

선형분류 경계면을 찾기 위한 Possibilistic 퍼셉트론 알고리즘

A Possibilistic Based Perceptron Algorithm for Finding Linear Decision Boundaries

김미경 · 이정훈

Kim Mi Kyung and Frank Chung-Hoon Rhee

한양대학교 전자컴퓨터공학부

요약

폐턴 인식에서 선형분류가능한 경계면을 찾아 폐턴을 분류하는 방법 중 가장 기본적인 방법은 퍼셉트론이라고 볼 수 있다. 하지만 선형분류불가능한 폐턴에 대해서는 유용한 결과를 보여주지 못하였다. 먼저 제안된 퍼지 퍼셉트론은 베타영역 설정에 의해 수렴하지 못하는 특성을 보완하였다. 그러나 폐턴의 순수한 전형성을 고려해 주지 못하는 단점이 있다. 이에 Crisp의 선형분류 특성과 퍼지의 수렴특성을 합성하고자 Possibilistic 퍼셉트론을 제시한다.

Abstract

The perceptron algorithm, which is one of a class of gradient descent techniques, has been widely used in pattern recognition to determine linear decision boundaries. However, it may not give desirable results when pattern sets are nonlinearly separable. A fuzzy version was developed to make up for the weaknesses in the crisp perceptron algorithm. This was achieved by assigning memberships to the pattern sets. However, still another drawback exists in that the pattern memberships do not consider class typicality of the patterns. Therefore, we propose a possibilistic approach to the crisp perceptron algorithm. This algorithm combines the linearly separable property of the crisp version and the convergence property of the fuzzy version. Several examples are given to show the validity of the method.

Key Words : crisp perceptron, fuzzy perceptron, possibilistic perceptron, typicality, membership

1. 서 론

경계면 결정함수(decision function)에 의해 폐턴을 분류하는 분류자로서, 가장 기본적인 방법은 퍼셉트론이라고 볼 수 있다. 이는 선형분류가능한(lineary separable) 폐턴 데이터들에 대해서는 좋은 결과를 보여 왔지만, 클래스간의 경계가 어매한 클래스들에 대해서는 올바른 경계결정함수를 찾지 못하고, 또한 수렴하지 못하는 문제점을 가지고 있다. 이에 발전된 형태인 퍼지 퍼셉트론의 경우에는 폐턴에 대해서 소속도 함수를 적용하여, 경계결정함수를 보정할 때 그 역할을 조정하게 된다. 이러한 방법은 알고리즘의 수렴과 함께, 일반적인 퍼셉트론의 방법보다는 바람직한 결과를 보일 수 있다. 그러나 퍼지 퍼셉트론의 특성상 폐턴 데이터의 클래스에 대한 전형성을 고려하지 않은 상대적인 거리 개념에 의한 소속도 정도 결정과 베타영역의 설정에 의해 그 결과가 달라지는 단점을 보인다. 또한 일반 선형분류가능한 폐턴 데이터들에 대해서는 일반적인 퍼셉트론보다 수렴결과가 더 좋지 못할 수도 있다. 따라서 본 논문에서는 일반적인 퍼셉트론의 선형분류가능한 데이터에 대한 장점과 퍼지 퍼셉트론의 선형분류불가능한 폐턴에 대한 수렴특성을 합성하고자 Possibilistic 퍼셉트론을 제시한다. 기본적으로 본 논문에 제시된 알고리즘은 PCM (possibilistic C-means)에 사용된 소속도 결정방법을 사용해 전체 폐턴데이터에 대해 해당 클래스의 전형성(typicality)를 고려하도록 하고자한다. 이러한 클래스의 전형성 고려는 선형분류불가능한 데이터들에 대한 경계면 함수 결정에 있어서는 퍼지 퍼셉트론과 유사한 수렴의 특성을 부여하고, 선형분류가능한 폐턴들에 대해서는 일반적인 퍼셉트론 방법에 비해 좀더 바람직한 경계면의 위치를 제시할 수 있다. 본 논문에서는 여러 폐턴 데이터들을 통해 직선과 곡선으로 이루어진 경계면 함수를 결정해, 그 결과를 비교하여, 본 논문에 제시된 알고리즘의 유용성을 보일 것이며, 마지막으로 영상 데이터를 통해, 영상분할의 예제를 제시할 것이다.

2. 본 론

2.1 Crisp 퍼셉트론

폐턴 x_k 가 클래스1 또는 클래스2로 분류되는 한 쌍의 견본 벡터 $\{x_1, \dots, x_R\}$ 를 가지고 있다고 가정하자. 만일 이러한 클래스들 중 서로 다른 두개의 클래스를 분류하는 선형 분류함수 g 가 존재한다면

$$g(x) = W^T x_k \begin{cases} > 0 \text{ if } x_k \in \text{class1} \\ < 0 \text{ if } x_k \in \text{class2} \end{cases} \quad (1)$$

$g(x)=0$ 인 지점은 실수평면 R상에서 클래스1에 속하는 벡터들과 클래스2에 속하는 벡터들의 경계면을 정의한다. 이러한 퍼셉트론 알고리즘은 샘플 벡터들을 두개의 클래스로 나누는 경계결정함수를 정의하기 위해 사용되고 있다.

만일 위와 같이 두개의 클래스를 나눌 수 있는 선형 경계면 함수가 존재한다면, 퍼셉트론 알고리즘은 몇 번의 반복 수행을 거쳐 유용한 경계면을 찾아내게 된다[1]. 그러나 선형분류불가능한 패턴들의 경우에는 이러한 경계면 함수가 존재하지 않아 무한횟수의 반복 연산을 거쳐서도 수렴하지 못하는 문제점이 있다. 이는 퍼셉트론 알고리즘 종료조건을 수정하는 것에 의해 아주 좋은 결과는 아니지만, 선형분류가능한 경우와 선형분류불가능한 경우 모두 비교적 좋은 결과를 얻을 수 있도록 할 수 있다.

퍼지 집합 이론을 퍼셉트론 알고리즘에 포함하는 것은 이러한 문제에 대한 또 다른 방법이다.

Crisp 퍼셉트론 알고리즘의 주된 약점은 두개의 클래스가 선형분류 불가능할 때 하나의 적절한 경계면 함수를 찾아내지 못하고 무한 반복연산을 수행할 수 있다는 것이다. 만약 이러한 무한 반복연산을 방지하기 위해 임의의 지점에서 반복연산을 종료시키면 그 결과 경계면 함수는 해당 패턴에 최후의 경계면 임을 보장할 수 없게 된다.

경계면에서 겹쳐진 패턴들은 퍼셉트론 알고리즘이 수렴하지 못하고 잘못 동작하게되는 주된 원인이 된다. 같은 패턴 벡터들은 자기 클래스가 아닌 상관이 없는 클래스들에 대해 상대적으로 상관이 없어야 하는데 기존의 Crisp 퍼셉트론 알고리즘에서는 이들에 대해서도 완전한 weight(1을 갖는다)를 갖게된다.

2.2 Fuzzy 퍼셉트론

퍼지 퍼셉트론에서는 위에서 설명한 Crisp 퍼셉트론의 단점을 보완하기 위해 소속이 불확실한 패턴 벡터들이 weight 벡터 수정에 적게 영향을 미치게 하도록 퍼셉트론 알고리즘을 수정한다. 이를 위해 weight벡터를 수정하는 과정을 보완한다[2].

Crisp 퍼셉트론에서, 이러한 weight 수정 단계는 $W \leftarrow W + |u_{1k} - u_{2k}|^m c x$,로 한다. Crisp 퍼셉트론의 weight 수정단계에 소속도 함수 값을 적용하기 위해 아래와 같이 수정한다.

$$W \leftarrow W + |u_{1k} - u_{2k}|^m c x \quad (2)$$

x_k 가 모두 그 소속이 애매한 벡터라면 weight를 보정하는 값은 0이 된다. 정의된 조건에 따라 퍼지 소속도를 할당하면[2].

FOR all pattern x_k

IF x_k is class1

$$u_{1k} = 0.5 + \frac{\exp(f(d_2 - d_1)/d) - \exp(-f)}{2(\exp(f) - \exp(-f))}$$

$$u_{2k} = 1 - u_{1k}$$

Else

$$u_{1k} = 1 - u_{2k}$$

$$u_{2k} = 0.5 + \frac{\exp(f(d_1 - d_2)/d) - \exp(-f)}{2(\exp(f) - \exp(-f))}$$

END IF
END FOR

여기서, d_1 (d_2)은 벡터로부터 클래스1(2)의 평균까지의 거리이다. 그리고 d는 두 클래스의 평균값 사이의 거리이다. 상수 f는 소속도값이 0.5를 향해 감소하는 비율을 제어하는데 이 값은 반드시 양수이어야 한다. 위의 소속도 할당 식은 소속도 값이 0.5를 향해 지수 적으로 감소하도록 만들어준다.

퍼지 퍼셉트론에서는 선형분리가 불가능한 패턴데이터에 대해서도 수렴하기 위해 BETA영역을 설정하게 된다[2]. BETA영역은 다음과 같다.

$$\text{BETA} = \frac{1 - e^{-f}}{2(e^f - e^{-f})} + \varepsilon \text{ where } \varepsilon \geq 0. \quad (3)$$

BETA영역이란 소속도가 0.5 근처인 영역(0.5-BETA, 0.5+BETA)을 말하는 것으로 알고리즘이 한번 수행되고 난 후 모든 weight의 보정이 이 영역에서만 이루어 진다면 알고리즘은 종료하게 된다. 이를 위해서는 BETA영역 밖의 영역에서는 선형분리가 가능해야 한다.

하지만 퍼지 퍼셉트론 역시 문제점을 가지고 있다. 퍼지 퍼셉트론에서 소속도를 구하는 식이 프로토타입과 패턴사이의 거리에 의존하므로 패턴의 분포가 원형이 아닌 경우에는 만족스럽지 못한 결과를 얻게된다. 또 BETA영역의 설정으로 최적의 경계면 함수를 찾지 못하더라도 수렴하는 결과를 나타낸다.

이는 각 패턴의 소속도 측정에 있어, 상대적인 클래스 평균과의 거리에 의해 할당받은 소속도 값을 사용하기 때문에 각 패턴의 weight 보정과정에 대한 기여도가 실제 패턴의 클래스에 전형성과는 차이가 있기 때문이다.

2.3 제안한 Possibilistic 퍼셉트론

퍼지 분류는 각 반복연산과정에서 하나의 주어진 클래스에 하나의 패턴벡터가 전적으로 기여할 필요가 없다는 관점에서 전통적인 Crisp방법에 비해 장점이 있는 것으로 알려져 왔다. 하지만 fuzzy는 한 패턴의 각 클래스에 해당되는 소속도의 합이 1이 되게 확률적인 제약을 사용하였다. 이러한 제약에 의해 생성되는 상대적인 수로 소속도값을 할당하기 때문에 패턴의 전형성을 고려할 수 없다.

여기서 제안한 방법은 소속도의 Possibilistic한 해석을 용이하게 하기 위해 소속도의 합(sum)에 대한 제한을 두지 않는 방법이다[3].

기본적인 과정은 fuzzy 퍼셉트론과 동일하지만, weight를 보정할 때 사용하게 되는 소속도값을 할당하는데 있어서 패턴의 전형성을 고려한다는 것이 다르다. 이러한 요구를 만족하는 PCM의 objective function은 다음과 같이 공식화된다.

$$J_m(L, U) = \sum_{i=1}^L \sum_{j=1}^N (u_{ij})^m d_{ij}^2 + \sum_{i=1}^L \eta_i \sum_{j=1}^N (1 - u_{ij})^m \quad (4)$$

여기서 η_i 는 적절한 양수이다. 첫 번째 항은 패턴 벡터에서 클래스 평균까지의 상대적 거리는 가능한 한 가까울 것을 요구한다. 이에 반해 두 번째 항에서는 절대

적 거리가 가까울수록 소속도 u_{ij} 에게 가능한 한 큰 값을 갖도록 강요한다. 이와 같이하여 패턴 데이터의 전형성을 고려할 수 있다.

$$u_{ij} = \frac{1}{1 + \left(\frac{d_{ij}^m}{\eta_i} \right)^{\frac{1}{m-1}}} \quad (5)$$

이와 같이, 새로 정의된 소속도값 u_{ij} 의 업데이트된 값은 각 패턴과 클래스 평균과의 거리에 의존한다. 프로토타입의 적합성의 관점에서, 클래스의 한 점의 소속도는 그 클래스의 평균으로부터 거리에 의해 결정되어야만 하고 다른 클래스들과 겹치지 않아야 한다.

m 값은 퍼지화 정도와 소속도 함수(Possibility distribution)의 모양을 결정한다. $m=1$ 에 가까워질수록 패턴의 퍼지화 정도가 낮아지게 되고, $m=2$ 무한대에 접근할 때 퍼지화 정도가 가장 커진다. 실제 각종 패턴인식 문제에 대해서 $m=2$ 로 설정했을 때 비교적 좋은 결과를 나타낸다.

η_i 의 값은 클래스에서 소속도값이 0.5가되는 점의 거리를 결정한다. 따라서, 각 클래스를 위한 소속도 함수의 바람직한 대역폭에 의존하여 선택되는 것이 필요하다.

$$\eta_i = K \frac{\sum_{j=1}^N u_{ij}^m d_{ij}^2}{\sum_{j=1}^N u_{ij}^m} \quad (6)$$

식 (6)에 사용된 소속도 u_{ij} 는 적절한 퍼지분할에 의해 얻어지게 된다. 이러한 선택은 η_i 가 각 클래스의 평균 퍼지 클래스간 거리에 적절하게 만든다.

Possibilistic 퍼셉트론의 결과는 다른 클래스분류 기법들처럼 초기화에 따라 결과가 크게 달라질 수 있다. 그래서, Possibilistic 퍼셉트론에서도 전체의 최소값으로 수렴되기 위해 합리적인 초기화방법이 요구된다. Possibilistic 퍼셉트론 수행 시 퍼지 분할에 사용된 소속도 값들을 사용하면 η_i 를 측정하는데 훌륭한 초기화 요소들을 공급할 수 있다. 이렇게 새로 얻어진 소속도 값들에 의해 weight 보정값이 패턴의 전형성을 고려한 값으로 바뀌게 되는 것이다.

Possibilistic 퍼셉트론에서, 클래스들은 많은 이동성을 갖지 못한다. 그 이유는 각 데이터들이 단지 하나의 클래스에만 소속되기 때문이다. 이후의 실험에서 제안한 Possibilistic 퍼셉트론 알고리즘의 유용성을 보여주고 있다.

3. 실험결과 및 분석

본 논문에 제시된 방법의 효과를 측정하기 위해, Possibilistic과 퍼지, 그리고 Crisp 퍼셉트론을 여러 종류의 패턴 데이터에 대해 수행하고, 그 결과를 비교한다. 패턴집합은 Iris, Twoclass, Ellipse 데이터들에 대해 각각의 퍼셉트론을 수행하였다. 퍼셉트론의 특성상 클래스가 2개인 문제를 고려하게 된다. Iris 데이터는 클래스가 3개인 데이터이므로 비교적 선형분류가 불가능한 클래스 2,3만을 사용하여 실험하였다.

Crisp과 Possibilistic 퍼셉트론은 수렴하지 않으므로 종료조건을 weight의 변화가 없을 때가 아닌 최대 반복

횟수를 정해 놓고 그 중에서 에러가 가장 적을 때의 weight를 찾아 1 pattern Jack-knife를 수행하여 confusion matrix를 비교하였다.

각 표에서는, 퍼지화 상수(fuzzifier) f 의 값은 3.0으로, m 은 2.0으로, learning rate c 는 0.5, BETA 영역 설정에 관련된 상수 ϵ 는 0.02로 각각 설정되었다.

표 1. Twoclass 데이터의 confusion matrix 비교

Two class	Crisp		Fuzzy		Possibilistic	
	class1	class2	class1	class2	class1	class2
class1	86	35	114	7	96	25
class2	0	121	20	101	3	118

표 2. Iris 데이터의 confusion matrix 비교

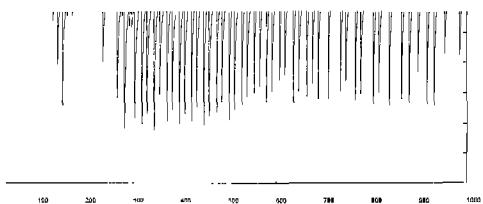
Iris	Crisp		Fuzzy		Possibilistic	
	class1	class2	class1	class2	class1	class2
class1	43	7	49	1	46	4
class2	2	48	5	45	0	50

위의 실험 결과를 보면 crisp에 비해 fuzzy와 Possibilistic이 더 나은 결과를 나타내는 것을 볼 수 있다. 하지만 패턴 데이터의 클래스 모양이 선형으로 구분이 불가능한 경우의 비교는 다른 결과를 보여준다. 아래 결과는 ellipse 데이터의 confusion matrix이다.

표 3. ellipse 데이터의 confusion matrix 비교

Ellipse	Crisp		Fuzzy		Possibilistic	
	class1	class2	class1	class2	class1	class2
class1	37	13	31	19	44	6
class2	1	49	27	23	1	49

퍼지의 경우는 약 50%밖에 인식하지 못하는 결과를 나타내었다. 이는 평균까지의 거리함수에 기초한 소속도 할당으로 인해 패턴의 분포가 원형이 아닌 패턴 클래스에 대해서는 올바른 구분을 할 수 없음을 나타낸다.



(a) Crisp



(b) Fuzzy

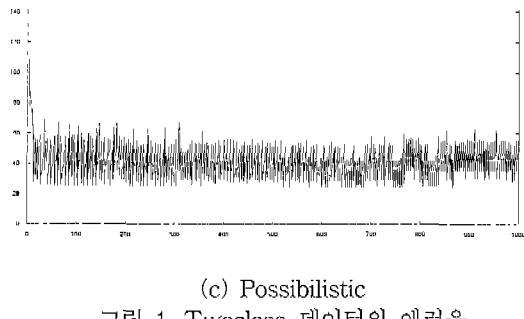


그림 1. Twoclass 데이터의 어려움

위의 그림은 Twoclass 데이터에서 각 퍼셉트론의 어려움(잘못 분류된 패턴 수)을 그래프로 나타낸 것이다. 최대 반복 횟수 후의 Possibilistic 퍼셉트론은 퍼지 퍼셉트론의 경우처럼 하나의 경계면 함수를 완벽히 찾지는 못한다. 그러나 충분한 반복연산후의 weight의 보정범위는 충분히 매우 작기 때문에 crisp에 비해서는 좋은 성능을 보이게 된다. 또한 퍼지 퍼셉트론은 BETA영역의 설정으로 경계면이 최적화되지 못하더라도 수렴하는 결과를 볼 수 있다. 이에 반해 Possibilistic 퍼셉트론은 완벽하게 수렴하지는 않았지만 결과 경계면이 더 좋은 성능을 보였다.

이러한 패턴 분류자들을 좀더 일반적인 실험을 위해 숲과 길의 두 부분으로 분류가 가능한 자연영상에 대해 영상분할실험에 적용해 보았다. median filter, excess green, homogeneity, entropy의 특징 영상을 이용하여 각 클래스 별로 100개의 패턴을 추출하여 weight 함수를 찾아 영상 데이터를 분할하였다. 아래그림은 영상 분할의 결과이다.

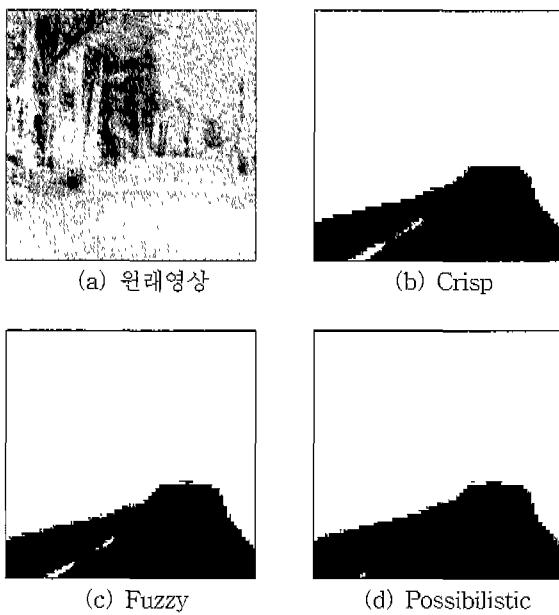


그림 2. 영상 분할의 예

원래 영상을 보면 길과 숲 이렇게 2개로 분할 가능한 이미지이다. 이를 분할 알고리즘에 적용하면 그림2와 같은 결과를 얻을 수 있다. 3개의 퍼셉트론 모두가 어느 정도 숲의 영상을 깨끗하게 찾아내었다. 하지만 길 영상 분할 결과를 자세히 보면 crisp과 퍼지에서는 길의 중앙

선부분이 숲 영상으로 분할된 것을 알 수 있다. 이에 반해 Possibilistic 퍼셉트론은 중앙선부분도 더욱더 확실한 길로 인식되는 결과를 볼 수 있다.

4. 결 론

퍼지 퍼셉트론은 선형분류불가능한 경우에 적절한 경계면을 찾지 못하는 Crisp 퍼셉트론의 주된 문제점을 해결하는 방법으로서 제시되었다. 퍼지 기술들은 경계면 결정에 큰 역할을 하지 못하는 패턴들을 찾아내고 이를 경계면 계산에서 다른 패턴들보다 작은 wweight를 부여하게 된다. 하지만 퍼지 퍼셉트론에서의 소속도는 클래스 평균과의 상대적인 거리에 의한 값이다. 따라서 실제 패턴의 클래스에 따른 전형성이 고려된 값이라 볼 수 없다.

본 논문에서는 Possibilistic의 기술을 사용하여 소속도 할당단계에서부터 해당클래스에 대한 샘플 벡터의 전형성에 직접 의존해 해당 벡터의 wweight보정단계에 직접 영향을 미치도록 하였다. 퍼지 퍼셉트론은 평균까지의 거리함수에 기초한 소속도 할당으로 인해 패턴데이터의 분포가 원형이 아닌 데이터에 대해서는 만족스럽지 않은 결과를 나타내었다.

수렴이라는 측면에서 보면 퍼지 퍼셉트론이 가장 우수하지만 데이터의 클래스가 섞여 있는 경우 crisp과 퍼지에 비해 Possibilistic 퍼셉트론이 우수하다는 것을 알 수 있었다. 이는 잡음(noise)패턴이 첨가된 데이터에서 더 유용할 것으로 생각된다.

그러므로, Possibilistic 퍼셉트론은 두개의 클래스가 서로 선형분류가능한 여부에 상관없이 두개의 클래스 사이에 바람직한 경계면을 생산하는 신뢰성 있는 방법이다.

본 논문에 제시된 방법은 퍼셉트론의 특성에 따라 클래스가 2개인 블래스 분할문제에 적합하다. 따라서 본 논문에서는 클래스가 2개인 패턴데이터에 대한 결과만을 보였다. 그러나, 다수의 클래스가 존재하는 복잡한 패턴데이터에 대해서도 신뢰성 있는 결과를 얻기 위해서는 향후 신경망으로의 확장이 고려된다. 다수의 뉴런이 존재하는 신경망 블래스 분류자로 확장될 경우, 각종 영상 분할 문제에 있어서도 다수의 객체를 신뢰성 있게 분류 해낼 수 있을 것으로 고려된다.

참 고 문 헌

- [1] J. Tou and R. Gonzalez, *Pattern Recognition Principles*. Reading. MA: Addison-Wesley, 1974.
- [2] J. Keller and D. Hunt, "Incorporating fuzzy membership functions into the perceptron algorithm," *IEEE Trans. PAMI*, vol. 7, no. 6, pp. 693-699, 1985.
- [3] R. Krishnapuram and J. Keller, "A possibilistic approach to clustering," *IEEE Trans. Fuzzy Systems*, vol. 1, no. 2, pp. 98-110, 1993.
- [4] J. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*. New York: Plenum, 1981.

저자 소개



김미경(Kim Mi Kyung)

1995~1999년 : 순천향대학교 전자공학과 학사
2000년~현재 : 한양대학교 전자 전기제어계측
공학과 석사과정

관심분야 : 패턴인식, 퍼지이론, 컴퓨터비전,
신경회로망

E-mail : mkgduck@fuzzy.hanyang.ac.kr



이정훈(Frank Chung-Hoon Rhee)

1981~1985년 : University of Southern California(USC), Dept. Electrical Eng., BSEE

1985~1987년 : University of Missouri, Dept. of Electrical & Computer Eng., MSEE

1990~1993년 : University of Missouri, Dept. of Electrical & Computer Eng., Ph.D.

1994~1995년 8월 : 한국 전자통신연구원

1995년 9월 ~ 현재 : 한양대학교 전자컴퓨터공학부 조교수

관심분야 : Computer Vision, Pattern Recognition, and all aspects of Computational Intelligence.

E-mail : frhee@fuzzy.hanyang.ac.kr