

지역적 특성을 갖는 동적 선택 방법에 기반 한 다중 인식기 시스템

(A Multiple Classifier System based on Dynamic Classifier Selection having Local Property)

송혜정[†] 김백섭^{**}
(Hyeo-jung Song) (Baek-sop Kim)

요약 본 논문에서는 지역적 특성을 가지는 작은 인식기(마이크로 인식기)의 모음으로 인식기를 구현하는 다중 인식기 시스템을 제안한다. 각 학습패턴에서 k개의 이웃한 학습패턴을 추출해서 학습한 인식기를 마이크로인식기라고 한다. 각 학습패턴에는 한개 이상의 마이크로 인식기를 부여한다. 본 논문에서는 선형 커널을 사용한 SVM과 RBF 커널을 사용한 SVM등 두 가지 형태의 마이크로 인식기를 사용한다.

테스트 패턴이 인가되면 테스트패턴 주변의 마이크로인식기들 중에서 성능이 가장 좋은 것 하나를 선택한 후 선택된 인식기로 최종 클래스를 결정한다. 테스트패턴 주변에 있는 학습패턴들을 인식한 결과를 성능 측정 척도로 사용한다.

Elena 데이터베이스를 사용하여 기존의 단일 인식기, 다중 인식기 결합, 다중 인식기 선택 방법들과 인식률을 비교한 결과 제안된 방법이 우수함을 알 수 있다.

키워드 : 다중 인식기 시스템, 동적 인식기 선택, 지역 학습

Abstract This paper proposes a multiple classifier system having massive micro classifiers. The micro classifiers are trained by using a local set of training patterns. The k nearest neighboring training patterns of one training pattern comprise the local region for training a micro classifier. Each training pattern is incorporated with one or more micro classifiers. Two types of micro classifiers are adapted in this paper : SVM with linear kernel and SVM with RBF kernel.

Classification is done by selecting the best micro classifier among the micro classifiers in vicinity of incoming test pattern. To measure the goodness of each micro classifier, the weighted sum of correctly classified training patterns in vicinity of the test pattern is used.

Experiments have been done on Elena database. Results show that the proposed method gives better classification accuracy than any conventional classifiers like SVM, k-NN and the conventional classifier combination/selection scheme.

Key words : Multiple Classifier System, Dynamic Classifier selection, local accuracy, SVM, local learning

1. 서론

패턴인식기술에서 차원이 높은 복잡한 실세계의 응용에 대한 성능향상을 위해서 단일 인식기 시스템은 성능의 한계를 가지게 된다. 이는 하나의 인식기안에 다양한

형태의 특징값을 효과적으로 분류해내지 못하기 때문이다[1]. 따라서 여러 가지 상호보완적인 여러 인식기들을 사용하여 단일 문제로의 분리와 결합을 통하여 성능향상에 도움을 주고 있는 다중 인식기 시스템(MCS : Multiple Classifier System)으로의 연구가 활발하게 진행 중에 있다[2].

다중 인식기 시스템은 여러 개의 단일 인식기를 결합하거나 선택하여 인식성능의 향상을 가져온다. 다중 인식기 시스템을 구성하기 위한 인식기 결합 방법에는 두 가지 접근법이 있다[3]. 첫 번째는 인식기를 병렬로 구성하여 일

[†] 학생회원 : 한림대학교 컴퓨터공학과
hjsong@hallym.ac.kr

^{**} 종신회원 : 한림대학교 정보통신공학부 교수
bskim@hallym.ac.kr

논문접수 : 2002년 10월 19일

심사완료 : 2003년 1월 14일

력패턴을 동시에 입력한 후 출력된 결과물을 이용하여 확률, 통계, 신경망, 퍼지등 다양한 분야의 이론을 결합하는 인식기 결합방법(classifier fusion algorithm)이고, 두 번째는 미지의 데이터가 가장 정확하게 분류할 수 있는 인식기를 동적으로 선택하는 동적 인식기 선택(dynamic classifier selection) 방법이다.

대표적인 인식기 결합 방법으로는 다수결 방식(majority voting), 베이시안 방법, BKS(Behaviour Knowledge Space) 방법, Borda 함수, 신뢰값 합산법(Linear Confidence Accumulation(LCA) method), 신경망(neural network)등이 있다[4].

인식기 결합 방법은 사용된 각각의 단일 인식기들이 독립적인 오류를 생성한다는 가정에 기반을 두고 있다. 그러나 실제 패턴인식문제에 있어서는 오류에 독립적인 각 인식기들의 집합을 설계하는 것이 어렵다[1,5].

오류 독립 가정을 피하기 위한 접근방법으로 최근에 주목받는 동적 인식기 선택방법[3,6,7]은 미지의 데이터가 가장 정확하게 분류할 수 있는 인식기를 동적으로 선택하는 것으로, 학습 데이터들을 서로 배타적인 조건을 가진 집합으로 분리하기 위하여 군집화(clustering)를 하고, 나누어진 각 영역에 대해 인식기의 성능을 측정하여 각 부 영역에 대해 가장 좋은 인식기를 결정한다. 각 부 영역에서는 해당 영역에 적합한 하나의 인식기가 사용되며, 테스트 패턴이 속한 부 영역과 대응된 인식기로 최종 결과를 결정한다[3].

그러나 지금까지 연구된 동적 선택 방법을 기반으로 한 다중 인식기 시스템에서는 구성되는 각 인식기들을 특징공간에 분포된 학습 패턴들의 전역적인 정보나 그룹 정보를 이용하여 설계하므로 유한개의 학습 데이터만을 기준으로 설계된 인식기들은 새로운 입력에 대한 오류의 가능성을 내포하여 일반화에 약하다고 할 수 있다. 따라서 새로 입력되는 패턴을 기준으로 이 패턴과 가까운 주변의 학습 패턴들을 분석하여 결정할 수 있는 시스템이 마련된다면 학습 시스템의 능력을 지역적으로 접근할 수 있도록 해당 영역 안에 가장 적합한 최적의 파라미터를 이용할 수 있게 되고, 이것은 전체 시스템의 성능향상을 가져오게 된다[8]. 이러한 접근 방법이 지역적 학습(local learning)방법이며, 이 접근 방법으로 가장 잘 알려진 k-NN 알고리즘은 다른 패턴인식 방법들과 비교하여 효율이 좋다는 것을 여러 논문의 실험에 대한 결과 비교에서 확인할 수 있다[6, 9].

본 논문에서는 학습단계에서 마이크로 인식기라 불리는 지역적으로 학습시킨 인식기들을 생성하고, 인식단계에서 테스트 패턴 주변의 마이크로 인식기들 중에서 가

장 성능이 좋은 것을 선택하는 다중 인식기 시스템을 제안한다.

마이크로 인식기는 각 학습 패턴에 대하여 k개의 이웃한 패턴들을 이용하여 SVM(Support Vector Machine)으로 학습하게 된다. 인식기 동적 선택을 위한 성능측정 방법으로는 지역적 영역의 학습패턴들에 대한 마이크로 인식기의 정확성과 가까운 학습패턴들이 같은 클래스를 가지는 확률을 이용한다.

본 논문의 구성은 다음과 같다. 2장에서는 다중 인식기 시스템과 관련된 연구들을 살펴보고, 3장은 마이크로 인식기를 이용한 동적 선택 방법에 기반 한 다중 인식기 시스템을 제안한다. 4장은 제안한 다중 인식기 시스템의 인식성능을 비교하고자 단일 인식방법, 인식기 결합방법, 인식기 동적 선택방법들에 대한 실험결과를 보이고, 5장에서는 결론을 맺는다.

2. 관련 연구

본 장에서는 최근에 연구되어진 다중 인식기 시스템에 이용된 동적 인식기 선택 방법들에 대하여 기술한다.

인식기 결합 방법에 대한 대안으로 Ho[3]에 의해 제안된 동적 인식기 선택 방법은 학습 패턴들을 서로배타적인 조건을 가진 집합으로 분리하여 나누어진 각 영역에 대해 인식기의 성능을 측정하여 각 부분에 대한 가장 좋은 인식기를 결정하고, 테스트 패턴에 대해 가까운 영역으로 분류하여 대응되는 가장 좋은 인식기로 결과를 출력하는 방법이다. 테스트 단계에서 동적 선택되는 인식기들은 독립적일 필요가 없으며 정확하게 분류되는 하나의 인식기만이 필요기 때문에 독립가정보다 안정적이며 결합방법을 이용한 다중 인식기 시스템 보다 간단하며, 최적의 선택이 될 수 있다고 할 수 있다[9].

단일 인식기들을 이용하여 학습한 결정 경계부분을 확인하면 지역적으로 결정 경계부분이 많이 다르다는 것을 알 수 있다. 이것은 단일 인식기 마다 특징공간에서 가장 성능이 좋은 자신만의 영역을 가지고 있다는 것을 나타내 주고 있다[10]. 그림 1은 2차원 특징공간에 두개의 클래스를 가지는 데이터와 여러 단일 인식기에 대한 결정경계를 보인 것이다. 각 인식기 마다 서로 다른 결정경계를 보여주며 지역에 따라서 정확하게 분류되는 인식기가 서로 다르다는 것을 알 수 있다. 이것은 동적 선택에 기반 한 다중 인식기 시스템에서 미지의 패턴이 어떤 위치에 존재하는가에 따라서 선택할 인식기가 달라져야 한다는 것을 보여주고 있다.

최근 연구에서 지역적 특성을 고려한 동적 인식기 선택 방법으로 대표적인 것이 Woods[6]에 의해 제안된 지역적




그림 1 여러 단일 인식기에 대한 결정경계

정확성 평가 방법(local accuracy estimates)이다. 이 방법에서 각 인식기는 테스트 패턴 주변의 특징공간에 대한 지역적 영역에서 정확성을 평가하여 계산되며, 지역적 영역은 학습 패턴의 k개의 이웃한 패턴들로 정의된다.

동적 인식기 선택 방법에 대한 대표적인 알고리즘은 DCS_LA[6], DCS_MCB[7], M3CS[11]로 다음과 같다.

2.1 DCS_LA(Dynamic Classifier Selection by Local Accuracy)

인식기의 성능을 평가하기 위해 사용되는 지역적 정확성 평가방법에 기반한 동적 인식기 선택 방법은 미지의 패턴에 대해 모든 단일 인식기의 인식 결과가 일치하면 최종 결과로 출력하고, 일치하지 않는다면 각 인식기의 지역적 정확성을 측정하여 가장 정확성이 높은 인식기를 선택한다.

[알고리즘]

- (가) 학습패턴을 사용하여 특징선택을 통하여 서로 다른 특징 집합을 가진 단일 인식기(D_1, \dots, D_L) 들을 설계한다.
- (나) 입력패턴 x 에 대해 모든 단일 인식기가 동일한 클래스 레이블을 출력한다면 x 에 레이블을 할당하고 종료한다.
- (다) 만약 다르다면, 각 인식기의 지역적 정확성을 평가한다.
 D_i 에 의해 할당된 x 의 클래스 레이블을 s 라 한다면, x 와 가장 가까운 K 개의 학습패턴을 골라 D_i 의 지역적 정확성(클래스 레이블 s 로 기대되는 학습패턴들에 대한 비율)계산한다.
- (라) 가장 정확성이 높은 인식기로부터 출력된 클래스 레이블을 최종 레이블로 출력한다.

2.2 DCS_MCB(Dynamic Classifier Selection based on Multiple Classifier Behaviour)

테스트 패턴과 MCB 사이의 유사도 정도에 의존하여 지역적 영역 선택을 동적으로 적용시키는 DCS_MCB는

지역적 정확성 평가방법에 MCB방법을 추가한 동적 인식기 선택방법으로 MCB는 각 인식기에 의해 할당된 클래스 레이블들로 다음 식으로 표현된다.

$$MCB(X^1) = C_1(X^1), C_2(X^1), \dots, C_L(X^1),$$

X^1 : 입력 패턴 (1)

MCB는 인식기의 정확성을 측정하기 위한 지역적 영역 선택에 사용되는데, 패턴들의 유사성을 측정하기 위해 MCB사이의 유사도를 이용한다. 유사도 함수의 식은 다음과 같다.

$$S(X^1, X^2) = \frac{1}{L} \sum_{i=1}^L T_i(X^1, X^2), i = 1, \dots, L \quad (2)$$

여기서 $T_i(X^1, X^2) = \begin{cases} 1 & \text{if } C_i(X^1) = C_i(X^2), \\ 0 & \text{if } C_i(X^1) \neq C_i(X^2) \end{cases}$ 이다.

유사도 함수 $S(X^1, X^2)$ 는 [0,1]범위를 가지며 $S(X^1, X^2)=1$ 이면 패턴 X^1, X^2 에 대한 모든 L개의 인식기가 같은 클래스를 가진다는 것을 의미하고, $S(X^1, X^2)=0$ 이면 두개의 패턴에 대해 모든 인식기가 서로 다른 클래스 레이블을 할당한 것이다.

미지의 테스트 패턴에 대해 MCB를 계산하여 유사도가 높은 k개의 학습패턴들을 적용적으로 선택하여 지역적 정확성을 평가하여 가장 우수한 인식기의 출력을 최종 출력으로 한다.

2.3 M3CS(Multiple classifiers combination by clustering and selection)

군집화 선택방법에 기반 한 동적 인식기 선택 방법 중 M3CS는 두 단계로 처리된다. 데이터 군집화 단계에서는 학습 데이터를 각 인식기와 대응시키기 위한 분할 작업으로 미리 각 인식기로부터 정확하게 분류되는 부분을 각 클래스 레이블에 대한 영역으로 분할한다. 인식기로 정확하게 분류되지 않는 부분에 대해서는 군집화를 처리하여 새로운 클래스 레이블을 할당한다. 선택 단계에서는 입력 패턴과 근접한 영역을 찾아서 분류 성능이 가장 좋은 인식기를 선택하여 최종 결정에서 추천

되어진다.

1) 군집화 단계

- (가) 각 단일 인식기로부터 학습 데이터를 분류하여 정확하게 분류되는 부분과 정확하게 분류되지 않는 부분으로 나눈다
- (나) 정확하게 분류되는 부분은 각 클래스에 해당하는 데이터들을 군집으로 보고 중심값을 S 를 계산한다.
- (다) 정확하게 분류되지 않는 부분에 대해서는 군집화 작업을 통하여 각 군집들의 가우시안 파라미터 R'_j 를 계산한다.
- (라) $S + R'_j$ 개의 군집에 대한 중심 값을 생성한다.

2) 선택 단계

- (가) 입력 패턴과 군집의 중심 값과의 Mahalanobis 거리가 작은 군집들을 선택한다.
- (나) 선택한 군집들에서 각 인식기의 정확성을 계산한다.
- (다) 분류 성능이 가장 좋은 인식기를 선택하여 최종 클래스 레이블을 출력한다.

3. 동적 선택 방법에 기반 한 다중 인식기 시스템

3.1 제안한 다중 인식기 시스템 구조

제안한 다중 인식기 시스템의 구성은 그림 2와 같다.

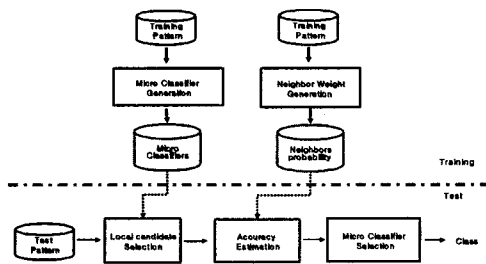


그림 2 제안한 시스템 구성도

제안한 다중 인식기 시스템은 두 단계로 처리된다. 학습 단계에서는 모든 학습 패턴에 대하여 2개의 마이크로 인식기를 설계한다. 마이크로 인식기는 각 학습패턴을 둘러싼 주변의 학습 패턴들을 이용하여 선형 SVM과 RBF 커널함수를 이용한 비선형 SVM 학습방법으로 결정함수를 유도한다. 테스트 단계에서는 테스트 패턴과 가까운 학습 패턴들을 이용하여 지역적 영역에 속하는 각 학습패턴들이 가지는 마이크로 인식기들을 선택하고, 인식 성능을 평가하여 가장 좋은 인식기를 선택한다. 동적으로 선택된 마

이크로 인식기로 테스트 패턴의 최종 클래스 레이블을 결정하게 된다. 인식기를 선택하기 위한 성능 측정 방법으로는 각 마이크로 인식기의 지역적 정확성 측정방법에 가중치를 더하는 방법으로, 학습패턴들에 대해서 각 패턴과 주변의 패턴들이 같은 클래스를 가지는 확률을 계산하여 정확하게 인식되는 학습패턴에 대해서는 가중치를 더하여 성능 측정값을 계산하는 방법이다.

마이크로 인식기는 특징공간에서의 지역적 영역에 대한 정보를 이용하여 결정 경계를 가지기 때문에 동적으로 선택된 영역에 대한 정확한 분류가 이루어 질 수 있다. 그림 3은 전체 학습 데이터를 이용한 SVM 인식기와 제안한 마이크로 인식기로 얻은 결정경계를 보인 것이다. RBF 커널을 사용한 비선형 SVM 인식기의 결정 경계는 전체 학습 데이터에 대해 전역적으로 적용하여 나타난 결과로 본다면 지역적 영역으로 설계된 마이크로 인식기의 결정경계는 주변 패턴에 민감하게 작용하는 것을 알 수 있다. 그림 3 (a)의 중간에 위치한 영역을 살펴보면 같은 클래스들이 모여 있는 곳에 다른 클래스 소수가 존재하는 경우 전역적인 결정경계를 보이는 SVM인 경우에는 오류로 처리되나 마이크로 인식기에서는 정확하게 분류되는 것을 보이고 있다.




그림 3 마이크로 인식기(a)와 SVM_RBF(b)의 결정경계

3.2 마이크로 인식기

학습 패턴마다 포함되는 마이크로 인식기는 각 학습 패턴의 지역적 영역에 대하여 2개의 다른 인식방법을 이용하여 설계한다.

마이크로 인식기에 사용될 학습 알고리즘은 지역적 영역에 대한 학습 패턴들의 개수가 적기 때문에 일반적인 통계적 결정 함수를 유도할 수 없고, 신경망에서는 오버러닝을 발생시키므로 마이크로 인식기의 인식방법으로 적합하지 않다. 따라서 학습 패턴의 개수가 적은 경우에도 잘 동작하는 SVM을 마이크로 인식기의 학습방법으로 채택하였다.

3.2.1 Support Vector Machine

SVM은 1995년 Vapnik에 의해 제안된 통계적 학습

이론으로 일반화 성능이 뛰어난 최적의 인식 방법으로 알려져 최근 다양한 분야에 응용되고 있다[10,12]. 클래스를 구분 짓는 결정경계에 속하는 데이터를 support vector라 하며 이것을 학습하여 선형적인 결정함수를 유도한다. 결정함수의 식은 아래와 같다[10].

$$D(x) = \sum_{x_i \in S} \alpha_i \lambda_i K(x_i, x) + \alpha_0 \quad (3)$$

S는 support vector 집합이고, λ_i 는 입력 벡터 x_i 의 클래스로 ± 1 값을 갖는다. $\alpha_i \geq 0$ 는 학습되는 동안 최적화된다. 선형 SVM에서는 $K(x_i, x)$ 가 입력패턴의 단순한 내적 $(x_i \cdot x)$ 으로 계산되며, 비선형 SVM에서는 $K(x_i, x)$ 가 커널함수로 계산하여 입력패턴을 고차원적인 특징공간으로 매핑하여 비선형 문제를 고차원 공간에서의 선형문제에 해결할 수 있도록 한다. 대표적인 커널 함수로는 Neural Network, Radial Basis, polynomial을 사용한다.

다음은 RBF(Radial basis function) 커널 함수식이다.

$$K(x, y) = e^{-|x-y|^2/2\sigma^2} \quad (4)$$

본 논문에서는 개수가 적은 지역적 학습 패턴들로도 잘 동작하는 SVM 학습방법을 이용하여 마이크로 인식기를 설계하였다.

SVM은 두개의 클래스 분리 문제를 위한 알고리즘으로 다중 클래스를 처리하기 위해서는 SVM을 조합해야 하는데 본 논문에서는 DAG(Directed Acycle Graph) SVM [13]을 사용하였다. DAG SVM은 각 클래스마다 학습시킨 결과 값을 실수 값으로 얻어서 가장 큰 값을 가지는 클래스로 분류하는 방법이다.

3.2.2 마이크로 인식기 설계

각 학습 패턴마다 포함될 마이크로 인식기는 각 학습 패턴들을 중심으로 주변의 지역적 영역에 포함되는 학습 패턴들을 이용하여 설계된다. 마이크로 인식기는 하나의 학습 패턴에 대해 2개를 포함시킨다. 하나는 선형 SVM으로 학습된 것이고, 다른 하나는 RBF 커널 함수를 사용한 비선형 SVM 학습방법을 이용한 것이다.

제안한 시스템의 학습단계는 다음과 같다.

(가) 클래스 레이블 y_i 를 포함하는 학습 데이터 $X =$

$\{(x_i, y_i)\}_{i=1}^N$ 에 대해 각 학습패턴 x_i 의 주변의 K개의 패턴들을 이용하여 지역적 영역 $R_i = \{r_1, \dots, r_k\}$ 을 정의한다.

(나) 정의된 지역적 영역에서의 서로 다른 클래스가 존재하면 각 학습패턴 주변의 지역적 영역 R_i 을 이용하여 선형 SVM과 RBF 커널함수를 사용한 비선형 SVM으로 학습한 마이크로 인식기

MC_i^{sum}, MC_i^{sum} 를 생성한다.

그림 4는 마이크로 인식기 생성 단계에 대한 구성도를 보인 것이다.




그림 4 마이크로 인식기 생성 단계 구성도

3.3 다중 인식기 동적 선택

인식 단계에서는 미지의 입력 패턴에 대한 클래스를 결정하기 위하여 입력 패턴 주변의 마이크로 인식기들의 성능을 측정하여 동적으로 선택한다. 입력패턴 주변의 마이크로 인식기는 입력패턴과 가까운 학습패턴들을 이용하여 정의된 영역에서의 각 학습패턴에 포함된 마이크로 인식기들로, 주변 데이터를 이용하여 인식 성능을 측정하여, 가장 성능이 우수한 마이크로 인식기를 이용한 분류 결과를 최종 클래스로 출력한다. 인식기를 선택하기 위한 성능 측정 방법으로는 지역적 영역의 학습 패턴들에 대한 마이크로 인식기의 정확성과 가까운 학습패턴들이 같은 클래스를 가지는 확률을 이용한다. 인식 알고리즘은 다음과 같다.

- (가) 테스트패턴 x 에 대해 학습패턴에서 M개 최근접 이웃 $N(x)$ 을 구한다.
- (나) $N(x)$ 에서 학습패턴의 클래스 레이블이 모두 같으면 해당 클래스 레이블을 인식결과로 출력하고 종료한다.
- (다) 클래스 레이블이 모두 같지 않으면, $N(x)$ 에 속한 학습패턴 각각에 부착된 마이크로 인식기를 선택하여(선택된 마이크로 인식기의 집합을 $MC(x)$ 라고 하자) 각각의 인식기의 지역적 정확도를 계산한다.

j번째 마이크로 인식기 $MC_j \in MC$ 의 지역적 정확도는 x 에 가장 가까운 S개의 학습패턴 $N_s(x)$ 을 사용하여 다음과 같이 계산한다.

$$LA_j(x; N_s(x)) = \frac{\sum_{i=1}^S W_i \delta(C(x_i), MC_j(x_i))}{\sum_{i=1}^S W_i} \quad (5)$$

여기서, $\delta(x, y)$ 는 $x = y$ 인 경우만 1이고 그렇지 않은 경우는 0이다. $x_i \in N_s(x)$ 는 x 의 i번째 최근접 이

웃 학습패턴이고 $C(x_i)$ 는 x_i 의 클래스 레이블이다.

W_i 는 학습패턴 x 가 그의 i 번째 최근접 이웃 학습패턴 x_i 이 같은 클래스 레이블을 가질 확률로서 학습 데이터로부터 계산되어진다.

$$W_i = \sum_{j=1}^L P(C(x) = k, C(x_i) = k)$$

여기서 L 은 클래스 수이다.

(라) MC 중에서 지역적 정확도가 가장 높은 것 MC^* 를 선택해서 MC^* 로 테스트패턴 x 를 인식하여 결과를 출력한다.

(마) 지역적 정확도가 같은 경우는 다수 결정으로 인식 결과를 출력한다.

그림 5는 인식 단계 구성도를 보인 것이다.




그림 5 인식 단계 구성도

4. 실험 및 결과 분석

4.1 실험환경

실험에 사용된 데이터는 ELENA project[14]로부터 얻은 데이터베이스중 Phoneme_CR과 Satimage_CR 데이터 집합을 이용하였다.

Phoneme데이터 집합은 불어의 비음과 모음을 구분하기 위한 데이터로 5개의 특징을 가지고 총 150개의 패턴으로 구성되어 있으며, Satimage데이터 집합은 지구 자원 탐사 위성인 Landsat에 의한 다중분광스캐너 이미지로 4개의 분광 띠에 대한 3×3 픽셀값에 대해 6개의 클래스를 가지며 총 6435개의 패턴들로 구성되었다.

분류에 대한 정확도를 측정하기 위하여 각 데이터 집합은 각 클래스의 개수가 동일하도록 임의로 분리하여 학습 패턴과 테스트 패턴으로 나누어 사용되었다. 실험에서는 데이터 집합의 구성에 따른 오류를 없애기 위하여 10개의 데이터 집합을 임의로 구성하여 인식률에 대한 평균값으로 최종 인식률을 나타내었다.

사용한 소프트웨어 툴로는 School of Information Systems, University of East Anglia에서 개발한 MATLAB Support Vector Machine Toolbox를 이용하였다[15].

4.2 실험결과

제안한 방법에 대한 성능을 평가하기 위하여 동일한

데이터 집합을 사용하여 여러 가지 인식방법들에 대하여 인식률을 확인하였다. 단일인식기 시스템의 인식방법으로는 k-NN과 선형 분류 방법에 해당하는 SVM_Linear와 비선형 분류를 위하여 RBF커널 함수를 이용한 SVM_RBF에 대하여 실험을 하였다. 또한 다중 인식기 시스템에서는 실험에 사용된 단일 인식기 방법들을 그대로 사용하여 k-NN, SVM_Linear, SVM_RBF의 인식결과를 결합하거나 지역적 영역에 대한 분류 정확도가 가장 높은 인식기를 선택하도록 하였다. 결합방법에 기반 한 다중 인식기 시스템으로는 다수 결 방식과 BKS방식에 대하여 실험을 하였고, 동적 인식기 선택 방법으로는 DCS_LA, DCS_MCB에 대하여 실험하여 표 1에 인식결과를 비교하였다.

표 3 여러 인식 방법에 대한 ELENA DB의 인식률(%)

실험 방법		Satimage	Phoneme
단일 인식기	k-NN	89.73 (5-nn)	86.29 (3-nn)
	SVM_Linear	85.37	77.34
	SVM_RBF	90.30	87.10
인식기 결합 방법	Majority Voting	90.39	86.94
	BKS	90.10	86.32
동적 인식기 선택 방법	DCS_LA	89.95	86.32
	DCS_MCB	90.01	86.32
제안한 방법		90.81	88.00

제안한 방법에서 설정해야하는 파라미터로는 마이크로 인식기를 구성할 때 이용할 학습 패턴 주변의 학습 대상이 되는 영역의 크기와 마이크로 인식기의 성능 측정을 위한 지역의 크기이다. 여기서 학습 영역의 크기는 Satimage 데이터 집합일 경우 50개로 설정한 경우 91.45%의 인식률을 보였으나 100개로 선정된 경우는 89.74%의 인식률을 보였다.

그림 6은 후보 마이크로 인식기들의 성능 측정을 위




그림 6 MC 성능 측정을 위한 주변 영역의 크기에 따른 인식률

한 테스트 주변의 영역 크기에 따른 인식률을 보인 것이다. Satimage 데이터에서는 크기가 5일 때 가장 높게 나타났으며, Phoneme 데이터에서는 30일 때 가장 좋은 성능을 보였다.

4.3 결과 분석

ELELNA DB의 Phoneme_CR과 Satimage_CR 데이터 집합을 이용하여 단일 인식기 시스템과 다중인식기 시스템의 여러 인식방법들에 대한 실험 결과에서 마이크로 인식기를 사용하여 동적으로 인식기를 선택한 방법이 다른 방법들보다 인식성능이 우수함을 볼 수 있다. Satimage 데이터 집합에 대해서는 다른 연구 방법 중 가장 높은 인식률을 가진 다수결 방식에 대한 인식률 90.39%와 비교하여 제안한 방법이 90.81%로 0.42% 성능 향상을 가져왔으며, Phoneme 데이터 집합에서는 SVM_RBF 방법이 87.10%로 높은 인식률을 보였으며 제안한 방법의 인식률 88.00% 과 비교하여 0.9% 성능 향상을 가져왔다. 단일 인식기 시스템에서는 RBF 커널을 사용한 SVM 인식방법이 가장 인식률이 높았으며, 인식결합방법과 동적인식기 선택 방법에서는 다수결 방식이 성능이 우수함을 보였다.

마이크로 인식기의 성능은 학습의 크기와 성능 측정을 위한 영역에 따라 차이를 보이고 있다. 크기가 클수록 전역적인 성격을 나타내며 작을수록 국소적이라 할 수 있다.

5. 결론 및 향후 연구 과제

본 논문에서 제안한 시스템은 각 학습 패턴에 대한 지역적 특성을 가지는 마이크로 인식기를 설계하여 테스트 단계에서 테스트 패턴의 지역적 영역에 속하는 마이크로 인식기들 중에서 가장 성능이 좋은 인식기를 동적으로 선택하게 된다.

제안한 다중 인식기 시스템은 결합방법에서의 단점인 다중 인식기를 구성하는 단일 인식기들에 대한 오류 독립 가정을 피할 수 있고, 새로운 입력 패턴 주변의 지역적 영역을 이용하므로 일반화 성능을 향상시킬 수 있으며, 입력 패턴 주변의 패턴 분포 정도에 따라서 최적의 파라미터 설정으로 인식률을 향상시킬 수 있다. 또한 동적 선택에서 마이크로 인식기는 클래스가 서로 다른 데이터들이 존재하는 경우에만 생성되어 동작되므로 클래스 사이의 결정 경계 부근의 국소적인 영역에서의 오류를 줄일 수 있기 때문에 기존에 연구되었던 다중 인식기 시스템과 비교하여 향상된 성능을 가져온다.

향후 연구 과제는 지역적 영역의 크기를 동적으로 처리하고, 데이터 분포를 분석하여 최적의 파라미터가 설

정될 수 있도록 한다면 일반화에 대한 문제 적응능력을 갖춘 시스템으로의 발전을 가져올 수 있게 될 것이다.

참고 문헌

- [1] L. Xu, A. Krzyzak and C. Y. Suen, "Methods of Combining Multiple Classifiers and Their Application to Handwriting Recognition," IEEE Transactions on System, Man, and Cybernetics, Vol. 22, No. 3, pp. 418-435, 1992.
- [2] F. Roli, J. Kittler (Eds.): Multiple Classifier Systems, Third International Workshop, MCS 2002, Cagliari, Italy, June 24-26, 2002, Proceedings. Lecture Notes in Computer Science 2364 Springer 2002.
- [3] T. K. Ho, J. J. Hull and S. N. Srihari, "Decision combination in multiple classifiers systems," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 16, No. 1, pp. 66-75, January 1994.
- [4] 이관용, 백종현, 변해란, 이일병, "다중인식기의 다단계 결합을 통한 무제약 필기 숫자 인식," 정보과학회논문지 (B) 제 26권 제 1호, pp.93-105, 1999.
- [5] J. Kittler, M. Hatef, R. P. W. Duin, J. Matas, "On combining classifiers," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 20, pp. 226 -239, March 1998.
- [6] K. Woods, W. P. Kegelmeyer Jr., K. Bowyer, "Combination of multiple classifiers using local accuracy estimates," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 19, pp. 405 -410, April 1997.
- [7] G. Giacinto and F. Roli, "Dynamic classifier selection based on multiple classifier behaviour," Pattern Recognition, Volume 34, Issue 9, pp. 1879-1881, September 2001.
- [8] L. Bottou and V. Vapnik. Local learning algorithms. Neural Computation, Vol. 4, No. 6, pp. 888-900, 1992.
- [9] G. Giacinto and F. Roli, "Methods for Dynamic Classifier Selection," ICIAP '99, 10th International Conference on Image Analysis and Processing, Venice, Italy, Sept 27 - 29, pp. 659-664, 1999.
- [10] Jain, A. K., Duin, P. W., Jianchang Mao, "Statistical pattern recognition: a review," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 22, pp. 4 -37, January 2000.
- [11] R. Liu and B. Yuan, Multiple classifiers combination by clustering and selection, Information Fusion, Volume 2, Issue 3, pp. 163-168, September 2001.
- [12] C. J. C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition," Data Mining and Knowledge Discovery, 1998.
- [13] J. Platt, N. Cristianini, J. Shawe-Taylor, "Large

Margin DAGs for Multiclass Classification," in Advances in Neural Information Processing Systems 12, pp. 547-553, MIT Press, 2000.

[14] <http://www.dice.ucl.ac.be/neural-nets/Research/Projects/ELENA/elena.htm>

[15] <http://theoval.sys.uea.ac.uk/~gcc/svm/toolbox>



송 해 정

1989년 한림대학교 전자계산학과(이학사), 1998년 한림대학교 컴퓨터공학과(공학석사). 2003년 한림대학교 컴퓨터공학과(공학박사). 2000년~현재 한림대학교 정보통신공학부 연구전임강사. 관심분야는 컴퓨터 비전, 패턴인식 등



김 백 섭

1978년 한양대학교 전자공학과(공학사). 1980년 한국과학기술원 산업전자공학과(공학석사). 1987년 한국과학기술원 전기 및 전자공학과(공학박사). 1984년~1986년 한양대학교 의과대학 계량의학교실 조교수, 1989년~1990년 Syracuse 대학 CASE center 객원연구원, 1987년~현재 한림대학교 정보통신공학부 교수, 관심분야는 컴퓨터 비전, 영상처리, 패턴인식, 신경망, 생체인식 등