

# Fuzzy Twin Support Vector Machine 개발 및 전리층 레이더 데이터를 통한 성능 평가

## Development of Fuzzy Support Vector Machine and Evaluation of Performance Using Ionosphere Radar Data

천민규 · 윤창용 · 김은태 · 박민용

Minkyu Cheon, Changyong Yoon, Euntai Kim and Mignon Park

연세대학교 전기전자공학부

### 요 약

Support Vector Machine(SVM)은 통계적 학습 이론에 기반을 둔 분류기이다. 또한 Twin Support Vector Machine(TWSVM)은 이진 SVM 분류기의 한 종류로써, 서로 관련된 두 개의 SVM 유형 문제를 통해 평행하지 않은 두 개의 평면을 결정하고 이 두 평면을 통해 분류기를 완성하는 방식이다. 이러한 방식의 TWSVM은 학습 시간이 SVM에 비해 훨씬 짧으며, SVM과 비교하여 떨어지지 않는 성능을 보여준다. 본 논문은 분류기 입력에 Fuzzy Membership을 적용하는 방식의 TWSVM을 제안하고, 전리층 레이더 데이터를 이용한 실험을 통하여 기존에 제시되었던 분류기와 비교한다.

키워드 : 패턴 분류, Support Vector Machine, Twin Support Vector Machine, Fuzzy Membership, 전리층 레이더 데이터

### Abstract

Support Vector machine is the classifier which is based on the statistical training theory. Twin Support Vector Machine(TWSVM) is a kind of binary classifier that determines two nonparallel planes by solving two related SVM-type problems. The training time of TWSVM is shorter than that of SVM, but TWSVM doesn't shows worse performance than that of SVM. This paper proposes the TWSVM which is applied fuzzy membership, and compares the performance of this classifier with the other classifiers using Ionosphere radar data set.

Key Words : pattern classification, Support Vector Machine, Twin Support Vector Machine, Fuzzy Membership, Ionosphere radar data

## 1. 서 론

Support Vector Machine(SVM)은 패턴을 고차원 특징 공간으로 사상시킬 수 있다는 점과 대역적으로 최적의 식별이 가능하다는 특징을 가진다. 여기서 가중치는 일반적인 신경망과는 달리 선형 부등 조건을 가진 Quadratic Programming (2차 계획법) 문제를 해결함으로써 얻어지게 된다. 또한 전통적인 대부분의 패턴인식 기법들은 학습 데이터의 수행도를 최적화하기 위한 경험적인 위험 최소화 방법에 기초하고 있는데 반하여, SVM은 고정되어 있지만 알려지지 않은 확률 분포를 갖는 데이터에 대해 잘못 분류하는 확률을 최소화하는 구조적인 위험 최소화 방법에 기초하고 있다. [8]

최근에 제시된 Twin Support Vector Machine (TWSVM)은 분류된 클래스 마다 Quadratic Programming 문제를 적용, 해결하여 클래스마다 서로 평행하지 않는 경계들을 생성한 뒤, 각각의 경계를 이용하여 새로운 분류기를 형성하는 방식이다.

본 논문에서는 최근에 제시된 Twin Support Vector Machine에 Fuzzy Membership을 적용하여, 전리층 레이더 데이터를 통해 기존의 Twin Support Vector Machine과 ELM (Extreme Learning Machine)과의 성능을 비교하였다.

## 2. Twin Support Vector Machine

Twin Support Vector Machine은 군집화된 각 클래스의 데이터 주위에 평행하지 않은 경계를 형성한다. Twin Support Vector Machine의 각 클래스에 대한 두 개의 2차 계획법 문제는 전형적인 Support Vector Machine의 2차 계획법 문제와 형태가 일치한다. [1]

TWSVM 분류기는 다음의 두 개의 2차 계획법 문제를 해결함으로써 얻어지게 된다.

(TWSVM 1)

$$\begin{aligned} \text{Min} \quad & (Aw^{(1)} + e_1b^{(1)})^T(Aw^{(1)} + e_1b^{(1)}) + c_1e_2^Tq \\ & w^{(1)}, b^{(1)}, q \\ & -(Bw^{(1)} + e_2b^{(1)}) + q \geq e_2, \quad q \geq 0 \end{aligned} \quad (1)$$

접수일자 : 2007년 10월 30일

완료일자 : 2008년 1월 9일

본 연구는 한국과학재단 특정기초연구(R01-2006-000-11016-0)지원으로 수행되었음.

(TWSVM 2)

$$\begin{aligned} & \text{Min} (Bw^{(2)} + e_2b^{(2)})^T(Aw^{(2)} + e_2b^{(2)}) + c_2e_1^Tq \\ & w^{(2)}, b^{(2)}, q \\ & -(Aw^{(2)} + e_1b^{(2)}) + q \geq e_1, \quad q \geq 0 \end{aligned} \quad (2)$$

이 때, A와 B 행렬은 각각 +1과 -1 클래스에 속하는 데이터 행을 포함한 행렬이다. 클래스 +1에 속하는 데이터의 수가  $m_1$ , 클래스 -1에 속하는 데이터의 수가  $m_2$ ,  $x \in R^n$  일 경우, A 행렬은  $m_1 \times n$ , B 행렬은  $m_2 \times n$ 이 된다.  $c_1, c_2$ 는 모두 0보다 크며,  $e_1$ 과  $e_2$  벡터는 행렬 연산에 있어 차원을 맞추어 주기 위한 모든 요소가 1인 벡터이다. 벡터  $q$ 는 잘못 분류된 학습 데이터에 해당하는 음이 아닌 여러 변수이다.

이 알고리즘은 각각의 클래스에 속한 데이터들로 부터 거리의 합이 가장 작은 평면을 찾는 과정이다.

식(1), (2)의 첫 번째 수식은 목적 함수로써 하나의 클래스의 데이터들과 평면까지의 거리의 합과 여러 변수의 합을 최소화하는 과정을 의미한다. 이 때,  $c_1$ 과  $c_2$ 는 평면과 데이터 사이 거리 합의 최소화와 여러 변수 합의 최소화의 중요도를 결정하는 변수이다. 즉,  $c$ 가 크다면 평면과 데이터 사이 거리의 최소화 보다 잘못 분류된 학습 데이터에 해당하는 여러 변수를 최소화가 우선시 될 것 이며,  $c$ 가 작다면 여러 변수 최소화 보다는 평면과 데이터 간의 거리 최소화가 중요시되는 알고리즘이 될 것이다. 두 번째 수식은 제약 식으로써 다른 클래스에 속한 데이터로부터 평면까지의 거리가 적어도 1만큼 떨어져 있어야 함을 의미한다.

다시 말해, TWSVM은 각 클래스에 대한 목적 함수와 다른 클래스 패턴에 의해 결정되는 제약식을 결정하는 2차 계획법 문제를 포함한다. 즉, TWSVM1은 클래스 +1의 데이터들을  $x^T w^{(1)} + b^{(1)} = 0$  주위로 군집화하고, TWSVM2는 클래스 -1의 데이터들을  $x^T w^{(2)} + b^{(2)} = 0$ 로 군집화 한다.

그리고, 데이터의 수가  $m$ 이라 가정하면, 일반적인 SVM의 복잡도는  $m^3$ 이 되고, TWSVM의 경우는 이를 두 종류의 문제로 각각 나누어 복잡도를 측정하게 된다. 가령 각각의 데이터 수를  $m/2$ 라고 한다면 SVM과 TWSVM의 실행 시간 비율은 다음과 같다.

$$\left[ \left( m^3 / \left( 2 \times \left( \frac{m}{2} \right)^3 \right) \right) \right] = 4$$

즉, TWSVM의 학습 속도가 일반적인 SVM에 비해 4배 정도 빠름을 알 수 있다.

식 TWSVM1 (1)을 통해 라그랑지안 함수를 유도하면 다음과 같다.

$$\begin{aligned} L(w^{(1)}, b^{(1)}, q, \alpha, \beta) &= \frac{1}{2}(Aw^{(1)} + e_1b^{(1)})^T(Aw^{(1)} + e_1b^{(1)}) \\ &+ c_1e_2^Tq - \alpha^T(-(Bw^{(1)} + e_2b^{(1)}) + q - e_2) - \beta^Tq \end{aligned} \quad (3)$$

이 때,  $\alpha$ 와  $\beta$ 는 라그랑제 승수로써 각각  $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_{m_2})^T$ ,  $\beta = (\beta_1, \beta_2, \dots, \beta_{m_2})^T$ 이다. 그리고 위의 라그랑지안 함수 식 (3)에 대한 K.K.T. (Karush-Kuhn-Tucker)조건을 정리하면 다음과 같다.

$$A^T(Aw^{(1)} + e_1b^{(1)}) + B^T\alpha = 0 \quad (4)$$

$$e_1^T(Aw^{(1)} + e_1b^{(1)}) + e_2^T\alpha = 0 \quad (5)$$

$$c_1e_2 - \alpha - \beta = 0 \quad (6)$$

$$-(Bw^{(1)} + e_2b^{(1)}) + q \geq e_2, \quad q \geq 0 \quad (7)$$

$$\alpha^T(-(Bw^{(1)} + e_2b^{(1)}) + q - e_2) = 0, \quad \beta^Tq = 0 \quad (8)$$

$$\alpha \geq 0, \quad \beta \geq 0 \quad (9)$$

이 때,  $\beta \geq 0$  이므로, (6)을 통해

$$0 \leq \alpha \leq c_1 \quad (10)$$

를 알 수 있고, 식(4)와 (5)를 함께 정리하면 다음과 같다.

$$[A^T \ e_1^T][A \ e_1][w^{(1)}, b^{(1)}]^T + [B^T \ e_2^T]\alpha = 0 \quad (11)$$

$H = [A \ e_1]$ ,  $G = [B \ e_2]$ ,  $u = [w^{(1)}, b^{(1)}]$ 라 하면 식 (11)은 다음과 같이 정리될 수 있다.

$$H^T H u + G^T \alpha = 0, \quad \text{즉, } u = -(H^T H)^{-1} G^T \alpha \quad (12)$$

식 (12)에서의 벡터  $u$ 는 경계면을 결정하는 벡터인  $w^{(1)}$ 과 변수  $b^{(1)}$ 을 포함하고 있다. 또한 벡터  $u$ 를 구하기 위한  $\alpha$ 는 라그랑지안 함수인 식 (3)과 K.K.T 조건을 결합한 아래의 최적화 문제를 해결함으로써 얻을 수 있다.

$$\begin{aligned} & \text{Max}_{\alpha} \ e_2^T \alpha - \frac{1}{2} \alpha^T (G(H^T H)^{-1} G) \alpha \\ & 0 \leq \alpha \leq c_1 \end{aligned} \quad (13)$$

위와 같은 방법으로 TWSVM2에 대해서 정리하면 다음과 같다.

$$\begin{aligned} & \text{Max}_{\alpha} \ e_1^T \gamma - \frac{1}{2} \gamma^T (H(G^T G)^{-1} H) \gamma \\ & 0 \leq \gamma \leq c_2 \end{aligned} \quad (14)$$

또한, TWSVM2의  $w^{(2)}$ 와  $b^{(2)}$ 를 포함하는 벡터  $v = [w^{(2)}, b^{(2)}]$ 는 다음과 같이 나타낼 수 있다.

$$v = (G^T G)^{-1} H^T \gamma \quad (15)$$

식 (12)와 (15)를 통해 클래스 +1과 클래스 -1에 대한 평행하지 않은 두 평면을 결정할 수 있고, 새로운 데이터  $x \in R^n$ 에 대해 어떤 클래스에 속하는지를 결정하는 결정 평면은 다음과 같이 나타 낼 수 있다.

$$x^T w^{(r)} + b^{(r)} = \text{Min}_{l=1,2} |x^T w^{(l)} + b^{(l)}| \quad (16)$$

### 3. Fuzzy Twin Support Vector Machine

#### 3.1 Fuzzy Membership을 포함한 데이터 집합

Fuzzy Membership을 포함한 학습 데이터들의 집합을 다음과 같다고 가정한다. [2], [3], [4]

$$(y_1, x_1, s_1), \dots, (y_m, x_m, s_m) \quad (17)$$

$x_i$ 는 학습 데이터,  $y_i$ 는 +1 또는 -1로써 데이터가 속한 클래스를 의미하며,  $s_i$ 는 각 데이터마다 부여되는 Fuzzy

Membership으로써  $0 \leq s_i \leq 1$ 의 범위를 갖는다.

위의 데이터 집합을 기반으로 하여 TWSVM1의 라그랑지안 함수를 재구성하면 다음과 같다.

$$L(w^{(1)}, b^{(1)}, q, \alpha, \beta) = \frac{1}{2}(Aw^{(1)} + e_1b^{(1)})^T(Aw^{(1)} + e_1b^{(1)}) + c_1s_{+1,i}e_2^Tq - \alpha^T(-(Bw^{(1)} + e_2b^{(1)}) + q - e_2) - \beta^Tq \quad (18)$$

또한 TWSVM1의 최적화 함수에  $s_{+1,i}$ 를 추가함으로써 식 (13)의 제약식 즉,  $\alpha$ 의 범위가 다음과 같이 바뀌게 된다.

$$0 \leq \alpha \leq s_{+1,i}c_1 \quad (19)$$

즉, 식 (13)과 (14)를 재구성하면 다음과 같다.

$$\begin{aligned} \text{Max}_{\alpha} \quad & e_2^T\alpha - \frac{1}{2}\alpha^T(G(H^TH)^{-1}G)\alpha \\ & 0 \leq \alpha \leq s_{+1,i}c_1 \end{aligned} \quad (20)$$

$$\begin{aligned} \text{Max}_{\alpha} \quad & e_1^T\gamma - \frac{1}{2}\gamma^T(H(G^TG)^{-1}H)\gamma \\ & 0 \leq \gamma \leq s_{-1,i}c_2 \end{aligned} \quad (21)$$

### 3.2 Fuzzy Membership의 결정

TWSVM의 식(1), (2)에 포함된 변수  $c_1, c_2$ 는 앞서 언급한 바와 같이 식 (1)과 (2)의 최소화 과정에서 데이터와 평면 사이 거리 합의 최소화와 에러 변수의 최소화 사이의 중요도를 결정하는 변수이다.

이에 반해, 식(18)에 포함된  $s_i$ 는 두 종류의 클래스로 데이터를 분류하는데 있어, 데이터 자체의 중요도를 결정하는 변수이다. 즉, 앞서 제시한 일반적인 TWSVM은 모든 데이터가 동일한 중요도를 가지는 반면, Fuzzy Membership을 포함한 TWSVM은 각 데이터마다 중요도가 부가되어 잘못 분류된 데이터와 실제 속한 클래스에 해당하는 평면과의 단순 거리가 아닌 잘못 분류된 데이터의 중요도를 함께 포함하여 최소화하게 된다.

본 논문에서는 각 클래스의 평균값에서 가까울 수록  $s_i$ 에 큰 수를 적용하는 방식을 선택하였으며, 그 값을 정하는 방식은 다음과 같다.

클래스 +1 데이터 값의 평균을  $x_+$ , 클래스 -1 데이터 값의 평균을  $x_-$ 라 한다. 이 때, 클래스 +1과 클래스 -1에 대해 각 클래스의 데이터를 모두 포함하는 원의 반지름은 다음과 같다. [4]

$$\text{클래스 +1 : } r_+ = \text{Max} |x_+ - x_i| \quad \{x_i : y = +1\}$$

$$\text{클래스 -1 : } r_- = \text{Max} |x_- - x_i| \quad \{x_i : y = -1\}$$

위의 결과를 이용하여, 각 데이터에 해당하는 Fuzzy Membership을 다음과 같이 적용한다.

$$s_{+1,i} = 1 - |x_+ - x_i| / (r_+ + \delta) \quad (22)$$

$$s_{-1,i} = 1 - |x_- - x_i| / (r_- + \delta) \quad (23)$$

식 (22)와 (23)의  $\delta$ 는  $r_+$  또는  $r_-$ 가 0이 될 경우를 고려

하여 추가된 상수이며, 위와 같이 결정된  $s_{+1,i}$ 과  $s_{-1,i}$ 는 0보다 크고, 1보다 같거나 작은 값을 갖게 된다.

## 4. 시뮬레이션을 통한 Fuzzy TWSVM의 성능 분석

### 4.1 2차원 데이터를 통한 TWSVM과 Fuzzy TWSVM의 성능 비교

시뮬레이션에 적용될 학습 데이터로서 2차원 벡터를 사용하였다. ( $x = [x_1 \ x_2]$ ) 클래스 +1의 데이터는 [0 0]를 중심으로  $x_1, x_2$ 를 각각 0부터 10까지 랜덤하게 발생시킨 벡터를 사용하였으며, 클래스 -1의 데이터는 [20 20]을 중심으로  $x_1, x_2$ 를 각각 0부터 10까지 랜덤하게 발생시킨 벡터를 사용하였다.

그림 1과 그림 2는 같은 데이터를 각각 TWSVM과 Fuzzy TWSVM을 사용하여 분류한 결과를 보여준다.

두 분류기의 성능 비교를 위해 클래스 +1과 클래스 -1 각각 300개의 학습 데이터를 생성하고, 동일한 데이터를 두 분류기에 적용하여 분류 성공률을 비교하였다.

이 때, TWSVM의  $c_1$ 과  $c_2$ 는 각각 100으로 지정하고, Fuzzy TWSVM의  $c_1$ 과  $c_2$ 의 경우는 잘못 분류된 데이터의 중요도를 최대한 TWSVM과 비슷하게 하여 비교하기 위해 100을 클래스 +1과 클래스 -1 데이터의  $s_i$ 값의 평균으로 나누어 지정하였다. 즉, Fuzzy TWSVM의  $c_1s_{+1,i}$ 과  $c_2s_{-1,i}$  평균값이 TWSVM의  $c_1, c_2$ 와 최대한 동일하게 지정하였다. 다음의 표 1은 앞서 설명한 실험의 결과를 보여준다.

표 1. Fuzzy TWSVM과 TWSVM 학습 데이터 분류 성공률 (단위 %)

Table 1. Training accuracy of Fuzzy TWSVM and TWSVM (unit %)

FTWSVM	91.5	92.5	91.17	91.17	
TWSVM	91.3	92.5	91.17	90.83	
93	91.5	90.17	92	90.83	91.3
93	91.17	89.83	91.67	91	91.3

실험 결과 Fuzzy TWSVM 분류기는 TWSVM 분류기보다 좋은 결과를 보여준다. 연속적인 10번의 실험에서 6차례가 Fuzzy TWSVM의 학습 데이터 분류 성공률이 높게 나왔으며, 3차례가 동일한 성공률을 보였다. 평균적인 성공률은 Fuzzy TWSVM의 경우 91.51%, TWSVM의 경우는 91.38%로써 Fuzzy TWSVM의 경우가 600개 데이터 기준으로 한 번의 수행에 대해 약 0.85개 정도의 에러 데이터의 수가 적다고 볼 수 있다.




그림 1. TWSVM을 통한 데이터 분류  
Fig 1. Data classification with TWSVM




그림 2. Fuzzy TWSVM을 통한 데이터 분류  
Fig 2. Data classification with Fuzzy TWSVM

4.2 전리층 레이더 데이터를 통한 Fuzzy TWSVM의 성능 분석

본 절에서는 전리층 레이더 데이터를 TWSVM과 Fuzzy TWSVM을 통해 분류하였다. [7]

표 2. 전리층 레이더 데이터  
Table 2. Ionosphere radar data

데이터 수	특징점 차원	클래스
351	34	2 (good/bad)

10 fold cross validation을 통해 위의 데이터를 분류한 학습 및 테스트 분류성공률의 평균값은 표3과 같다.

전리층 레이더 데이터 분류 결과, 학습과 테스트 모두 Fuzzy TWSVM 분류기의 성공률이 TWSVM에 비해 뛰어난 것을 볼 수 있었다.

표 3. 10 fold cross validation에 의한 TWSVM과 Fuzzy TWSVM의 학습 및 테스트 분류 성공률 (단위 %)  
Table 3. Training and test accuracy of TWSVM and Fuzzy TWSVM using 10 fold cross validation (unit %)

	TWSVM	Fuzzy TWSVM
학습	88.61	92.67
테스트	86.29	87.43

또한, Fuzzy TWSVM은 fuzzy membership이 상대적으로 큰 데이터에 대해 더 정확한 분류 성능을 보였다.

표4는 Fuzzy TWSVM과 TWSVM에 의한 분류 결과 서로 다른 데이터를 비교한 결과이다.

전리층 레이더 데이터 분류의 결과를 분석해 본 결과, 분류 성공률 측면에서 Fuzzy TWSVM이 더 좋은 결과를 보여 주었지만, TWSVM을 통해 올바르게 분류된 모든 데이터들이 Fuzzy TWSVM을 통해서도 모두 올바르게 분류되는 않았다. 표4를 통해 Fuzzy TWSVM을 통한 분류는 fuzzy membership 값에 크게 의존함을 볼 수 있다.

상대적으로 fuzzy membership의 값이 큰, Index가 1~7인 데이터들은 TWSVM을 통해서는 잘못 분류되었으나, Fuzzy TWSVM을 통해서는 올바르게 분류되었음을 볼 수 있으나, index 8과 9의 데이터는 TWSVM에서는 올바르게 분류되었으나, 오히려 Fuzzy TWSVM을 통해서는 잘못 분류되었음을 확인할 수 있다.

이처럼 본 논문에서 제안한 Fuzzy TWSVM은 기존의 TWSVM에 비해 좋은 학습과 테스트 결과를 보여주었으며, 개발자가 임의로 결정할 수 있는 특정 데이터에 대한 중요도(fuzzy membership)가 클수록 더 좋은 분류 결과를 기대할 수 있다고 볼 수 있다.

표 4. Fuzzy membership 비교  
Table 4. Comparison of fuzzy membership

데이터 index	Fuzzy membership	TWSVM 분류결과	Fuzzy TWSVM 분류결과
1	0.82	F	T
2	0.65	F	T
3	0.81	F	T
4	0.74	F	T
5	0.60	F	T
6	0.64	F	T
7	0.78	F	T
8	0.14	T	F
9	0.42	T	F

표5는 표3과 동일한 데이터 전리층 레이더 데이터 집합을 이용한 hidden layer가 50개인 ELM (Extreme Learning Machine)과 Fuzzy TWSVM의 학습과 테스트 분류 성공률을 보여준다.[5],[6] 동일한 데이터 집합에 대해서, Fuzzy TWSVM는 ELM에 비해 학습 과정에서의 분류

성공률은 약간 떨어지나 테스트 과정에서의 분류 성공률은 동일함을 볼 수 있다. 이는, 기본적으로 SVM의 학습 과정이 마진을 최대화하는 과정을 포함하므로 단순히 여러 최소화에 기반을 둔 학습 과정을 통한 ELM에 비해 학습 과정에서의 분류 성공률과 크게 차이가 나지 않는 테스트 결과를 기대할 수 있기 때문이다. 실제로 어떠한 데이터 집합에 대해서는 Fuzzy TWSVM의 학습 과정에서의 성공률은 ELM에 비해 떨어지는데 반해 오히려 테스트 과정에서의 성공률은 Fuzzy TWSVM이 더 높게 나타나는 경우도 있었다.

표 5. 10 fold cross validation에 의한 Hidden layer가 50개인 ELM와 Fuzzy TWSVM의 학습 및 테스트 분류 성공률 (단위 %)

Table 5. Training and test accuracy of ELM which has 50 hidden layer and Fuzzy TWSVM using 10 fold cross validation (unit %)

	ELM	Fuzzy TWSVM
학습	94.03	92.67
테스트	87.43	87.43

351개의 전리층 레이더 데이터 집합에서 임의로 315개를 뽑아낸 데이터를 학습 과정에 적용한 결과, Fuzzy TWSVM에서는 올바르게 분류되었으나 ELM을 통해서 잘못 분류된 데이터의 수는 15개였으며, ELM을 통해서 올바르게 분류되었으나 Fuzzy TWSVM을 통해서 잘못 분류된 데이터의 수는 17개였다. 각각의 서로 다른 분류 결과를 보여준 데이터 집합들의 fuzzy membership 평균 값은 Fuzzy TWSVM에서 올바르게 분류된 데이터들의 경우 0.70이었으며 잘못 분류된 데이터들의 경우는 0.42였다. 이는 앞서 TWSVM과 비교했을 경우와 마찬가지로 fuzzy TWSVM의 경우, fuzzy membership 즉, 데이터의 중요도가 클수록 올바르게 분류될 확률이 큼을 증명해준다.

### 5. 결론 및 향후 과제

본 논문에서 제시한 Fuzzy Twin Support Vector Machine은 기존의 Twin Support Vector Machine과 동일하게 Support Vector Machine에 비해 약 4배 빠른 학습 속도를 유지하면서 각 학습 데이터마다 Fuzzy Membership을 적용하여 기존의 Twin Support Vector Machine에 비해 높은 학습 데이터의 분류 성공률을 보여주었다.

Fuzzy TWSVM의 경우는 단순히 TWSVM에 비해 분류 성공률이 높다는 장점이 외에도, 개발자가 임의로 결정할 수 있는 데이터들의 중요도 (fuzzy membership) 값에 따라 상대적으로 좋은 분류를 보장해 줄 수 있다는 장점을 또한 가지고 있다.

본 논문에서는 전리층 레이더 데이터를 통해 위의 결론을 증명하였다.

이와 같은 결과를 통해 영상 내에서의 사물 인식과 같은 적용에서도 빠른 학습 속도와 이전 분류기에 비해 좋은 결과를 기대할 수 있다.

### 참고 문헌

- [1] Jayadeva and R. Khemchandani, "Twin Support Vector Machines for Pattern Classification," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 29, No. 5, pp 905-910, May 2007
- [2] Yongqiao Wang, Shouyang Wang and K. K. Lai, "A New Fuzzy Support Vector Machine to Evaluate Credit Risk," *IEEE Transactions on Fuzzy Systems*, Vol. 13, No. 16, pp 820-831, December 2005
- [3] Yi-Hung Liu and Yen-Ting Chen, "Face Recognition Using Total Margin-Based Adaptive Fuzzy Support Vector Machines," *IEEE Transactions on Neural Networks*, Vol. 18, No. 1, pp 178-192, January 2007
- [4] Chun-Fu Lin, and Sheng-De Wang, "Fuzzy Support Vector Machines," *IEEE Transactions on Neural Networks*, Vol. 13, No. 2, pp 464-471, March 2002.
- [5] G.-B. Huang, Q.-Y. Zhu and C.-K. Siew, "Extreme Learning Machine: Theory and Application," *Neurocomputing*, vol. 70, pp.489-501, 2006
- [6] G.-B. Huang, and C.-K. Siew, "Extreme learning machine with randomly assigned RBF kernels," *International Journal of Information Technology*, vol. 11, no. 1, pp.16-24, 2005
- [7] <http://mllearn.ics.uci.edu/MLSummary.html>
- [8] Richard O. Duda, Peter E. Hart and David G. Stork, *Pattern Classification*, Wiley, pp 215-281

### 저자 소개



천민규(Minkyu Cheon)

2006년 : 연세대학교 전자공학과 졸업  
(공학사)

2006년 ~ 현재 : 연세대학교 전기전자공학과  
석사과정

관심분야 : 지능제어, 퍼지이론, 컴퓨터비전

Phone : +82-2-2123-2868

E-mail : 1000minkyu@yonsei.ac.kr



윤창용(Changyong Yoon)

1997년: 연세대학교 전자공학과 졸업  
(공학사)

1999년: 연세대학교 전자공학과 석사 과정  
졸업(공학석사)

1999년~2006년: LG전자/정보통신 UMTS  
연구소 선임연구원

2006년~현재: 연세대학교 전기전자공학과 박사과정

관심분야: 지능제어, 퍼지이론, 컴퓨터비전

Phone : +82-2-2123-2868

E-mail : cyyoon4u@paran.com



김은태(Euntai Kim)

1992년: 연세대학교 전자공학과 졸업  
(공학사, 전체수석)

1994년: 연세대학교 전자공학과 석사 과정  
졸업(공학석사)

1999년: 연세대학교 전자공학과 박사 과정  
졸업(공학박사)

1999년 3월~2002년 2월: 국립한경대학교 제어계측 공학과  
조교수

2002년 3월~현재: 연세대학교 전기전자공학부 부교수

2003년: University of Alberta, visiting researcher

1998년~현재: IEEE TFS, IEEE SMC, IEEE CAS,  
FSS 등에서 심의위원 활동 중

2003년: 대한 전자공학회 해동상 수상

관심분야: Computational intelligence, 지능형 로봇

Phone : +82-2-2123-2863

E-mail : etkim@yonsei.ac.kr



박민용(Mignon Park)

1973년: 연세대학교 전자공학과 졸업  
(공학사)

1977년: 연세대학교 전자공학과 석사 과정  
졸업(공학석사)

1982년: 일본 동경대학교 전자공학과 박사  
과정 졸업(공학박사)

1977년~1982년: 일본 동경대학교 의용전자 연구실

1982년: 미국 MIT & BERKELEY 연구소

1982년~현재: 연세대학교 전기전자공학과 정교수

관심분야: 퍼지제어, 로봇틱스, 의용전자

Phone : +82-2-2123-2868

E-mail : mignonpark@yonsei.ac.kr