

영상 분할을 위한 퍼지 커널 K -nearest neighbor 알고리즘

Fuzzy Kernel K -Nearest Neighbor Algorithm for Image Segmentation

최병인 · 이정훈

Byung-In Choi and Frank Chung-Hoon Rhee

한양대학교 전자전기제어계측공학과

요약

커널 기법은 데이터를 high dimension 상의 속성 공간으로 mapping함으로써 복잡한 분포를 가지는 데이터에 대하여 기존의 선형 분류 알고리즘들의 성능을 향상시킬 수 있다[4]. 본 논문에서는 기존의 유클리디안 거리측정방법 대신에 커널 함수에 의한 속성 공간의 거리측정방법을 fuzzy K -nearest neighbor(fuzzy K -NN) 알고리즘에 적용한 fuzzy kernel K -nearest neighbor(fuzzy kernel K -NN) 알고리즘을 제안한다. 제시한 알고리즘은 데이터에 대한 적절한 커널 함수의 선택으로 기존 알고리즘의 성능을 향상 시킬 수 있다. 제시한 알고리즘의 타당성을 보이기 위하여 여러 데이터 집합에 대한 실험결과와 실제 영상의 분할 결과를 보일 것이다.

Abstract

Kernel methods have shown to improve the performance of conventional linear classification algorithms for complex distributed data sets, as mapping the data in input space into a higher dimensional feature space[7]. In this paper, we propose a fuzzy kernel K -nearest neighbor(fuzzy kernel K -NN) algorithm, which applies the distance measure in feature space based on kernel functions to the fuzzy K -nearest neighbor(fuzzy K -NN) algorithm. In doing so, the proposed algorithm can enhance the performance of the conventional algorithm, by choosing an appropriate kernel function. Results on several data sets and segmentation results for real images are given to show the validity of our proposed algorithm

Key Words : fuzzy K -nearest neighbor, kernel function, nonlinear classification, kernel method

1. 서 론

기존의 K -nearest neighbor(K -NN)은 입력 패턴으로부터 K 개의 가장 가까운 sample 패턴들의 주된 클래스로 패턴을 분류하는 간단하고, nonparametric한 알고리즘이다[1]. 반면에, K -NN은 각 sample 패턴들이 입력 패턴들의 클래스 label을 결정하는데 같은 기여도를 가지는 문제점이 있다. 이는 다른 클래스의 패턴들이 겹쳐있는 데이터에 대하여 오분류를 야기할 수 있다. 이를 개선하기 위하여 fuzzy set 이론을 K -NN rule에 적용시킨 fuzzy K -nearest neighbor(fuzzy K -NN) 알고리즘이 제안되었다[2]. fuzzy K -NN은 입력 패턴에 가까운 K 개의 sample 패턴들과 입력패턴 사이의 거리의 역수와 선택된 sample 패턴들의 기여도인 membership 값에 따라 각 클래스에 대한 입력 패턴의 fuzzy membership 값을 할당한다. 따라서 서로 겹친 부분에서 K -NN 보다 향상된 분류 결과를 얻을 수 있다.

반면에, 기존의 K -NN 또는 fuzzy K -NN은 유클리디안 공간상의 패턴 간 거리 측정 방법을 사용한다. 이러한 거리

측정 방법을 대신하여 커널 함수에 의한 높은 차원의 속성 공간상의 거리 측정 방법을 사용한 kernel K -nearest neighbor (Kernel K -NN) 알고리즘이 제안되었다[3]. 제안된 알고리즘에서는 속성 공간상의 내적인 커널 함수를 사용함으로써 큰 계산량을 요하는 속성 공간으로의 변환 없이 속성 공간상에서의 거리를 측정할 수 있다. 그러므로 제안된 알고리즘은 복잡한 분포를 가지는 데이터에 대하여 향상된 분류 성능을 가질 수 있었다.

본 논문에서는 이러한 커널 함수에 의한 거리 측정 방법을 기존의 fuzzy K -NN에 적용한 fuzzy kernel K -nearest neighbor(fuzzy kernel K -NN) 알고리즘을 제안한다. 제안한 알고리즘은 커널 함수를 통한 거리 측정 방법을 입력 패턴의 fuzzy membership 값을 구할 때 사용하게 된다. 그러므로 arbitrary한 분포를 갖는 데이터들에 대하여 fuzzy K -NN 보다 향상된 classification 성능을 얻을 수 있다.

본 논문의 나머지 부분은 다음과 같이 구성된다. 2절에서는 커널 함수에 대하여 간략히 언급하고, 3절에서는 기존의 fuzzy K -NN 알고리즘에 대하여 설명한다. 4절에서는 제안한 fuzzy kernel K -NN 알고리즘에 대하여 간략히 설명한다. 다음으로 제안한 알고리즘의 타당성을 보이기 위하여 여러 데이터들과 실제 영상의 분할에 대한 결과를 fuzzy K -NN과 비교하고 마지막으로 결론을 맺을 것이다.

접수일자 : 2005년 10월 21일

완료일자 : 2005년 12월 5일

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

2. 커널 함수

커널 함수의 적용은 입력 데이터들을 높은 차원의 속성 공간으로 변환하여 처리를 하는 것이다[5][6][7]. 이러한 변환은 그림 1에서 볼 수 있듯이 입력 데이터 공간에서 분류가 어려운 데이터들을 속성 공간상으로 변환하여 분류가 용이하게 만든다. n 차원 데이터 공간상의 패턴 x 가 N 차원 속성 공간으로 feature mapping할 경우를 가정하면 다음과 같다.

$$\mathbf{x} = (x_1, L, x_n) \rightarrow \phi(\mathbf{x}) = (\phi_1(\mathbf{x}), L, \phi_N(\mathbf{x})) \quad (1)$$

여기서, $\phi(\cdot)$ 는 비선형적으로 데이터 공간의 패턴을 높은 차원의 속성 공간으로 변환시켜주는 변환 함수이다. 커널 함수는 다음과 같이 비선형 변환 함수에 의한 속성 공간상에서의 내적으로 정의된다.

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (2)$$

그러므로 커널 함수에 의하여 큰 계산량이 요구되는 속성 공간상으로의 변환 없이 내적을 구할 수 있다.

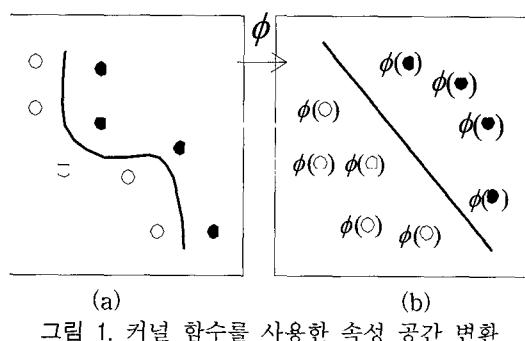


그림 1. 커널 함수를 사용한 속성 공간 변환
(a) 입력 공간 (b) 변환된 속성 공간

Fig 1. Feature space transformation using a kernel function (a) input space (b) transformed feature space

다음의 세 가지의 커널 함수가 일반적으로 사용된다.

(1) Polynomial kernel

$$K(x_i, x_j) = (1 + x_i \cdot x_j)^p \quad (3)$$

(2) Gaussian kernel

$$K(x_i, x_j) = \exp \left\{ -\frac{\|x_i - x_j\|^2}{2\sigma^2} \right\} \quad (4)$$

(3) Sigmoid kernel

$$K(x_i, x_j) = \tanh(\alpha(x_i \cdot x_j) + \beta) \quad (5)$$

여기서 p, α, β, σ 는 커널 함수의 파라미터들이다.

3. Fuzzy K-nearest neighbor algorithm

K -nearest neighbor(K -NN) 알고리즘의 문제점은 입력 패턴의 클래스를 결정하는 데 K 개의 가장 가까운 sample 패턴들의 기여도가 같은 값을 가진다는 것이다. 이러한 문제점을 개선하기 위하여 fuzzy K -nearest neighbor(fuzzy K -NN)

알고리즘은 입력 패턴으로부터 가장 가까운 K 개의 sample 패턴들의 유clidean 거리와 입력 패턴의 fuzzy membership을 할당하는데 얼마나 기여하는지를 나타내는 membership 값을 사용하여 입력 패턴의 fuzzy membership 값을 할당한다. 입력 패턴 x 에 대한 fuzzy membership 값은 다음과 같다.

$$u_i(\mathbf{x}) = \frac{\sum_{j=1}^K u_{ij} \left(1 / \| \mathbf{x} - \mathbf{x}_j \|^2 / (m-1) \right)}{\sum_{j=1}^K \left(1 / \| \mathbf{x} - \mathbf{x}_j \|^2 / (m-1) \right)} \quad (6)$$

여기서 i 는 클래스 label을 나타내고, j 는 입력 패턴과 가장 가까운 K 개의 sample pattern의 index를 나타낸다. 또한 m 은 퍼지화를 나타내는 변수이다. u_{ij} 는 입력 패턴과 K 개의 선택된 sample 패턴들 중 j 번째 패턴이 입력 패턴의 클래스 label을 i 로 선택할 때 얼마나 기여하는지에 대한 fuzzy membership을 나타낸다. 식(6)에서 볼 수 있듯이 fuzzy membership은 입력 패턴과 sample 패턴의 거리의 역수에 좌우 된다. 그러므로 패턴들 간의 거리가 가까우면 가까울수록 fuzzy membership에 더욱 크게 기여할 것이다. Labeled된 sample 패턴 x 의 초기 fuzzy membership 값인 u_{ij} 는 [2]에서 다음과 같이 제시하였다.

$$u_{ij}(\mathbf{x}) = \begin{cases} 0.51 + (n_j / K) \cdot 0.49, & \text{if } j = i \\ (n_j / K) \cdot 0.49, & \text{if } j \neq i \end{cases} \quad (7)$$

여기서 i 는 해당 sample 패턴의 클래스 label을 나타내고, j 는 클래스 label을 나타낸다. n_j 는 해당 sample 패턴과 가장 가까운 K 개의 sample 패턴들 중에서 j 번째 클래스에 소속되어 있는 패턴들의 개수를 나타낸다. Fuzzy K -NN 알고리즘을 요약하면 다음과 같다[2].

Let $W=\{\mathbf{x}_1, \dots, \mathbf{x}_n\}$ be a set of n labeled patterns

BEGIN

 Input \mathbf{x} , of unknown classification

 Set K , $1 \leq K \leq n$

 Initialize $i = 1$

 DO UNTIL(K -nearest neighbors to \mathbf{x} found)

 Compute distance from \mathbf{x} to \mathbf{x}_i

 IF ($i \leq K$) THEN

 Include \mathbf{x}_i in the set of K -nearest neighbors

 END IF

 END DO UNTIL

 Initialize $i = 1$

 DO UNTIL (\mathbf{x} assigned membership in all classes)

 Compute $u_i(\mathbf{x})$ using (6)

 Increment i

 END DO UNTIL

END

4. Fuzzy Kernel K -nearest neighbor algorithm

본 논문에서 제안하는 fuzzy kernel K -nearest neighbor 알고리즘의 주된 목적은 높은 차원의 속성 공간상에서 거리 측정을 통하여 fuzzy K -nearest neighbor 알고리즘의 수행

성능을 향상시키는 것이다. 그러므로 먼저 속성 공간에서 데이터간 거리 측정 방법을 설명한다.

입력 패턴 x_i, x_j 의 속성 공간상의 거리는 다음과 같이 나타난다.

$$\begin{aligned} d_\phi(x_i, x_j) &= \|\phi(x_i) - \phi(x_j)\|^2 \\ &= \phi(x_i)\phi(x_i) - 2\phi(x_i)\phi(x_j) + \phi(x_j)\phi(x_j) \end{aligned} \quad (8)$$

식(2)의 커널 함수의 정의로부터 식(8)의 속성 공간상의 내적은 다음과 같이 커널 함수로 대치될 수 있다.

$$d_\phi(x_i, x_j) = K(x_i, x_i) - 2K(x_i, x_j) + K(x_j, x_j) \quad (9)$$

식(9)에서 볼 수 있듯이 커널 함수의 적용으로 속성 공간상으로의 패턴들의 변환과정 없이도 속성 공간상의 패턴들 간 거리를 구할 수 있다.

제안한 알고리즘은 식(9)에서 정의한 커널 함수를 사용한 속성 공간상의 거리 측정 방법을 기준의 fuzzy K-NN 알고리즘에 적용한다. 입력 패턴 x 에 대한 fuzzy membership 값은 다음과 같이 나타난다.

$$u_i(x) = \frac{\sum_{j=1}^K u_{ij} (1/d_\phi(x, x_j)^{2/(m-1)})}{\sum_{j=1}^K 1/d_\phi(x, x_j)^{2/(m-1)}} \quad (10)$$

u_{ij} 는 해당 sample 패턴과 가장 가까운 K 개의 sample 패턴의 선택을 위한 거리 측정 방법을 본 논문에서 제시한 커널 거리 측정 방법을 사용하여 식(7)에서 구할 수 있다. 알고리즘의 전체 구조는 fuzzy K-NN 알고리즘과 같고, 식(10)을 사용하여 입력 패턴의 fuzzy membership 값을 할당하게 된다.

5. 실험 결과 및 분석

제안한 알고리즘의 타당성을 보이기 위하여 “T-shape”, “Two class”, “Pima-Indian”的 3개의 데이터와 실제 영상의 분할에 대하여 제안된 알고리즘과 fuzzy K-NN 알고리즘을 수행하고, 그 결과를 비교 분석한다.

먼저 Labeled sample 패턴들의 초기 fuzzy membership 값을 구하기 위하여 초기 $K=\{1, 3, 5, 7, 9\}$ 를 사용하였다. 또한 각 입력 패턴의 fuzzy kernel K-NN을 수행하기 위하여 $K=\{1, 2, 3, 4, 5, 6, 7, 8, 9\}$ 를 사용하였다. 즉, 각 K 에 대하여 5개의 초기 K 를 적용하여 5번의 실험을 하였다. 5번의 실험에 의해 나타난 인식률을 평균하여 각 K 값의 결과로서 나타낸다.

각 실험은 데이터 집합의 모든 패턴에 대하여 하나의 패턴을 제외한 나머지 패턴들을 Labeled sample 패턴 집합으로 설정하고, 설정된 패턴 집합을 사용하여 제외된 패턴을 분류하게 된다.

모든 실험에서 fuzzifier, m 은 2.0으로 설정하고, 커널 함수는 polynomial kernel, $K(x_i, x_j) = (1+x_i \cdot x_j)^p$ 로 선택하였다. 또한 polynomial kernel의 파라미터 p 는 0.1에서 10까지 0.1씩 변화하면서 선택하여 제안한 알고리즘을 수행하고, 수행 결과 중 가장 높은 인식률을 해당 실험에 대한 제안한 알고리즘의 결과로 취하게 된다.

각 데이터들의 속성들은 서로 다른 값의 범위를 가지므로 알고리즘을 수행하기 전에 데이터의 속성 값들을 0과 1사이

로 normalization 한다.

5.1 “T-shape” 데이터

“T-shape” 데이터는 447개의 패턴들로 이루어져 있고, 2개의 속성 값을 가지며 2개의 클래스를 가지며, 각 클래스는 228개와 219개로 구성되어 있다.

데이터의 분포는 다음과 같다.

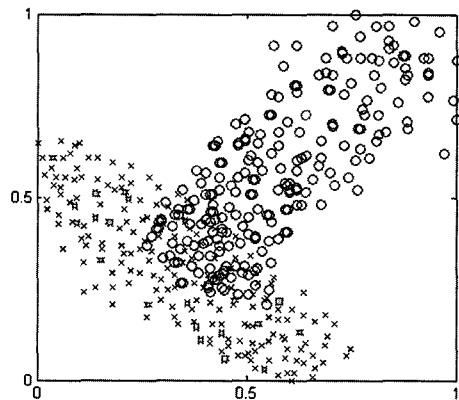


그림 2.“T-shape” 데이터의 scatter plot
Fig. 2. Scatter plot of the “T-shape” data

그림 3은 “T-shape” 데이터에 대한 제안된 알고리즘과 fuzzy K-NN의 결과를 나타낸다. 그림에서 볼 수 있듯이 주어진 데이터 분포에 대하여 제안한 알고리즘이 fuzzy K-NN 보다 향상된 수행 결과를 나타낸다. 전체 평균 분류 결과는 제안된 알고리즘이 88.4%이고, fuzzy K-NN이 88%를 나타내었다. 그러므로 제안한 알고리즘이 약 0.4%의 성능 향상을 얻을 수 있었다.

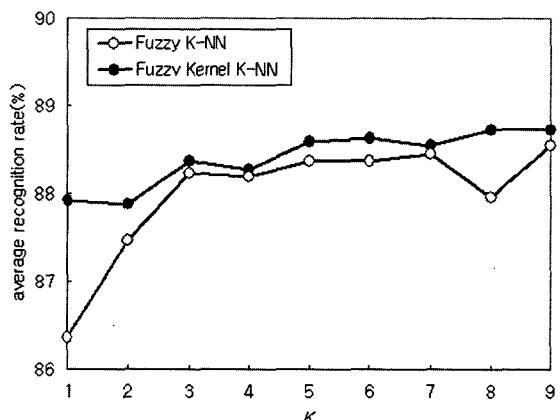


그림 3.“T-shape” 데이터의 평균 인식률
Fig. 3. Average recognition rate for “T-shape” data

5.2 “Two class” 데이터

“Two class” 데이터는 패턴이 242개이고 4개의 속성 값을 가지며 2개의 클래스를 갖는 데이터 집합이다. 각 클래스는 121개의 패턴으로 구성되어 있다. 그림 3은 데이터의 속성 1과 2, 속성 3과 4를 사용하여 scatter plot으로 데이터의 분포를 나타낸다.

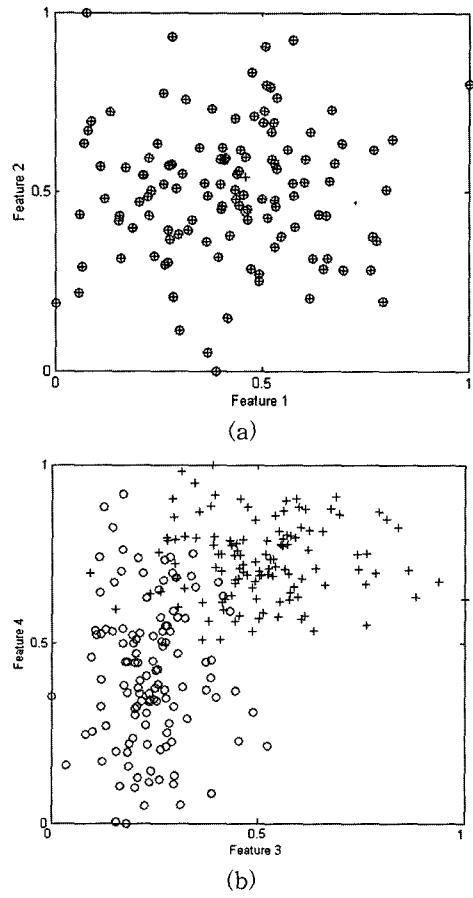


그림 4. “Two class” 데이터의 scatter plot (a) 속성 1과 2
(b) 속성 3과 4

Fig 4. Scatter plot of “Two class” data using (a) feature 1 and 2 (b) feature 2 and 3

제안된 알고리즘과 fuzzy K-NN 알고리즘의 결과는 다음과 같다.

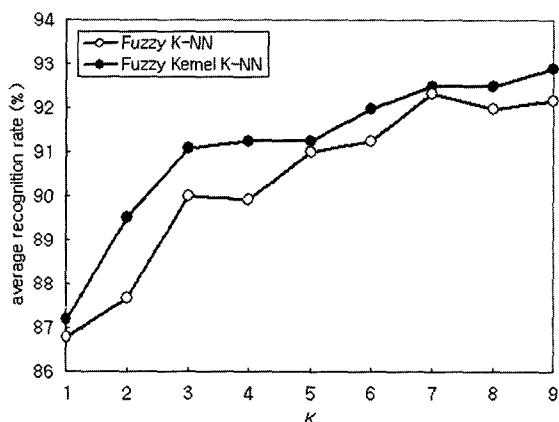


그림 5. “Two class” 데이터의 평균 인식률
Fig 5. Average recognition rate for “Two class” data

그림 5에서 볼 수 있듯이 모든 K 에 대하여 제안한 fuzzy kernel K-NN이 fuzzy K-NN보다 높은 평균 인식률을 나타낸다. 전체 평균 분류 결과는 fuzzy kernel K-NN이 91.2%를 나타내고, fuzzy K-NN이 90.3%를 나타내었다. 그러므로

적절한 커널 파라미터 선택으로 약 0.9%의 인식률의 향상을 얻을 수 있었다.

5.3 “Pima-Indian” 데이터

“Pima-Indian” 데이터는 768개의 패턴으로 이루어져 있고, 8개의 속성 값을 가지며 2개의 클래스로 구성되어 있다. 각 클래스는 500개와 268개의 패턴으로 구성되어 있다. 그림 6은 제안한 알고리즘과 fuzzy K-NN의 결과를 나타낸다.

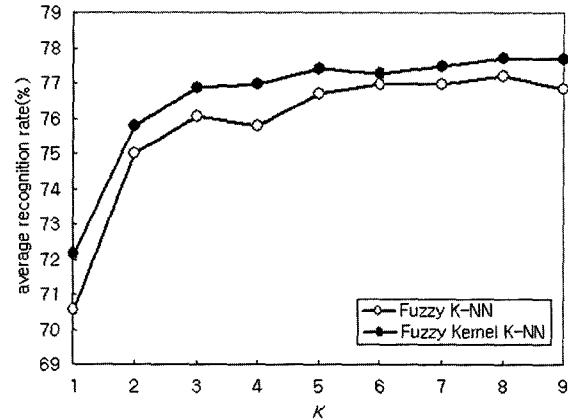


그림 6. “Pima-Indian” 데이터의 평균 인식률
Fig 6. Average recognition rate for “Pima-Indian” data

그림에서 볼 수 있듯이 제안한 알고리즘의 인식률이 fuzzy K-NN보다 높은 것을 볼 수 있다. 또한 전체 평균 분류 결과는 fuzzy kernel K-NN이 76.6%를 나타내고, fuzzy K-NN이 75.8%를 나타내었다. 약 0.8%의 성능 향상을 얻을 수 있었다.

여러 데이터의 실험 결과를 통하여 적절한 커널 함수의 선택과 커널 파라미터의 선택으로 기존의 fuzzy K-NN보다 상당한 성능의 향상을 얻을 수 있었다. 이러한 성능 향상은 커널 함수에 의하여 데이터의 분류에 좀 더 적당한 속성 공간으로의 변환에 기인한다고 볼 수 있다. 다음은 실제 영상에 대한 각 알고리즘의 영역 분할 결과를 살펴본다.

5.4 실제 영상의 분할

길, 숲, 2개의 영역을 가지는 200×200 사이즈의 영상에 대하여 각 알고리즘의 영상 분할 결과를 분석한다. 속성은 원 영상의 median filter와 intensity에 의한 결과 영상 값을 사용한다. 먼저 각 영역에서 100개씩의 200개의 sample 데이터를 추출하여 제안된 알고리즘과 fuzzy K-NN 알고리즘의 분류 결과를 살펴본다. 다음으로, 임의의 K 를 선택하고, 주어진 sample 데이터를 Labeled sample 패턴 데이터로 사용하여 전체 영상을 2 영역으로 분할한다. 그림 7은 추출된 데이터의 분포를 나타낸다. 그림 8은 추출된 데이터에 대한 각 알고리즘의 인식률을 나타낸다. 전체 평균 분류 결과는 fuzzy kernel K-NN이 98.1%를 나타내고, fuzzy K-NN이 98.4%를 나타내었다. 그러므로 약 0.3%의 성능 향상을 얻을 수 있었다.

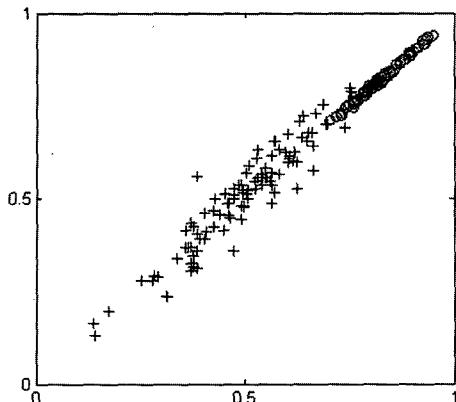


그림 7. 영상의 sample 데이터의 scatter plot
Fig. 7. scatter plot of the sampled image data

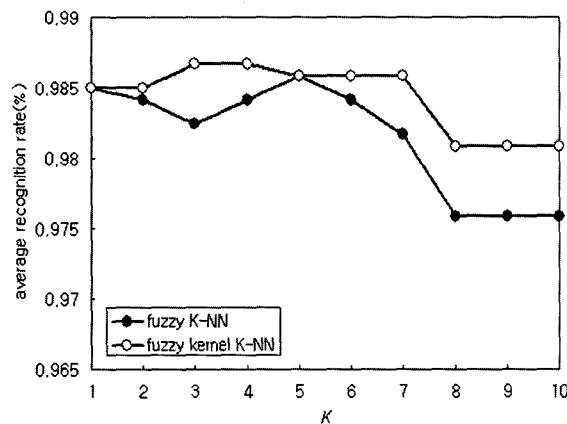


그림 8. 영상의 sample 데이터의 평균 인식률
Fig. 8. Average recognition rate for the sampled image data

위에서 추출한 sample 데이터를 사용하여 전체 영상의 영역 분할을 수행한다. Labeled sample 패턴 데이터의 초기 fuzzy membership에 대한 초기 K 는 1로 설정하고, 입력 패턴의 fuzzy membership을 위한 K 는 8로 설정하였다. 또한 커널 함수의 파라미터 p 는 0.1로 설정하였다. 그림 9(a)는 원 영상을 나타내고, 그림 9(b)와 9(c)는 각각 원 영상에 대한 fuzzy K-NN 알고리즘과 제안한 fuzzy kernel K-NN의 결과를 나타내고 있다. 그림에서 볼 수 있듯이 제안된 알고리즘은 숲 부분에서 fuzzy K-NN 보다 잘 못 분류된 픽셀들이 약간 더 적음을 알 수 있다.

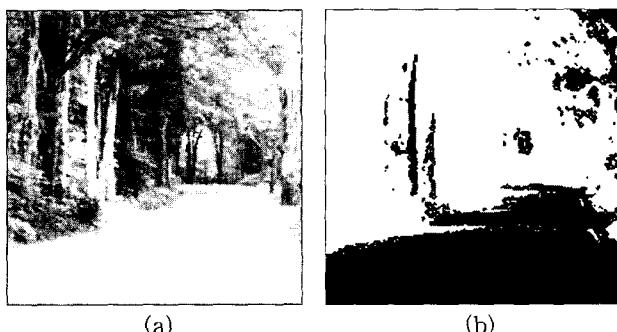


그림 9. 영상의 영역 분할 결과 (a) 원 영상 (b) fuzzy K-NN (b) fuzzy kernel K-NN
Fig. 9. Segmentation results for the image (a) Original Image (b) fuzzy K-NN (c) fuzzy kernel K-NN

표 1은 영상 분할 결과를 confusion matrix로 나타내었다. 표에서 볼 수 있듯이 fuzzy K-NN 알고리즘의 인식률이 90.8%이고 제안한 알고리즘의 인식률은 91.1%임을 알 수 있다. 그러므로 약 0.3%의 인식률의 향상을 얻을 수 있었다.

표 1. 실제 영상 분할 결과에 대한 confusion matrix
Table 1. Confusion matrix for segmentation results

Real Image	Fuzzy K-NN		Fuzzy kernel K-NN	
	Road	Tree	Road	Tree
Road	11060	3202	11069	3110
Tree	467	25271	458	25363

6. 결 론

본 논문에서는 기존의 fuzzy K-NN에 커널함수에 의한 거리 측정 방법을 적용시킨 fuzzy kernel K-NN 알고리즘을 제안하였다. 제안한 알고리즘은 커널 함수를 통하여 유클리디안 공간이 아닌 패턴의 분류에 적합한 속성 공간에서의 패턴 간 거리를 측정할 수 있었다. 또한 커널 함수의 적용으로 큰 계산량을 요구하는 데이터의 변환 없이 속성 공간상의 거리를 측정 할 수 있었다. 그러므로 데이터의 적절한 속성 공간으로의 변환함으로써 기존 알고리즘의 성능을 상당히 향상시킬 수 있었다. 또한 여러 데이터와 실제 영상의 영상 분할 결과로부터 적절한 커널 함수와 커널 파라미터의 선택으로 기존의 fuzzy K-NN 알고리즘의 인식률을 상당히 향상시킬 수 있다는 것을 알 수 있었다. 반면에, 적절한 커널 함수와 최적의 커널 함수의 파라미터를 자동적으로 선택할 수 있는 선택 기법의 제시가 향후 과제로 남아있다.

참 고 문 헌

- [1] J. Tou and R. Gonzalez, *Pattern Recognition Principles*, Addison-Wesley, 1974.
- [2] J. Keller, M. Gray, and J. Givens, JR, "A fuzzy K-nearest neighbor algorithm," *IEEE Trans. Syst., Man, Cybern.*, vol. 15, no. 4, pp. 258-263, August 1985.

- [3] K. Yu, L. Ji, and X. Zhang, "Kernel nearest-neighbor algorithm," *Neural Processing Letters*, vol. 15, no. 2, pp.147-156, 2002.
- [4] J. H. Chen and C. S. Chen, "Fuzzy kernel perceptron," *IEEE Trans. Neural Networks*, vol. 13, no. 6, pp. 1364-1373, 2002.
- [5] N. Cristianini and J. Shawe-Taylor, *An Introduction to Support Vector Machines*, Cambridge University Press, 2000.
- [6] V. Vapnik, *Statistical Learning Theory*, John Wiley & Sons, 1998.
- [7] B. Schölkopf, C. Burges, and A. Smola, *Advances in Kernel Methods*, MIT Press, 1998.



이정훈(Frank Chung-Hoon Rhee)

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

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

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

1994년~1995년 : 한국전자통신연구소 선임연구원

1995년~현재 : 한양대학교 전자컴퓨터공학부 부교수

2002년~현재 : 제어자동화시스템공학회 편집위원

2003년~현재 : 세계 퍼지 학회(IFSA) 한국 지부 대표

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

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

저자 소개



최병인(Byung-In Choi)

2001년 : 한양대학교 전자공학과 졸업

2001년~2003년 : 동 대학원 전자전기제어
계측공학과 석사

2003년~현재 : 동 대학원 전자전기제어계
측공학과 박사과정

관심분야 : Fuzzy Systems, Pattern Recognition, Support
Vector Machines.

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