

# 밀도에 기반한 퍼지 서포트 벡터 머신을 이용한 멀티 카테고리에서의 패턴 분류

## Density based Fuzzy Support Vector Machines for multicategory Pattern Classification

박종훈, 최병인, 이정훈  
한양대학교 전자전기제어계측공학과

Jong-Hoon Park, Byung-In Choi and Frank Chung-Hoon Rhee  
School of Electrical Engineering Computer Science, Hanyang University  
E-mail : {jhpark2, bichoi, frhee}@fuzzy.hanyang.ac.kr

### ABSTRACT

본 논문은 multiclass 문제에서 기존에 나와 있는 fuzzy support vector machines 이 decision boundary 를 설정하는데 있어 모든 훈련 데이터에 대해서 바람직한 decision boundary 를 만들지 못하므로 그러한 경우를 예로 제시한다. 그리고 그에 대한 개선점으로 밀도를 이용해 decision boundary 를 조정하여 기존 FSVM 의 decision boundary 보다 더 타당한 decision boundary 를 설정하는 것을 보인다.

**Key Words** : Fuzzy support vector machines, multiclass, density

### 1. 서 론

Support vector machines(SVMs) 은 Vapnik 에 의해 제안된 통계적 학습 이론에 기반을 두고 있다. SVM 은 많은 응용에서 전통적인 학습 기구들 보다 높은 수행성을 보여줬고 분류 문제를 해결하는 강력한 수단으로 소개되어 왔다. SVM 은 입력 데이터들을 고차원의 특징 공간으로 사영(mapping)하고, 이 공간에서 두 클래스 사이의 마진이 최대가 되는 optimal separating hyperplane 을 찾는다. 그러나 두 클래스가 아닌 여러개의 클래스로 문제가 확장 될 때는 4가지 타입의 방법들이 사용된다[1, 2, 3]. 그 중 pairwise support vector machines 은  $k$  개의 class problem 을  $k(k-1)/2$  개의 two-class problem 으로 바꾸어준다. 그러나 이 방법은 분류되지 않는 영역이 생긴다. 그래서 이것을 해결하기 위해 membership functions 을 이용하여 푸는 방법이 제안 되었다[4]. 그러나 membership function 을 이용한 방법도 완벽하지는 않다. 최적 hyperplane 을 결정하는 support vector 가 변하지 않는 한 어떠한 훈련 데이터가 들어와도 두 클래스를 분류하는 optimal separating hyperplane 는 변하지 않는다는 문제점이 있다. 본 논문의 목적은 fuzzy support vector machines 이 가지는

문제점을 해결하기 위해 밀도를 고려해줘 decision boundary 를 조정하고자 한다.

본 논문의 나머지는 다음과 같이 구성되어 있다. 2절에서는 SVM 의 이론을 설명하고 3 절에서는 membership function 을 이용한 FSVM 을 설명한다. 그리고 4절에선 밀도를 이용한 decision boundary 의 조정을 설명하고 5절에선 실험을 통한 성능을 보여주고 6절에서 결론을 짓는다.

### 2. Support Vector Machines

선형적으로 분리 가능한 두 데이터 집합에 대하여, SVM 은 그 평면에서 가장 가까운 support vector 들 간의 거리(margin)가 최대이고 두 데이터 집합을 분할하는 최대 마진 다차원 평면을 찾아 두 데이터 집합을 최적으로 분할한다. 주어진  $l$  개의 패턴 쌍  $(\mathbf{x}_i, y_i)$  들에 대하여, 최대 마진 hyperplane  $\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b$  는 다음의 quadratic programming problem 을 푸는 것에 의해서 얻어질 수 있다.

$$\begin{aligned} & \text{minimize} && \langle \mathbf{w} \cdot \mathbf{w} \rangle, \\ & \text{subject to} && y_i(\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b) \geq 1, \\ & && i = 1, \dots, l, \end{aligned} \quad (2.1)$$

여기서  $\mathbf{w}, b$  와  $y_i = 1$ 는 각각 가중치 벡터 (weight vector), 바이어스(bias), 그리고 클래스 라벨을 나타낸다. 식(2.1)은 다음의 목적 함수  $W(\alpha)$  를 최대화로 단순화할 수 있다.

$$\begin{aligned} \text{maximize } W(\alpha) &= \sum_{i=1}^l \alpha_i \\ &\quad - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle \mathbf{x}_i \cdot \mathbf{x}_j \rangle, \\ \text{subject to } \sum_{i=1}^l y_i \alpha_i &= 0, \alpha_i \geq 0, \\ i &= 1, \dots, l \end{aligned} \quad (2.2)$$

여기서  $\alpha$  는 Lagrange multiplier 를 나타낸다. 위의 2차 최적화 문제를 푸는 것으로 최적의 가중치 벡터  $\mathbf{w}^*$ 와 bias  $b^*$ 를 다음과 같이 얻을 수 있다.

$$\mathbf{w}^* = \sum_{i=1}^l y_i \alpha_i \mathbf{x}_i, \quad (2.3)$$

$$b^* = \frac{\max_{y_i=1} (\langle \mathbf{w}^* \cdot \mathbf{x}_i \rangle) + \min_{y_i=-1} (\langle \mathbf{w}^* \cdot \mathbf{x}_i \rangle)}{2} \quad (2.4)$$

여기서,  $\mathbf{w}^*$ 는 마진이  $1/\|\mathbf{w}^*\|$ 인 maximum margin hyperplane 을 형성한다. 선형 분리가 불가능한 데이터 집합에 대해서는 분리 불가능한 정도를 나타내는 변수  $\xi_i$ (slack variable) 를 위의 최적화 문제에 첨가하는 것이 요구되고 다음과 같이 표현될 수 있다.

$$\xi_i = \max(0, \gamma - y_i(\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b)) \quad (2.5)$$

식 (2.2)에  $\xi_i$  를 포함하면 다음과 같은 2차 최적화 문제를 얻을 수 있다.

$$\begin{aligned} \text{maximize } W(\alpha) &= \sum_{i=1}^l \alpha_i \\ &\quad - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle \mathbf{x}_i \cdot \mathbf{x}_j \rangle, \\ \text{subject to } \sum_{i=1}^l y_i \alpha_i &= 0, \\ C > \alpha_i &\geq 0, i = 1, \dots, l \end{aligned} \quad (2.6)$$

여기서  $C$ 는 양의 정수이다. 식(2.6)이 식 (2.2)에서 단지  $\alpha$  에 상한 값  $C$ 를 첨가한 것과 같으므로, 식(2.6)의 해답은 식(2.3), (2.4) 와 같다. 그리고 비선형적으로 분리가 불가능한 경우 데이터 공간의 패턴을 높은 차원의 속성공간으로 변환시켜주는 변환함수  $\phi(\cdot)$  를 이용하여 커널함수  $K$  를 통해 다음과 같이 2차최

적화 문제를 표현할 수 있다.

$$\begin{aligned} \phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j) &= K(\mathbf{x}_i \cdot \mathbf{x}_j) \\ \text{maximize } W(\alpha) &= \sum_{i=1}^l \alpha_i \\ &\quad - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j K(\mathbf{x}_i \cdot \mathbf{x}_j), \\ \text{subject to } \sum_{i=1}^l y_i \alpha_i &= 0, \\ C > \alpha_i &> 0, i = 1, \dots, l, \end{aligned} \quad (2.7)$$

### 3. Fuzzy Support Vector Machines

분류되지 않는 영역을 해결하기 위해 fuzzy membership functions 을 도입한다[4]. 이것은 클래스  $i$  에 대해서 클래스  $j$  의 optimal separating hyperplane 의 직각방향으로 membership functions  $m_{ij}(\mathbf{x})$  정의한다. 여기서  $D_{ij}(\mathbf{x}) = \mathbf{w}_{ij}^t \mathbf{x} + b_{ij}$  이고  $D_{ij} = -D_{ji}$ 이다.

$$m_{ij}(\mathbf{x}) = \begin{cases} 1 & \text{for } D_{ij}(\mathbf{x}) \geq 1, \\ D_{ij}(\mathbf{x}) & \text{otherwise} \end{cases} \quad (3.1)$$

여기서는 음의 membership degree 도 허용해준다. minimum operator 를 사용하여 클래스  $i$ 의 membership function 을 정의할 수 있다.

$$m_i(\mathbf{x}) = \min_{j=1, \dots, k} m_{ij}(\mathbf{x}) \quad (3.2)$$

식(3.2)를 사용하여 data  $\mathbf{x}$  는 식(3.3)에 의해 분류된다.

$$\operatorname{argmax}_{i=1, \dots, k} m_i(\mathbf{x}) \quad (3.3)$$

그래서 minimum operator 에 의해 분류되지 않는 영역은 아래 그림처럼 조정될 수 있다.[4]




Fig1. Decision boundary with membership functions

### 4. Density based Fuzzy Support Vector Machines

Fuzzy support vector machines 에선 분류될 수 없는 영역은 두 클래스의 optimal separating hyperplane 에 의해 형성되는데 그것은 결국 서포트 벡터의 위치에 의한 것이라고 말할 수 있다. 그런데 퍼지 서포트 벡터 머신[4]은 이 서포트 벡터의 위치가 변하지 않으면 어떤 입력 데이터가 들어오더라도 두 클래스의 optimal separating hyperplane 은 변하지 않으며 decision boundary 도 변하지 않는다는 문제점이 있다. 이것을 해결하기 위해 본 논문에선 입력 데이터의 밀도분포를 통해 decision boundary 를 조정하려 한다. 각 클래스의 훈련 데이터 주변 밀도를 추정함으로써 분류되지 않는 영역에서 각 클래스의 밀도가 decision boundary 에 영향을 미치도록 하였다. 각 클래스의 훈련 데이터 주변의 밀도추정 방법은 parzen-window 방법[5]을 사용한다.

$\mathbf{x}_n$ 의 밀도를 추정하기 위해  $\mathbf{x}_n$ 을 포함하는 영역  $R_n$ 을 형성한다. 이때  $V_n$ 을  $R_n$ 의 부피라고 하고,  $k_n$ 을  $R_n$ 안의 데이터 수라고 한다면 밀도 추정치  $p_n(\mathbf{x})$ 는 다음과 같은 식을 가진다.

$$p_n(\mathbf{x}) = \frac{k_n/n}{V_n} \quad (4.1)$$

Parzen windows 는 영역  $R_n$ 을 고정시키고, 영역안에 존재하는 데이터의 개수  $k_n$ 을 계산하여 밀도추정치  $p_n(\mathbf{x})$ 를 얻는 방법이다.

$$p_n(\mathbf{x}) = \frac{1}{n} \sum_{i=1}^n \frac{1}{V_n} \varphi\left(\frac{\mathbf{x}-\mathbf{x}_i}{h_n}\right) \quad (4.2)$$

$h_n$  : 다차원 공간의 선분길이

$V_n = h_n^d$  : 다차원 공간의 부피

$p_n(\mathbf{x})$ 는  $h_n$ 에 따라 값에 따라  $h_n$ 이 작으면 밀도분포가 완만해지고  $h_n$ 가 커지면 밀도분포가 날카로워진다. 또한 밀도분포를 normalize 시키기 위해  $p_n(\mathbf{x})$ 의 최대값으로 나누어 주어야 한다.

식(4.2)를 이용하여 두 클래스의 optimal separating hyperplane  $D_{ij}$ 를 새롭게 정의한다.

$$D_{ij}(\mathbf{x}) = \alpha(\mathbf{w}_{ij}^T \mathbf{x} + b_{ij}) + (1-\alpha)(p_{n_i}(\mathbf{x}) - p_{n_j}(\mathbf{x})) \quad (4.3)$$

여기서  $\alpha$ 는 밀도와 마진 사이의 중요도를 주는 파라미터이다. 식(4.3)을 식(3.1)에 대입하여 새로운  $m_{ij}(\mathbf{x})$ 를 얻을 수 있다. 이를 통해 클래스  $i$ 에 대한 minimum operator 로 membership function 을 얻을 수 있다.

$$m_i(\mathbf{x}) = \min_{j=1,\dots,k} m_{ij}(\mathbf{x}) \quad (4.4)$$

식(4.4)를 이용하여 data  $\mathbf{x}$ 는 식(4.5)에 의해 분류된다.

$$\operatorname{argmax}_{i=1,\dots,k} m_i(\mathbf{x}) \quad (4.5)$$

### 5. 실험 결과

본 논문에서 제안한 방법의 타당성을 보이기 위하여 기존 FSVM 의 decision boundary 설정이 좋지 못한 예를 위에서 제안한 방법으로 시뮬레이션 한 결과를 보이도록 하겠다.

class 가 3개이고 각 훈련 데이터가 98, 93, 64개씩인 경우를 위에 제안한 알고리즘에 의해 실험하였다. 데이터가 서포트 벡터가 변하지 않는 범위에서 분포하고 있다. 기존방법에 의한 decision boundary 는 아래 그림과 같다.





Fig 2. FSVM decision boundary for 3-class

class3의 데이터 분포는 나머지 class 처럼 고르지 못하고 가운데 부분에 데이터가 존재하지 않는다. 따라서 가운데 그만큼 밀도의 영향을 더 받게 된다. 다음 그림들은 기존의 FSVM 방법, 밀도, 제안한 방법의 min, max operator 적용단계를 gray level로 표현했다.






Fig 3. 기존 FSVM (a)  $m_1$  (b)  $m_2$  (c)  $m_3$  (d) max




Fig 4. 밀도 (a)  $m_1$  (b)  $m_2$  (c)  $m_3$  (d) max





Fig 5. FSVM+밀도 (a)  $m_1$  (b)  $m_2$  (c)  $m_3$  (d)  $m_4$





Fig 6. FSVM+밀도를 이용한 decision boundary

이 실험은 윈도우 사이즈를 0.2 로 하였고  $\alpha$  값을 0.3 으로 하여  $D_{ij}$  가 밀도에 더 영향을

받도록 하였다. 윈도우 사이즈가 작게 되면 분류되지 않는 영역에 데이터가 존재하지 않기 때문에 밀도의 영향이 줄어들어 기존 FSVM의 decision boundary 와 똑같은 결과를 가져온다.  $\alpha$  값의 변화를 주었을 decision boundary 변화가 심하였다. 이는 밀도와 마진 중 어떤 것에 더 중요도를 두느냐에 따라 decision boundary 가 변화되는 것으로  $\alpha$  값이 작으면 밀도의 영향을 많이 받아 decision boundary 가 많이 변화되고  $\alpha$  가 크면 밀도의 영향을 덜 받아 기존의 FSVM decision boundary 와 유사하게 형성된다.

## 6. 결론

본 논문이 제안한 알고리즘은 기존 FSVM 이 서포트 벡터가 변하지 않는 이상 어떤 훈련 데이터에 대해서도 decision boundary 가 똑같은 문제가 있어 decision boundary 를 형성하는 separating hyperplane 에 parzen-window 를 적용하여 각 클래스의 훈련 데이터의 밀도 분포가 decision boundary 에 영향을 미치게 하였다. 데이터의 밀도를 통해 decision boundary 를 조정하여 훈련데이터에 대한 더 정확한 decision boundary 를 형성하였다.

감사의 글 : 본 연구는 한국과학기술원 영상 정보특화센터를 통한 국방과학연구소의 연구비 지원으로 수행되었습니다.

## 참고 문헌

- [1] Vapnik, V. (1998). *Statistical learning theory*. New York: Wiley
- [2] Krebel, U. H.-G (1999). Pairwise classification and support vector machines. In B. Scholkopf, C. J. C. Burges, & A. J. smola (Eds.), *Advances in kernel methods: Support vector learning* (pp. 255-268). Cambridge, MA: MIT Press.
- [3] Dietterich, T.G., & Bakiri, G. (1995). Solving multiclass learning problems via error-correcting output codes. *Journal of Artificial Intelligence Research*, 2, 263-286
- [4] Daisuke Tsujinishi, Shigeo Abe (2003). Fuzzy least squares support vector machines for multiclass problems. *Neural Networks*, 16, 785-792.
- [5] Richard O. Duda, Peter E. Hart, David G. Stork (2000) *pattern classification*.: Wiley