

# 출력 코딩 기반 다중 클래스 서포트 벡터 머신을 위한 특징 선택 기법

이영주<sup>†</sup>, 이정진<sup>††</sup>

## 요 약

서포트 벡터 머신은 뛰어난 일반화 성능에 힘입어 다양한 분야에서 의사 결정 나무나 인공 신경망에 비해 더 좋은 분류 성능을 보이고 있기 때문에 최근 널리 사용되고 있다. 서포트 벡터 머신은 기본적으로 이진 분류 문제를 위하여 설계되었기 때문에 서포트 벡터 머신을 다중 클래스 문제에 적용하기 위한 방법으로 다중 이진 분류기의 출력 결과를 이용하는 출력 코딩 방법이 주로 사용되고 있다. 그러나 출력 코딩 기반 서포트 벡터 머신에 사용된 기존 특징 선택 기법은 각 분류기의 정확도 향상을 위한 특징이 아니라 전체 분류 정확도 향상을 위한 특징을 선택하고 있다. 본 논문에서는 출력 코딩 기반 서포트 벡터 머신의 각 이진 분류기의 분류 정확도를 최대화하는 특징을 각각 선택하여 사용함으로써, 전체 분류 정확도를 향상시키는 특징 선택 기법을 제안한다. 실험 결과는 제안 기법이 기존 특징 선택 기법에 비하여 통계적으로 유의미한 분류 정확도 향상이 있었음을 보여주었다.

## A Novel Feature Selection Method for Output Coding based Multiclass SVM

Youngjoo Lee<sup>†</sup>, Jeongjin Lee<sup>††</sup>

## ABSTRACT

Recently, support vector machine has been widely used in various application fields due to its superiority of classification performance comparing with decision tree and neural network. Since support vector machine is basically designed for the binary classification problem, output coding method to analyze the classification result of multiclass binary classifier is used for the application of support vector machine into the multiclass problem. However, previous feature selection method for output coding based support vector machine found the features to improve the overall classification accuracy instead of improving each classification accuracy of each classifier. In this paper, we propose the novel feature selection method to find the features for maximizing the classification accuracy of each binary classifier in output coding based support vector machine. Experimental result showed that proposed method significantly improved the classification accuracy comparing with previous feature selection method.

**Key words:** Feature Selection(특징 선택), Multiclass(다중 클래스), Output Coding(출력 코딩), Support Vector Machine(서포트 벡터 머신)

※ 교신저자(Corresponding Author) : 이정진, 주소 : 서울특별시 동작구 상도1동 숭실대학교 컴퓨터학부 정보과학관 328호(156-743), 전화 : 02)820-0911, E-mail : leejeongjin@ssu.ac.kr  
접수일 : 2013년 3월 30일, 수정일 : 2013년 5월 4일  
완료일 : 2013년 5월 9일

<sup>†</sup> 정회원, 삼성전자 생산기술연구소 책임연구원  
(E-mail : spicio2@gmail.com)

<sup>††</sup> 정회원, 숭실대학교 컴퓨터학부 조교수

※ 이 논문은 2012년도 정부(교육과학기술부)의 재원으로 한국연구재단의 기초연구사업 지원을 받아 수행된 것임 (No. 2012R1A1A2043819)

## 1. 서 론

서포트 벡터 머신(Support Vector Machine, SVM)은 뛰어난 일반화 성능에 힘입어 다양한 분야에서 의사 결정 나무나 인공 신경망에 비해 더욱 좋은 분류 성능을 보이고 있기 때문에 현재 가장 널리 사용되고 있다[1,2]. 그러나 SVM은 기본적으로 이진분류 문제를 위해 설계되었기 때문에 최근 SVM을 다중 클래스 문제에 적용하기 위한 연구가 활발히 진행되고 있다.

SVM을 다중클래스에 적용하기 위한 방식은 크게 두 가지로 구분된다. 첫째, SVM 자체를 다중 클래스 분류기로 일반화하는 것이 있다. 둘째, 이진 SVM을 다중으로 사용하는 방식이 있다. 이진 SVM을 다중으로 사용하는 방식은 다시 다중 SVM의 출력 결과를 이용하여 데이터를 분류하는 출력 코딩 방식과 다중 SVM을 계층적으로 사용하여 데이터를 분류하는 계층 구조 방식으로 나눌 수 있다.

SVM 자체를 다중 클래스 분류기로 일반화하는 방식[3,4]은 학습 알고리즘의 계산 복잡도가 매우 높아 실제 문제에 적용되기가 매우 어렵고, 성능은 출력 코딩 방식과 유사하다[5]. 계층 구조 방식[6-8]은 분류기를 계층적으로 적용함으로써 필요한 분류기의 수를 줄여 분류 속도를 향상시키면서 출력 코딩 방식과 유사한 성능을 보인다. 하지만, 최적의 계층 구조를 얻기 위하여 복잡한 과정을 수행해야 하기 때문에 아직 실제 문제에 사용되지는 못하고 있다[9]. 따라서 실제 응용에서는 적용이 용이하고, 안정적인 성능을 가진 출력 코딩 방식[10-12]이 선호되고 있다. 특히 가장 좋은 성능을 보이는 OAO(One-Against-One) 기법[10]이 디팩토 표준(de facto standard)으로 사용되고 있다.

특징 선택은 분류기의 성능 향상을 위하여 분류기 성능 향상에 기여하는 특징을 선택하는 것으로, 분류기 설계 단계에서 반드시 고려되어야 한다[13]. 이진 분류의 경우 두 클래스를 잘 분류하는 특징을 선택하여 최적 분류기를 설계할 수 있지만, 다중 클래스 분류의 경우는 전체 클래스 분류 정확도와 특정 클래스의 분류 정확도 향상에 기여하는 특징이 다를 수 있다. 그러나 출력 코딩 기반 SVM은 특정 두 개의 클래스를 위한 이진 분류기의 조합임에도 불구하고, 기존 특징 선택 기법[13]은 각 분류기의 정확도 향상에

기여하는 특징이 아니라 전체 분류 정확도 향상에 기여하는 특징을 선택하고 있다. 따라서 본 논문에서는 출력 코딩 기반 SVM의 각 이진 분류기 분류 정확도를 최대화하는 특징을 각각 선택하여 사용함으로써 전체 분류 정확도를 향상시키는 특징 선택 기법을 제안한다.

본 논문은 다음과 같은 순서로 구성되어 있다. 2장에서는 본 논문에서 제안한 특징 선택 기법에 대하여 설명한다. 3장에서는 실험 결과를 기술하고, 4장에서는 결론을 맺는다.

## 2. 제안 기법

### 2.1 서포트 벡터 머신

D차원 특징벡터  $x_i$ 와 이에 대응되는 라벨  $y_i(=1, -1)$ 로 구성된  $N$ 개의 학습 데이터  $\{X_i, y_i\}, i=1, \dots, N$ 가 주어졌다고 하자. 두 클래스를 분리하는 분리 초평면은  $w \cdot x + b = 0$ 으로 표현될 수 있다. 여기서  $x$ 는 초평면 상의 점,  $w$ 는 초평면에 수직인 벡터,  $b$ 는 바이어스를 나타낸다. 학습 데이터가 선형 분리가 가능할 때 분리 초평면은 다음 식 (1)과 같은 성질을 갖는다.

$$w \cdot x_i + b \geq 1, y_i = 1. \quad (1)$$

$$w \cdot x_i + b \leq -1, y_i = -1.$$

식 (1)은 다음 식 (2)로 표현 가능하다.

$$y_i(w \cdot x_i + b) - 1 \geq 0. \quad (2)$$

이와 같은 두 초평면 상에 위치한 학습 데이터를 Support Vector(SV)라 하며  $w \cdot x_i + b = \pm 1$ 로 표현될 수 있다. SV와 분리 초평면 사이의 거리를 마진(Margin)이라고 하며,  $2/|w|$ 로 나타낼 수 있다. 최적 분리 초평면은 마진을 최대화하는 분리 초평면이므로 식 (2)의 조건을 만족하면서 다음의 식 (3)의 해를 구하면 된다. 그림 1은 이 과정을 도식화 한 것이다.

$$\min \frac{1}{2} \|w\|^2. \quad (3)$$

학습 데이터를 선형적으로 완전히 분리하는 것이 불가능한 경우에는 식 (4)와 같이 식 (3)에 여유 변수  $\xi$ 를 추가하여 오류에 대한 페널티  $C$ 를 부과함으로써 최적 분리 초평면을 구할 수 있다.




그림 1. 최적 분리 초평면의 결정 과정  
(a) 결정 평면 후보 (b) 최대 마진 분리 초평면

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (4)$$

비선형 분리 초평면이 요구되는 경우에는 커널 함수  $\phi: R^D \rightarrow H$  를 이용하여 학습 데이터를 사영하고, 사영된 고차원에서 선형 분리를 시도한다. 이 때의 목적 함수는 식 (4)와 동일하며, 제약식은 식 (5)와 같다.

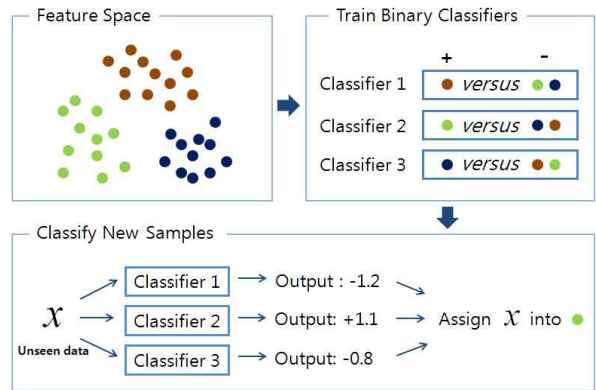
$$y_i (w \cdot \phi(x_i) + b) - 1 \geq 0 \quad (5)$$

### 2.2 출력 코딩 기법

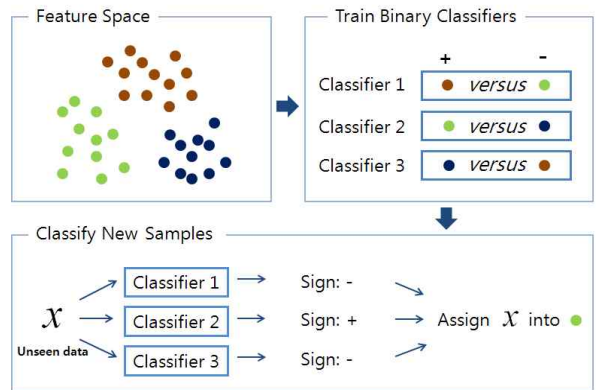
SVM을 다중 클래스 문제에 확장 적용하기 위한 방법인 출력 코딩 방식은 OAA(One-Against-All) [11], OAO(One-Against-One)[10], ECOC(Error Correcting Output Coding)[12] 등 세 가지 기법으로 나눌 수 있다. OAA 기법은 K개의 클래스가 주어졌을 때, 클래스 i의 데이터의 라벨은 +1로, 나머지 클래스의 데이터의 라벨은 -1로 코딩하여 K개의 이진 분류기를 학습한 후 새로운 데이터에 대해 K개의 이진 분류기를 적용하여 출력 값이 가장 큰 클래스로 데이터를 분류한다. 그림 2(a)는 OAA 기법의 적용 사례이다. OAA 기법은 학습과 분류에 K개의 이진 분류기만을 필요로 하기 때문에 속도 면에서 가장 유리하지만, 그림 3과 같이 K개의 분류기로 표현할 수 없는 공간이 생길 수 있기 때문에 분류 정확도가 떨어진다 [14].

다음으로 ECOC 기법은 하나의 클래스를 담당하는 이진 분류기를 복수로 생성하여, 하나의 이진 분류기에서 오분류가 발생하더라도 이 클래스에 관여하는 다른 이진 분류기의 결과를 이용하여 오분류를 정정하는 것이다. 기존 연구 결과에 따르면 ECOC는 OAO와 유사한 성능을 보이는 것으로 알려져 있다 [9].

제안 기법에 적용한 OAO 기법은 클래스의 가능



(a)



(b)

그림 2. 출력 코딩 기반 기법 적용 예시  
(a) One-Against-All 기법 (b) One-Against-One 기법

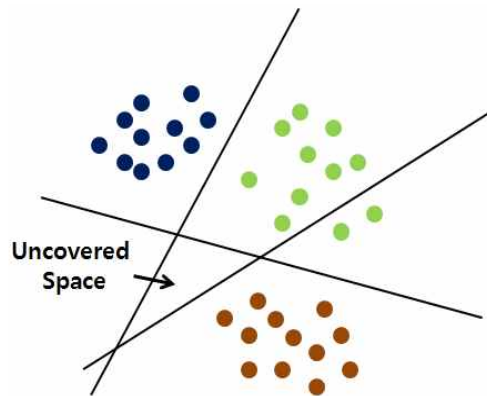


그림 3. 출력 코딩 기반 기법 적용 예시.

한  $K(K-1)/2$ 개의 조합 쌍마다 조합 쌍의 두 클래스에 속한 데이터를 이용하여 분류기를 학습한다. 학습된  $K(K-1)/2$ 개의 이진 분류기를 이용하여 새로운 데이터를 분류하는 방식은 몇 가지가 있지만, 투표 방식이 가장 널리 사용된다[15]. 투표 방식은 각 분류기의 분류 결과에 따라 클래스에 투표를 하여 최다 득표한 클래스로 새 데이터를 분류하며, 득표 수가 같

은 경우는 득표 수가 같은 클래스 중 임의의 클래스로 분류하는 방식이다. OAO 기법의 적용 사례는 그림 2(b)와 같다.

2.3 출력 코딩 특징 선택 기법

특징 선택은 주어진 특징들에서 분류기에 가장 좋은 분류 성능을 보여주는 특징을 선택하는 것이다 [13]. 특징 선택은 특징들의 수를 줄임으로써 분류 속도를 향상시킬 뿐만 아니라, 분류 정확도 향상에 기여하지 않는 특징들을 제거함으로써 분류 정확도를 향상시키기도 한다[16-17]. 특히 불필요한 특징에 의한 분류 성능 저하 현상은 Hughes Phenomenon으로 알려져 있다[18]. 현재까지 여러 가지 특징 선택 기법이 제시되었는데[19], 특징 선택은 기본적으로 NP-hard 문제이므로[20-22] 대부분의 연구가 발견적 기법에 초점을 맞추어 이루어져왔다. 본 연구에서는 매개 변수 선택이 필요 없으면서 좋은 성능을 보여주는 Sequential Forward Selection (SFS) 기법을 특징 선택 기법으로 사용하였다.

일반적으로 정해진 분류 기법과 학습데이터 하에서 특징 선택을 통하여 분류 성능을 향상시킬 수 있다. 따라서 출력 코딩 기반 SVM에서도 특징 선택 기법의 적용을 통하여 분류 성능 향상을 기대할 수 있다. 기존의 특징 선택 기법[13]은 다중 클래스를 처리할 수 있는 분류기를 대상으로 설계되었기 때문에 그림 4와 같이 전체 클래스의 분류 정확도 향상에 기여하는 특징을 선택하였다.

그러나 전체 클래스의 분류 정확도를 향상시키는 특징과 특정 두 클래스의 분류 정확도를 향상시키는 특징은 다를 수 있다. 따라서 이진 분류기의 출력 결과를 종합하여 다중 클래스 문제를 해결하는 출력 코딩 방식에서 그림 5에서와 같이 각 클래스 조합쌍의 분류 정확도를 향상시키는 특징을 각각 선택함으로써 이에 대응하는 이진 분류기의 정확도 향상을 통하여 전체 분류 정확도 개선을 기대할 수 있을 것




그림 4. 기존 특징 선택 기법의 예시.

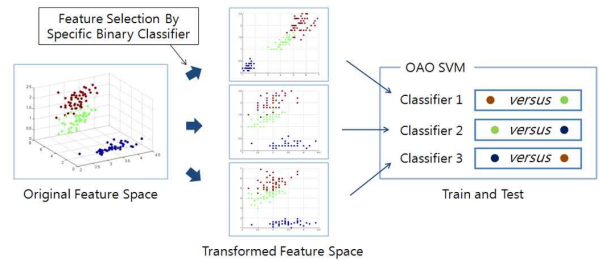


그림 5. 본 논문에서 제안한 특징 선택 기법의 예시

이다.

SVM을 다중클래스 문제에 적용하기 위한 방법들 중에서 de facto standard로 간주되는 OAO 기법에 사용되는 다수의 SVM에 대해서 기존에는 다수의 SVM 전체에 대해 모두 동일하게 구성된 특징 집합을 사용하였다. 하지만, 본 논문에서는 각각의 SVM에 대해서 최적의 다른 특징 집합을 사용하면, 기존 기법보다 분류 정확도가 높아질 수 있다. 본 논문에서 제안한 이와 같은 특징 선택 기법을 출력 코딩 특징 선택 기법이라고 명명한다. 제안 기법은 각 분류기에 대해서 각각 다른 특징들을 사용할 수 있는 것이고, 최종 분류를 위하여 결과적으로 이용되는 정보는 각 분류기의 분류 결과이므로 각 분류기마다 다른 특징들을 사용하는 것은 구현 측면에서도 문제가 없다.

3. 실험 결과

본 논문에서 제안한 출력 코딩 특징 선택 기법과 기존 특징 선택 기법의 성능을 비교 및 분석하기 위하여 다양한 종류의 데이터 수, 클래스 수, 특징 수를 가진 9개의 공개 데이터 셋[23]을 사용하였다(표 1).

표 1. 실험 데이터 셋

데이터 셋 이름	데이터 수	클래스 수	특징 수
iris	150	3	4
wine	178	3	13
glass	214	6	9
ecoli	336	3	7
vehicle	846	4	18
vowel	990	11	10
yeast	1484	10	8
car	1728	4	6
segmentation	2310	7	18

비교 대상으로는 특징 선택을 적용하지 않은 경우, 기존 특징 선택 기법을 적용한 경우를 선택하였다. SVM 매개 변수  $C$ 는 10으로 고정하였으며, 커널함수는 방사상 기저 함수를 사용하였고,  $\gamma$ 는 0.01로 고정하였다. 2-Fold Cross-Validation을 사용하여 분류기를 학습하고, 분류 정확도를 측정하였으며, Random Folding에 의한 분류 정확도 편차를 반영하기 위하여 20회 반복하여 정확도를 측정하고 평균 분류 정확도와 표준편차를 구하였다. 마지막으로 t-test를 이용하여 실험을 통해 구한 각 기법 별 평균 분류 정확도 사이의 차이를 검정하였다. 기존 특징 선택 기법의 경우도 위와 동일한 실험 조건으로 직접 구현하여 비교하였다.

실험 결과는 표 2와 그림 6에 제시하였다. 실험 결과 전체 9개 중 7개의 데이터 셋에서 본 연구에서 제안한 출력 코딩 특징 선택 기법을 적용한 경우가 특징 선택을 적용하지 않은 경우와 기존 특징 선택 기법을 적용한 경우보다 통계적으로 유의미한( $P$ -

$value < 0.05$ ) 분류 정확도 향상을 보였으며, 2개의 데이터 셋에서는 통계적으로 유의미한 차이가 없는 것으로 나타났다. 실험 결과 본 논문에서 제안한 특징 선택 기법이 기존 특징 선택 기법보다 높은 분류 정확도를 보이는 것으로 나타났다.

제안된 기법은 특정 두 클래스의 분류 정확도를 향상시키는 특징을 선택하기 때문에, 전체 클래스의 분류 정확도를 향상시키기 위해 선택된 특징보다 그 수가 적은 경향을 가진다. 표 1과 표 2의 실험 결과를 살펴보면, 클래스 수와 같은 다른 조건이 비슷하다면, 데이터 수에 비하여 특징 수가 많은 데이터 셋이 더 좋은 분류 정확도를 보여주는 경향을 발견할 수 있었다. 이는 본 논문에서 제안한 특징 선택 기법을 통하여 기존 특징 선택 기법에 비하여 적은 수의 특징을 사용함으로써 각 클래스의 데이터 특성을 더 잘 반영할 수 있는 컴팩트한 특성 공간에서 데이터 학습 및 분류를 수행하기 때문에 분류 정확도를 향상시키는 것으로 볼 수 있다.

표 2. 특징 선택 기법 간 분류 정확도 비교 (%)

데이터 셋 이름	특징 선택 적용 없음	기존 특징 선택 기법	제안 기법
iris	96.03±1.38	96.37±1.21	96.27±1.19
wine	97.25±1.09	98.62±0.90	99.27±0.63
glass	62.90±3.70	61.59±3.27	64.51±2.87
ecoli	86.35±1.07	86.18±0.94	87.44±0.89
vehicle	77.52±1.34	77.10±1.41	78.77±1.26
vowel	82.20±1.29	81.68±1.13	81.53±1.38
yeast	59.26±0.55	58.49±0.61	60.42±0.52
car	90.30±0.38	90.37±0.33	90.66±0.37
segmentation	93.63±0.23	93.85±0.20	94.26±0.47




그림 6. 특징 선택 기법에 따른 분류 정확도의 증감  
(\* $P$ -Value  $< 0.05$ , \*\* $P$ -Value  $< 0.01$ )

#### 4. 결 론

본 연구에서는 출력 코딩 기반 SVM을 구성하는 이진 분류기 별로 특징 선택을 수행하는 새로운 특징 선택 기법을 제시하고, 실험을 통하여 제안된 기법이 기존 특징 선택 기법에 비해 통계적으로 유의미한 성능 향상이 있음을 보여주었다. 제안된 이진 분류기 별로 특징선택을 수행하는 기법은 현재 연구가 활발히 이루어지고 있는 계층 구조 기반 기법에도 확장 적용될 수 있다. 향후 제안된 출력 코딩 특징 선택 기법을 OAO 이외에 OAA, ECOC 등에 적용을 통하여 성능 향상 검증을 수행할 예정이고, 특징 수와 데이터 수의 관계가 제안 기법의 기존 기법 대비 성능 향상에 미치는 영향에 대한 연구를 수행할 예정이다.


#### 참 고 문 헌

- [1] C. Huang, L.S. Davis, and J.R.G. Townshend, "An Assessment of Support Vector Machines for land Cover Classification," *International Journal of Remote Sensing*, Vol. 23, No. 4, pp. 725-749, 2002.
- [2] Y. Bazi and F. Melgani, "Toward an Optimal

- SVM Classification System for Hyperspectral Remote Sensing Images,” *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 44, No. 11, pp. 3374-3385, 2006.
- [ 3 ] K. Crammer and Y. Singer, “On the Learnability and Design of Output Codes for Multi-class Problems,” *Computational Learning Theory*, Vol. 47, No. 2, pp. 35-46, 2000.
- [ 4 ] J. Weston and C. Watkins, “Multi-Class Support Vector Machines,” *Proc. of European Symposium on Artificial Neural Networks*, pp. 219-224, 1999.
- [ 5 ] M. Bartlett, J. Movellan, and T. Sejnowski, “Face Recognition by Independent Component Analysis,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 13, No. 6, pp. 1450-1464, 2002.
- [ 6 ] J.C. Platt, N. Cristianini, and J. Shawe-Taylor, “Large Margin DAG’s for Multiclass Classification,” *Advances in Neural Information Processing Systems*, Vol. 12, pp. 547-553, MIT Press, 2000.
- [ 7 ] S. Cheong, S.H. Oh, and S. Lee, “Support Vector Machines with Binary Tree Architecture for Multi-Class Classification,” *Neural Information Processing: Letters and Reviews*, Vol. 2, No. 3, pp. 47-51, 2004.
- [ 8 ] C. Young, C. Yen, Y. Pao, and M. Nagurka, “One-class-at-a-time Removal Sequence Planning Method for Multiclass Classification Problems,” *IEEE Transactions on Neural Networks*, Vol. 17, No. 6, pp. 1544-1549, 2006.
- [ 9 ] C. Hsu and C. Lin, “A Comparison of Methods for Multiclass Support Vector Machines,” *IEEE Transactions on Neural Networks*, Vol. 13, No. 2, pp. 415-425, 2002.
- [10] J. Ghosh, “Multiclassifier Systems: Back to the Future,” *Proc. of the 3rd Int’l Workshop on Multiple Classifier Systems, Lecture Note in Computer Science*, Vol. 2364, pp. 1-15, 2002.
- [11] T. Hastie and R. Tibshirani, “Classification by Pairwise Coupling,” *The Annals of Statistics*, Vol. 26, No. 2, pp. 451-471, 1998.
- [12] T. Dietterich and G. Bakiri, “Solving Multi-class Learning Problems Via Error-Correcting Output Codes,” *Journal of Artificial Intelligence Research*, Vol. 2, pp. 263-286, 1995.
- [13] I. Guyon and A. Elisseeff, “An Introduction to Variable and Feature Selection,” *Journal of Machine Learning Research*, Vol. 3, No. 1, pp. 1157- 1182, 2003.(호 기입요함!)
- [14] B. Fei and J. Liu, “Binary tree of SVM: A New Fast Multiclass Training and Classification Algorithm,” *IEEE Transactions on Neural Networks*, Vol. 17, No. 3, pp. 696-704, 2006.
- [15] J.H. Friedman, *Another Approach to Polychotomous Classification*, Technical Report, Stanford University, 1996.
- [16] A. Jain and D. Zongker, “Feature Selection: Evaluation, Application, and Small Sample Performance,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 19, No. 2, pp. 153-158, 1997.
- [17] 이정진, 김경원, 이호, “블록 기반 클러스터링과 히스토그램 카이 제곱 거리를 이용한 반도체 결함 원인 진단 기법,” *멀티미디어학회논문지*, 제5권, 제9호, pp. 1149-1155, 2012.
- [18] G.F. Hughes, “On the Mean Accuracy of Statistical Pattern Recognizers,” *IEEE Transactions on Information Theory*, pp. 55-63, 1968.
- [19] Y. Saeys, I. Inza, and P. Larrañaga, “A Review of Feature Selection Techniques in bioinformatics,” *Bioinformatics*, Vol. 23, No. 19, pp. 2507-2517, 2007.
- [20] A.L. Blum and R.L. Rivest, “Training a 3-Node Neural Network is NP-complete,” *Neural Networks*, Vol. 5, No. 1, pp. 17-27, 1992.
- [21] M. Garey and D. Johnson, *Computers and Intractability: A Guide to the Theory of NP-completeness*, Freeman, New York, 1979.
- [22] M. Kudo and J. Sklansky, “Comparison of Algorithms that Select Features for Pattern Classifiers,” *Pattern Recognition*, Vol. 33, No.

1, pp. 25-41, 2000.

[23] UCI Machine Learning Repository, <http://archive.ics.uci.edu/ml/>, 2013.



이 영 주

2005년 2월 서울대학교 산업공학과 학사  
2007년 2월 서울대학교 산업공학과 석사  
2010년 2월 서울대학교 산업공학과 박사

2010년 3월~현재 삼성전자 생산기술연구소 책임연구원  
관심분야: 패턴인식, 영상처리, 컴퓨터 보조 진단, 의료 영상, 고성능 컴퓨팅



이 정 진

2000년 2월 서울대학교 기계항공공학부 학사  
2002년 2월 서울대학교 컴퓨터공학부 석사  
2005년 3월 New York Institute of Technology 경영학 석사

2008년 8월 서울대학교 컴퓨터공학부 박사  
2007년 10월~2009년 2월 울산대학교 의과대학 영상의학과 연구교수  
2008년 1월~2010년 5월 (주)클리니컬 이미징 솔루션 기술이사  
2009년 3월~2013년 2월 가톨릭대학교 디지털미디어학부 조교수  
2013년 3월~현재 숭실대학교 컴퓨터학부 조교수  
관심분야: 컴퓨터 그래픽스, 변형체 모델링, 3차원 가상 내시경 및 가상 수술