원수에 대한 각 방법의 식별률

k-NN, CAP, kCAP, 매해라노비스는 다함께 차원수가 증가할수록 식별률이 저하되고 있음을 알 수 있다. 이것은 차원수가 증가할수록 원형상간의 밀도가 희박하게

되는 것이 주된 원인으로 생각된다. 이것에 대해 제안하는 방법, SVM에서는 차원수가 증가하더라도 식별률은 고정밀도로 유지되고 있음을 알 수 있다.

3.2 실제 패턴에 대한 실험

다음으로, 실제패턴에 대한 각 방법의 특성평가를 행하였다. 실험에 사용한 데이터는 문자식별용 데이터베이스인 미니스티(MINIST)를 이용했다[8]. 이것은 문자가 0-9까지 10개의 클래스, 각각 28×28 픽셀 사이즈(pixel size), 8[bit/pixel] 계조영상에 대해서 라스터스캔(raster scan)에 의한 벡터화를 취하여 실험을 행하였다. 여기에서 패턴의 차원수는 영상의 화소수 784로 하여 원형상(prototype)의 수를 변화시킨 경우의 식별률에 의해 각 방법에 대한 평가를 행하였다. 더구나 SVM은 기본적으로 두 클래스의 식별문제를 취급하였기 때문에 각 클래스 1,000개 패턴의 평균에 대해서 최단거리가 된 다른 클래스와의 식별률을 산출하여 그 식별률을 전체 클래스로 평균한 것을 여기에서의 각 방법의 식별률로 하였다. 또한 여기에서 각 방법의 파라메타는 예비실험에 의해 다음과 같이 결정하였다.

k-NN에서는 k=3, CAP에서는 k=7, kCAP에서는 k=7, 가우시안 커널(Gaussian kernel) 함수의 파라메타

$\alpha = 1.0 \times 10^{-8}$, SVM에서는 소프트 마진(soft margin)의

파라메타 $\gamma = 5.0$, 가우시안 커널(Gaussian kernel)함수

의 파라메타 $\alpha = 1.0$, 제안하는 방법에서는 k=3으로 하였다. 그림 7에 원형상(prototype)의 수 10으로부터 100개까지 매해라노비스(Mahalanobis)외의 방법에 있어서 식별률을 나타낸다. 더구나 원형상의 수가 영상의 화소수 784이하인 경우 공분산 행렬을 구할 수가 없기 때문에 매해라노비스의 식별률은 여기에서 생략하였다. 실험결과로부터 제안하는 방법에 의한 식별률은 원형상의 수가 적은 경우에 특히 유효하다는 것을 알 수 있다.

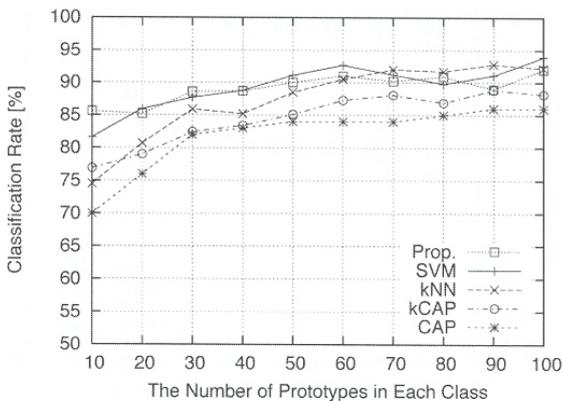


그림 7 원형상의 수 10에서 100개까지의 각 방법에 있어서 식별률

그림 8에 원형상의 수 785로부터 1,200개까지 각 방법에 있어서 식별률을 나타낸다. 실험결과로부터 SVM,

제안하는 방법(Prop.)에서 약간 높은 식별률을 나타냈지만, 매해라노비스(Mahalanobis)외의 방법은 거의 동등한 정도의 식별률을 나타내고 있음을 알 수 있다. 이상의 실험으로부터 제안하는 방법은 원형상의 수가 적고 희박한 경우에 특히 유효함을 알 수 있다.

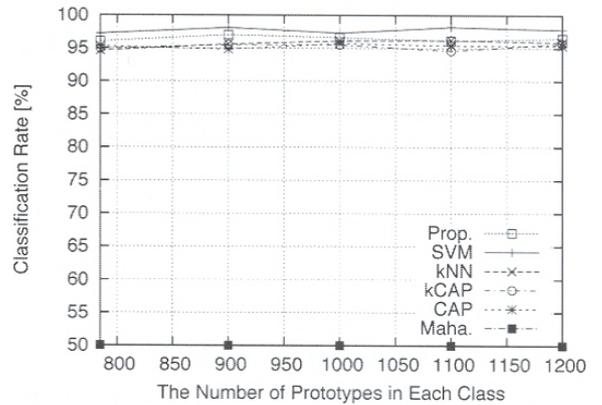


그림 8 원형상의 수 785에서 1,200개까지의 각 방법에 있어서 식별률

다음으로, 각 클래스의 원형상 수를 각각 10개, 1000개로 한 경우 각 클래스의 최근방 원형상의 수와 그 k 근방 k=2의 패턴을 그림 9와 그림 10에 각각 나타낸다. 단, 여기에서 클래스1을 1의 문자, 클래스2를 9의 문자로 하였다. 또한 각 클래스의 원형상 수가 각각 10개, 1,000개로 했던 경우의 각 클래스의 최근방 원형상과 그 k 근방 k=2의 패턴의 노름(norm) 평균을 각각 표1과 표2에 나타낸다. 더욱이, 여기에서 각 클래스의 최근방 원형상은 서로의 원형상에 대해서 유클리드의 거리가 최단이 되는 패턴으로 하였다.

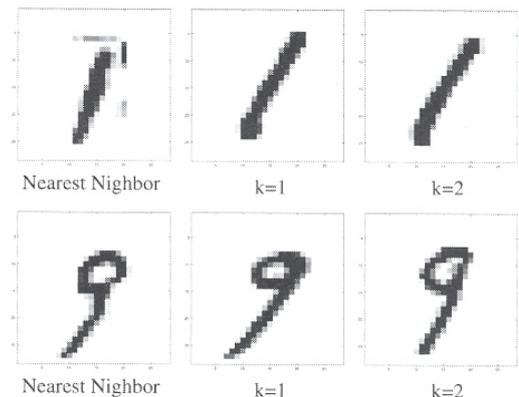


그림 9 원형상의 수 10개에 있어서 각 클래스의 최근방 원형상과 그 k 근방의 패턴

표 1 원형상의 수 10개에 있어서 각 클래스별 노름 평균

방 법	노름 평균
클래스 1	702.0
클래스 2	814.0

그림 9와 그림 10으로부터 각 클래스의 원형상 수가 많은 경우 각 클래스의 최근방 원형상과 그 k 근방 원형상의 유사성이 높다는 것을 알 수 있다. 또한 표 1과 표 2로부터 각 클래스의 원형상 수가 1,000개인 경우에 비해 10개인 경우 각 클래스에 있어서 노름 평균이 증가함을 알 수 있다. 이것은 각 클래스의 최근방 원형상과 그 k 근방 원형상의 유사성이 낮게되기 때문이라고 생각된다. 또한 이 경우, 노름 평균 증가율이 클래스별로 다르다는 것을 알 수 있다. 이것은 원형상의 수가 저하 하면 각 패턴에 의해 원형상의 조밀의 차가 크게되는 것이 그 원인이라고 생각된다. 따라서 제안하는 방법

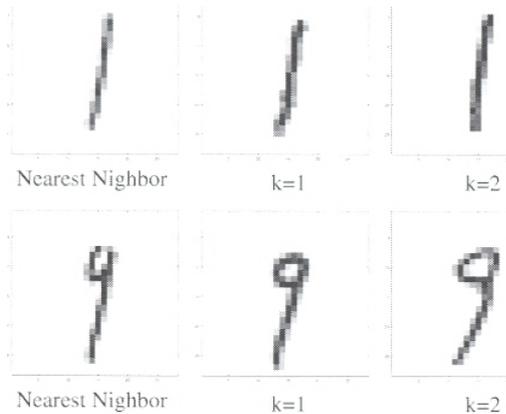


그림 10 원형상의 수 1,000개에 있어서 각 클래스의 최근방 원형상과 그 k 근방의 패턴

표 2 원형상의 수 1,000개에 있어서 각 클래스별 노름 평균

방 법	노름 평균
클래스 1	375.5
클래스 2	635.3

에 의해 입력패턴과 각 클래스에 있어서 최근방 원형상과의 거리를 노름 평균으로 가중치를 부가하여 입력패턴을 식별하는 것은 매우 유효한 방법이라고 생각된다.

4. 결 론

클래스(class)마다 원형상(prototype)의 분포가 선형분리 불가능하고 동시에 분산이 서로 다른 희박한 분포의 원형상에 있어서도 입력패턴에 대한 고정밀도의 식별을 하기위해 클래스별 최근방 원형상과 그 k 근방 원형상에 있어서 노름(norm) 평균에 기초한 최근방 결정법

에 의한 패턴식별방법을 제안했다. 제안하는 방법의 유효성을 평가하기위해 인공적인 패턴과 실제 패턴에 대해 일반적인 k-NN법, 매해라노비스(Maharanobis), CAP, kCAP, SVM의 각각에 기초한 방법과 제안하는 방법을 적용하여 식별률에 의한 평가를 행하였다. 인공적인 패턴에 대한 실험에 있어서 제안하는 방법은 다른 방법들과 비교하여 원형상의 수를 변화시킨 경우와 차원수를 변화시킨 경우 두개 모두 식별률이 향상되었다. 특히 원형상의 분포가 희박한 경우에 있어서 유효했다. 또한 실제 패턴에 대한 실험에 있어서도 제안하는 방법은 다른 방법들과 비교하여 특히, 원형상의 분포가 희박한 경우에 있어서 유효했다. 금후의 과제로서 노름평균에 대한 가중치 부여방법과 또한 제안하는 방법을 커널화함으로써 보다 식별률을 향상시킬 수 있는 방안이 남아있다.

참고문헌

- [1] S. A. Dudani, "The distance-weighted k-nearest neighbor", IEEE Trans. Syst. Man Cybern., Vol. SMC-8, No.4, pp.311-313, 1978.
- [3] S. M. Weiss, "Small sample error rate estimation for k-NN classifiers", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.PAMI-13, No.3, pp.285-289, March. 1991.
- [4] R. O. Duna, P. E. Hart and D. G. Stork, Pattern classification, Second edit. John Wiley & Sons, 2001.
- [6] N. Kato, M. Suzuki, S. Omachi, H. Aso and Y. Nemoto, "A Hand-written Character Recognition System Using Directional Element Feature and Asymmetric Mahalanobis Distance", IEEE Trans. on PAMI, Vol.21, No.3, pp.258-262, 1999.
- [7] F. Sun, S. Omachi, N. Kato, H. Aso, S. Kono and T. Tagagi, "Two-Stage Computational Cost Reduction Algorithm based on Mahalanobis Distance Approximations", Proceedings of ICPR, Vol.2, pp.700-703, 2000.
- [8] Y. LeCun, L. Bottou, Y. Bengio and P. Haffner, "Gradient-based learning applied to document recognition", Proceedings of IEEE, Vol.86, No.11, pp.2278-2324, 2005.
- [9] Y. Mitani and Y. Hamamoto, "Classifier design based on the use of nearest neighbor samples", Proc. 15th Int. Conf. Pattern Recognition, Vol.2, pp.773-776, 2000.
- [10] K. R. Muler, S. Mika, G. Ratsch, K. Tsuda and B. Scholkopf, "An introduction to kernel-based learning algorithms", IEEE Trans. Neural Networks, Vol.12, No.2, pp.181-201, Mar, 2001.