

마이크로 인식기의 동적 선택에 의한 패턴인식

송혜정, 김백섭
한림대학교 컴퓨터공학과
e-mail:hjsong@hallym.ac.kr

A Pattern Recognition Algorithm based on Dynamic Selection of Micro Classifiers

Hyeo-Jung Song, Baek-Sop Kim
Dept. of Computer Engineering, Hallym University

요 약

최근 패턴인식분야에서 성능향상을 목적으로 개별인식기들을 결합하거나 동적 선택에 대한 연구가 활발하게 진행되고 있다. 인식기를 동적으로 선택하는 경우에는 전체 학습패턴으로부터 학습한 개별 인식기를 이용하거나 클러스터링 알고리즘을 이용하여 학습패턴들을 특징공간에서의 부 영역으로 분할한 다음 각 클래스를 하나의 영역과 대응하는 방법이 사용되어 왔다. 이러한 접근방법에서는 각 패턴의 전역적인 정보를 이용하기 때문에 클래스 사이의 결정 경계부분에 대한 지역적인 정보를 이용하기 어렵다. 본 논문에서는 학습패턴의 지역적 영역에 대한 마이크로 인식기를 설계하여 임의의 테스트 패턴에 대한 지역적 영역에서 가장 성능이 좋은 인식기를 동적으로 선택하여 인식 성능을 향상시키는 방법을 제안한다.

1. 서론

패턴인식기술에서 차원이 높은 복잡한 실세계의 응용에 대한 성능향상을 위해서 개별 인식기 시스템은 성능의 한계를 가지게 된다. 이는 하나의 인식기 안에서 다양한 형태의 특징 값을 효과적으로 분류해 내지 못하기 때문이다[1]. 따라서 여러 가지 상호보완적인 여러 인식기들을 사용하여 단일 문제로서의 분리과 결합을 통하여 성능향상에 도움을 주고 있는 다중 인식기 시스템(Multiple Classifier System)으로의 연구가 활발하게 진행 중에 있다[2].

다중 인식기 시스템을 구성하기 위해서는 두 가지 접근법이 있다. 첫 번째는 인식기를 병렬로 구성하여 입력패턴을 동시에 입력한 후 출력된 결과물을 이용하여 확률, 통계, 신경회로망, 퍼지등 다양한 분야의 이론을 결합하는 인식기 결합방법(classifier fusion algorithm)이고, 두 번째는 미지의 패턴을 가장 정확하게 분류할 수 있는 하나의 인식기를 동적으로 선택하는 동적 인식기 선택(dynamic classifier selection) 방법이다[4].

인식기 결합 방법은 사용된 각각의 개별 인식기들이 독립적인 오류를 생성한다는 가정에 기반을 두

고 있으나 실제 패턴인식응용에 있어서 오류에 독립적인 개별 인식기들의 집합을 설계하는 데는 어려움이 있다[1-2].

오류 독립 가정을 피하기 위한 접근방법으로 최근에 주목받는 동적 인식기 선택방법[4-7]은 학습 패턴들을 서로배타적인 조건을 가진 집합으로 분리한 다음 나누어진 각 영역에 대해 개별 인식기의 성능을 측정하고, 각 영역에 대해 가장 좋은 인식기를 결정하기 때문에 입력 패턴들을 부 영역으로 나누기 위한 클러스터링 방법이 요구된다. 각 영역은 개별 인식기 결정에 의한 집합으로 정의되며, 알려지지 않은 패턴은 가장 가까운 영역에 대입되고 해당 영역에서 가장 좋은 인식기에 대한 출력결과를 최종 결정으로 사용된다[3]. 그러나 이러한 방법은 미리 정해진 부 영역을 대표하는 클러스터의 중심 값의 정보를 이용하기 때문에 클래스 사이의 결정경계부분에 대한 정보를 얻기 어렵다.

본 논문에서는 클래스 사이의 결정 경계부분에 대한 정보를 이용하기 위하여 모든 학습패턴에 마이크로 인식기를 구성하여 포함시키고, 인식 단계에서 이들 중 가장 성능 좋은 인식기를 동적으로 선택하

는 시스템을 제안 한다. 마이크로 인식기는 각 학습 패턴의 특징공간상에서의 주변 패턴들로 정의된 지역적 영역을 SVM(Support Vector Machine)으로 학습한다. 모든 학습패턴들은 지역적 정보로 설계된 마이크로 인식기를 포함하고 있으면서 인식 단계에서 동적으로 선택된다. 인식기 선택을 위한 성능 측정 방법으로는 지역적 영역의 학습패턴들에 대한 마이크로 인식기의 정확성과 가까운 학습패턴들이 같은 클래스를 가지는 확률을 이용한다.

본 논문의 구성은 다음과 같다. 2장에서는 동적 인식기 선택 방법에 대한 기존 연구에 대하여 살펴보고, 3장은 제안한 인식기 시스템에서의 마이크로 인식기와 동적 선택 방법을 설명하고 4장은 제안한 시스템의 인식성능을 확인하기 위한 다양한 인식 방법들의 실험결과를 비교한다.

2. 동적 인식기 선택 방법 (Dynamic Classifier Selection)

개별 인식기들을 이용하여 학습한 결정 경계부분을 확인하면 지역적으로 결정 경계부분이 많이 다르다는 것을 알 수 있다. 이것은 개별 인식기 마다 특징공간에서 가장 성능이 좋은 자신만의 영역을 가지고 있다는 것을 나타내 주고 있다[7]. 그림1은 2차원 특징공간에 두개의 클래스를 가지는 패턴과 여러 개별 인식기에 대한 결정경계를 보인 것이다. 각 인식기 마다 서로 다른 결정경계를 보여주고 있음을 확인할 수 있다.




그림 1 여러 인식기에 대한 결정경계
(a) Linear Discriminant Classifier,
(b) Quadratic Discriminant Classifier,
(c) 5-Nearest Neighbor Classifier

인식기 결합방법에 대한 대안으로 Srihari[3]에 의해 제안된 동적 인식기 선택 방법은 학습 패턴들을 서로배타적인 조건을 가진 집합으로 분리한 다음 나

누어진 각 영역에 대해 인식기의 성능을 측정하여 각 부분에 대한 가장 좋은 인식기를 결정하는 방법이다. 테스트 단계에서 동적 선택되는 인식기들은 독립적일 필요가 없으며 정확하게 분류되는 하나의 인식기만이 필요기 때문에 독립기정보보다 안정적이며 인식기 결합방법보다 간단하다[5].

동적 인식기 선택 방법에 대한 대표적인 알고리즘은 다음과 같다.

(1)DCS_LA (Dynamic Classifier Selection by Local Accuracy)[5]

지역적 정확성 평가방법에 기반 한 동적 인식기 선택 방법은 미지의 패턴에 대해 모든 개별 인식기의 인식 결과가 일치하면 최종 결과로 출력하고, 일치하지 않는다면 각 인식기의 지역적 정확성을 측정하여 가장 정확성이 높은 인식기를 선택한다.

(2)DCS_MCB(Dynamic Classifier Selection based on Multiple classifier behaviour)[7]

DCS_MCB는 MCB방법과 지역적 정확성 평가방법을 결합한 동적 인식기 선택방법으로, MCB는 각 개별 인식기로부터 출력된 클래스 레이블의 집합이다. 입력 패턴 X^1 에 대하여 다음 식으로 표현된다.

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

MCB는 인식기의 정확성을 측정하기 위한 지역적 영역 선택에 사용되는데, 패턴들의 유사성을 측정하기 위해 MCB사이의 유사도를 이용한다.

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

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

미지의 테스트 패턴에 대해 MCB를 계산하여 유사도가 높은 k개의 학습패턴들을 적응적으로 선택하여 지역적 정확성이 큰 인식기의 출력을 최종 출력으로 한다. 테스트 패턴과 MCB 사이의 유사도 정도에 의존하여 지역적 영역에 대한 선택을 동적으로 적용시키는 방법이다.

3.제안한 인식 시스템

제안한 시스템의 구성도는 그림 2와 같다.




그림 2 제안한 시스템 구성도

제안한 시스템은 학습단계와 인식단계로 처리된다. 학습단계에서는 각 학습 패턴과 특징공간상에서 가까운 패턴들로 정의된 지역적 영역에 대한 마이크로 인식을 설계하고, 테스트 단계에서는 테스트 패턴의 지역적 영역에 포함되는 학습 패턴들에 대한 마이크로 인식기의 성능을 평가하여 가장 좋은 인식기의 출력을 최종 출력으로 결정하게 된다.

인식기를 동적으로 선택하기 위한 인식기 성능을 측정하는 방법으로는 지역적 정확성 방법에 가중치를 추가하여 성능 측정값을 계산한다. 학습패턴들에 대해서 각 패턴과 주변의 패턴들이 같은 클래스를 가지는 확률을 계산하여 정확하게 인식되는 학습패턴에 대해서는 가중치를 더하는 방법이다.

3.1 지역적 영역에 대한 마이크로 인식기 설계

학습 패턴마다 포함되는 마이크로 인식기는 각 학습패턴의 지역적 영역에 대하여 2개의 다른 인식 방법을 이용하여 설계한다. 마이크로 인식기는 학습 패턴들의 개수가 적기 때문에 통계적 결정 함수를 유도할 수 없고, 또한 신경망을 이용한 인식 방법에서는 오버러닝을 발생시킬 수 있기 때문에 학습 패턴의 개수가 적은 경우에도 잘 동작하는 SVM을 인식 방법으로 채택하였다. 각 학습패턴을 둘러싼 주변의 학습 패턴들을 이용하여 선형 SVM과 RBF 커널 함수를 이용한 비선형 SVM 학습방법으로 결정함수를 유도하였다.

SVM은 오버러닝의 영향을 적게 받으면서도 일반화 능력이 강하며, 작은 크기의 학습 패턴들로도 고차원 공간에서의 비선형 인식기 설계가 가능하고 큰 크기의 학습 패턴들로 구성된 경우라도 인식기 설계에 필요한 작은 support vector 집합만을 선택하므로 계산량을 최소화 할 수 있는 장점을 가지고 있다 [7].

본 논문에서는 개수가 적은 지역적 학습 패턴들로도 비선형 인식기 설계가 가능한 SVM을 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 [9]을 사용하였다. DAG SVM은 각 클래스마다 학습시킨 결과 값을 실수 값으로 얻어서 가장 큰 값을 가지는 클래스로 분류하는 방법이다.

3.2 마이크로 인식기의 동적 선택 시스템

시스템을 구성하는 학습 알고리즘과 인식알고리즘은 다음과 같다.

[학습알고리즘]

(1)클래스 레이블을 포함하는 학습 패턴 집합 $X = x_1, \dots, x_N$ 을 사용하여 각 학습 패턴 x_i 마다 가장 가까운 K 개의 패턴들을 이용하여 지역적 영역 $R_i = r_1, \dots, r_K$ 을 정의한다.

(2)각 학습 패턴 주변의 지역적 영역 R_i 을 이용하여 SVM_linear, SVM_rbf로 학습한 마이크로 인식기 MC_i^{svm} , MC_i^{rbf} 를 생성한다.

(3)학습 패턴 x 와 j 번째 가까운 패턴 x_j 가 같은 클래스를 가지는 확률 NP_j 을 계산한다.

$$NP_j = \sum_{k=1}^L P(x \in C_k, x_j \in C_k)$$

L : 클래스 개수, C_k : 클래스

[인식알고리즘]

(1)미지의 테스트 패턴 x 와 가까운 학습패턴 M 개를 선택한다. 각 학습패턴 $x_j, j = 1, \dots, M$ 에는 마이크로 인식기 MC_j^{svm} 와 MC_j^{rbf} 이 대응되어 있으므로 x 에 대해 $2M$ 개의 마이크로 인식기가 후보가 되어 이들은 후보인식기 CMC 라 부른다.

(2)각 후보 인식기 ($CMC_k, k = 1, \dots, 2M$)로 M 개의 학습패턴을 분류하여 모든 인식기의 결과가 같은 클래스 이면 출력하고 종료한다.

(3) 후보인식기의 분류 결과가 다르면 각 인식기의 성능측정값 g_k 를 계산한다.

$$g_k = \sum_j^M w_j^k NP_j$$

$$w_j^k = \begin{cases} 1 & \text{if } CMC_k(x_j) = C_j \\ 0 & \text{otherwise} \end{cases}$$

여기에서 $CMC_k(x_j)$ 는 CMC_k 로 x_j 를 분류한 결과이고, C_j 는 x_j 의 클래스이다.

(4)성능 측정값이 가장 큰 후보 인식기를 선택한다.

$$S = \arg \max g_k$$

(5) 테스트 패턴 x 를 선택된 CMC_S 로 분류하여 최종 클래스 레이블을 출력한다.

4. 실험 및 결과 분석

실험에 사용된 데이터는 ELENA project[8]의 데이터베이스에서 Phoneme_CR과 Satimage_CR 데이터 집합을 이용하였다.

Phoneme 데이터 집합은 콧소리와 말소리 모음을 구분하기 위한 데이터로 5개의 특징값을 가지고 총 150개의 패턴으로 구성되어 있으며, Satimage 데이터 집합은 지구자원 탐사 위성인 Landsat에 의한 다중분광스캐너 이미지로 4개의 분광 띠에 대한

3X3 픽셀값을 이용하여 6개의 클래스로 총 6435개의 패턴들로 구성되었다.

사용한 소프트웨어 툴로는 School of Information Systems, University of East Anglia에서 개발한 MATLAB Support Vector Machine Toolbox를 이용하였다[9].

제안한 방법에 대한 성능을 평가하기 위하여 동일한 데이터 집합을 사용하여 여러 가지 인식방법들에 대하여 인식률을 확인하였다. 개별인식기로는 k-NN과 선형 분류 방법에 해당하는 SVM_Linear와 비선형 분류를 위하여 RBF커널 함수를 이용한 SVM_RBF에 대하여 실험을 하였다. 기존의 동적 인식기 선택 방법으로는 DCS_LA, DCS_MCB에 대하여 실험하여 표 1에 인식결과를 비교하였다.

표 1 여러 인식 방법에 대한 인식률(%) 비교

실험방법		Satimage CR	Phoneme CR
개별 인식기	k-NN	89.73 (5-nn)	86.29 (3-nn)
	SVM_Linear	85.37	77.34
	SVM_RBF	90.30	87.10
동적 인식기 선택 방법	DCS_LA	89.95	86.32
	DCS_MCB	90.01	86.32
제안한 방법		90.81	88.00

여러 인식방법들에 대한 실험 결과에서 Phoneme_CR 데이터의 인식률을 살펴보면 개별인식기의 SVM_RBF 인식방법이 87.1%로 기본 방법 중에서 가장 높은 인식률을 나타내고 있으며, 제안한 방법은 88.0%로 SVM_RBF의 인식률보다 0.9% 성능향상을 가져왔다.

5. 결론

본 논문에서는 지역적 정보로 설계된 마이크로 인식기를 이용하여 지역적 영역에 대하여 가장 성능 좋은 인식기를 동적으로 선택하는 시스템을 제안하였다.

기존에 연구된 동적 인식기 선택 방법에서는 미리 정해진 부 영역을 대표하는 클러스터의 중심 값을 이용하므로 클래스 사이의 결정 경계 부분에 대한 정보를 얻기 어려웠다. 마이크로 인식기는 특징 공간에서의 지역적 영역에 대한 정보를 이용하기 때문에 결정 경계 부분에 존재하는 패턴들에 대해 오류를 최소화하여 인식 성능의 향상을 가져올 수 있었다.

참고문헌

- [1] L. Xu, A. Krzyzak, and C. Y. Suen, "Methods of Combining Multiple Classifiers and Their Application to Handwriting Recognition," IEEE Trans. on System, Man, and Cybernetics, Vol. 22, No. 3, pp. 418-435, 1992.
- [2] Fabio Roli, Josef 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] S. N. Srihari et al., "Decision combination in multiple classifiers systems," IEEE Trans. on PAMI, Vol. 16, No. 1, pp. 66-75, January 1994.
- [4] Woods, K., Kegelmeyer, W.P., Jr., Bowyer, K., "Combination of multiple classifiers using local accuracy estimates," IEEE Trans. on PAMI, Vol. 19 No. 4, pp. 405-410, April 1997.
- [5] 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.
- [6] G. Giacinto and F. Roli, "Dynamic classifier selection based on multiple classifier behaviour," Pattern Recognition, Volume 34, Issue 9, pp. 1879-1881, September 2001.
- [7] Jain, A. K., Duin, P. W., Jianchang Mao, "Statistical pattern recognition: a review," IEEE Trans. on PAMI, Vol. 22, pp. 4-37, January 2000.
- [8] <http://www.dice.ucl.ac.be/neural-nets/Research/Projects/ELENA/elena.htm>
- [9] <http://theoval.sys.uea.ac.uk/~gcc/svm/toolbox/>