

# SVM 기반 실리콘 웨이퍼 마이크로크랙의 분류성능 분석

## Classification Performance Analysis of Silicon Wafer Micro-Cracks Based on SVM

김상연<sup>1</sup>, 김경범<sup>2,✉</sup>  
Sang Yeon Kim<sup>1</sup> and Gyung Bum Kim<sup>2,✉</sup>

<sup>1</sup> 한국교통대학교 대학원 항공·기계설계학과 (Graduate School, Aeronautical and Mechanical Design Engineering, Korea National University of Transportation)

<sup>2</sup> 한국교통대학교 항공·기계설계학과 (Aeronautical and Mechanical Design Engineering, Korea National University of Transportation)

✉ Corresponding author: kimgb@ut.ac.kr, Tel: +82-43-841-5378

Manuscript received: 2016.3.2. / Revised: 2016.6.28. / Accepted: 2016.7.14.

*In this paper, the classification rate of micro-cracks in silicon wafers was improved using a SVM. In case I, we investigated how feature data of micro-cracks and SVM parameters affect a classification rate. As a result, weighting vector and bias did not affect the classification rate, which was improved in case of high cost and sigmoid kernel function. Case II was performed using a more high quality image than that in case I. It was identified that learning data and input data had a large effect on the classification rate. Finally, images from cases I and II and another illumination system were used in case III. In spite of different condition images, good classification rates were achieved. Critical points for micro-crack classification improvement are SVM parameters, kernel function, clustered feature data, and experimental conditions. In the future, excellent results could be obtained through SVM parameter tuning and clustered feature data.*

KEYWORDS: Classification (분류), Micro-Crack (마이크로크랙), Silicon wafer (실리콘 웨이퍼), SVM (서포트벡터머신)

### 1. 서론

태양광발전의 단가를 낮추기 위한 노력으로 전 세계에서 많은 연구들이 진행되고 있다. 크게 세 가지로 요약해보면 태양전지 자체의 발전 효율을 높이는 부분, 태양전지 제조에 사용되는 재료의 양을 줄이면서 이로 인한 태양전지의 가격을 낮추는 부분, 그리고 대량 생산 체제 구축을 통한 생산 단가 인하 부분으로 정리할 수 있다. 그 중 태양전지 제조비용의 66% 이상을 차지하는 실리콘 웨이퍼의 박형화와 공정 개선에 따른 대량 생산을

통해 실리콘 재료의 단가 인하가 가능해졌다. 그러나 이와 관련된 공정 장비들도 얇아진 실리콘 웨이퍼를 다루면서 발생하는 웨이퍼의 파손이 이슈가 되고 있다. 특히 웨이퍼에 발생하는 마이크로크랙은 외관상 확인이 어렵고 작은 충격에도 균열이 전파되어 웨이퍼의 파손에 까지 이르게 된다. 이러한 웨이퍼가 셀 제조 공정에 투입될 경우 태양전지의 효율을 저하시키는 원인이 되며, 형태를 예측하기 어려운 마이크로크랙 패턴에 대해 명확히 알려진 바가 없어 발생원인 파악을 위한 제조 공정상 피드백이 제대로 이루어지지 못하고 있다.

태양전지의 효율과 직접적으로 연관되기 때문에 마이크로크랙의 형태별 분류에 대한 필요성이 요구되고 있다.<sup>1-3</sup>

분류에 대한 연구는 현재도 활발하게 진행되고 있다. 대표적인 분류 기술로는 PCA (Principal Component Analysis), 신경망 (Neural Network) 등이 있다.<sup>4</sup> 그러나 PCA는 형태적인 특징 정보가 많이 포함되는 형태를 주성분으로 선택하여 학습하기 때문에 다양한 형태의 마이크로크랙을 분류하기엔 적합하지 않다. 신경망은 많은 수의 학습 데이터를 요구하기 때문에 마이크로크랙 시편을 구하기 어려운 특성상 좋은 성능을 기대하기 어렵다.

따라서 본 논문에서는 상대적으로 적은 수의 학습데이터로 효율적인 분류 성능을 기대할 수 있는 SVM (Support Vector Machine)을 적용하여 마이크로크랙 분류 실험을 진행한 결과 우수한 분류율을 얻을 수 있었다.

## 2. SVM 분류기

### 2.1 SVM 알고리즘

SVM은 다층 퍼셉트론 분류기 (Multi-Layer Perceptron Classifiers)의 대안적인 학습 방법으로, 구조적 리스크를 최소화 (Structural Risk Minimization)하고 패턴을 고차원 특징 공간으로 사상시킬 수 있다는 점과 최적의 식별이 가능하다는 특징이 있다.<sup>5</sup> 통계적 학습 기법을 이용한 SVM은 기존의 PCA, 신경망 등의 분류 기술과는 달리 구조적 오류를 최소화 한다. 두께가 얇은 실리콘 웨이퍼는 취성이 강해 쉽게 깨지기 때문에 결함 영상의 샘플을 구하기가 매우 어렵다. 이러한 어려움을 극복하기 위해 적은 수의 표본만으로도 상대적으로 우수한 예측 성과를 기대할 수 있는 SVM을 적용하고자 한다.

선형 분리 가능한 두 클래스가 존재한다고 할 때 이것을 분류하는 최적의 결정평면에 가장 가까이 존재하는 각 클래스의 샘플을 SV (Support Vector)라고 한다. SVM은 결정평면과 SV 사이의 거리, 즉 마진 (Margin)이 최대가 되는 결정평면을 학습에 사용하여 각 클래스의 샘플을 기반으로 하는 이진 분류기이다. 입력 샘플이  $x_i$  이고 클래스 출력이  $d \in \{1, -1\}$  인 N개의 샘플  $\{(x_i, d_i)\}_{i=1}^N$  을 고려할 때, 결정평면은  $w \cdot x + b = 0$  으로 표시된다. 여기서  $w$ 는 가중치 벡터,  $b$ 는 바이어스를 나타낸다.

이때 두 클래스의 SV사이의 분리 마진은  $2\|w\|$

가 되며, 이를 최대화하기 위해서는  $\|w\|$ 를 최소화해야 한다. 여기서 결정평면과 목표 클래스 출력의 곱이 양수라는 제약조건을 적용하여 비용함수가 최소가 되는  $w$ 와  $b$ 를 구하면 최적화된 결정평면을 얻을 수 있다. 두 클래스에 포함된 샘플들이 선형적으로 완전 분리가 어려운 경우에는 식(1)과 같이 오류에 대해 슬랙 변수  $\xi_i$ 를 적용한 비용함수를 통해 최적화가 가능하며 이를 소프트 마진 기법이라고 한다.

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

이때 훈련 샘플들을 이용하여 마진의 최대화와 분류 허용 패널티에 대한 조절 인자인 C (Cost)의 적절한 값을 경험적으로 결정해야 한다. 그러나 직선으로 분류되지 않는 케이스에 대해서는 소프트 마진 기법 이외에 새로운 해결 방안을 논의할 필요가 있다.

### 2.2 Kernel Function

SVM 분류 기법을 다양한 분류 항목과 많은 자료에 적용하기 위해서는 커널 함수 (Kernel Function)를 사용하여 분류 작업을 수행할 수 있다. 일반적으로 변환함수를 이용하여 보다 고차원의 공간으로 사상 (Mapping)시키면 Fig. 1과 같이 선형 분리 가능한 조건이 된다. 사상된 공간에서도 원 공간에서의 거리 관계를 어느 정도는 보존할 필요가 있기 때문에, 사상 함수를 이용하여 커널함수를 식(2)과 같이 정의 한다. 커널 함수의 선택과 매개변수의 변화에 의해 분류 결과가 달라진다. 일반적으로 Table 1에 주어진 Polynomial, RBF, Sigmoid 커널이 많이 사용되고 있다.

$$K(x_i, x_j) \equiv \phi(x_i)^T \phi(x_j) \quad (2)$$

여기서 주목할 점은 식별함수와 식별의 최적화 문제에  $\phi(x)$ 를 쓰지 않고  $K(\cdot)$ 으로만 나타낼 수 있다는 점이다. 따라서 사상된 공간에서의 식별을 위해 구체적인 사상함수를 설정하지 않고도 식별 함수를 구현할 수 있게 된다. 즉 커널함수  $K(\cdot)$ 를 두 패턴 벡터 간의 거리를 나타내는 함수로 설정하면, 내적이라고 하는 형태로 원래 공간에서의 근사를 보존할 수 있고 식별함수를 구현할 수 있게 된다.




Fig. 1 Description of kernel function

Table 1 Type of kernel function

Function	Formula
Polynomial	$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$
RBF	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$
Sigmoid	$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$

2.3 Multi-Class SVM

일반적인 SVM은 이분류 (Binary Classification) 문제에만 적용할 수 있도록 설계되어 있기 때문에 마이크로크랙의 형태와 같은 다분류 문제에 적용하기 위해서는 SVM을 변형 혹은 확장시킬 필요가 있다. 지금까지 기존 SVM의 변형, 확장을 통해 다분류 문제를 해결하기 위한 다양한 접근법들이 연구되어 왔는데 이러한 접근법들은 크게 두 가지 방식으로 구분된다.<sup>5,6</sup>

첫번째 방식은 이분류 SVM 모형을 여러 개 만들어 결합하는 방식으로, 여기에는 분류할 클래스 개수만큼 이분류 SVM 모형을 구축해, 각 분류 집단에 포함되는 그룹과 그렇지 않은 그룹을 판별하는 형태의 One-Against-All (OAA) 방법이다.

두번째 방식은 분류할 모든 클래스에 대하여 구성할 수 있는 모든 쌍 (Pair)별로 독립된 SVM 모형을 구축하는 One-Against-One (OAO) 방법이다. 이 중에서, OAO 방식이 OAA에 비해 효율성은 떨어지지만 예측 정확도는 상대적으로 더 높게 나타나는 것으로 보고되고 있다. Fig. 2는 OAO 방식의 다분류 SVM 개념도를 나타낸다. 그 외에도 나무의 각 가지들에 SVM이 걸려 있는 형태의 계층적인 구조를 가지는 Tree structure 방법 등이 존재하나 학습 시간이 짧지만, 제대로 된 설계가 어려운 단점이 있다.<sup>7</sup>

본 논문에서는 가장 높은 분류율을 기대 할 수 있는 OAO 방식을 적용하여 마이크로크랙 분류 실험에 적용하였다.

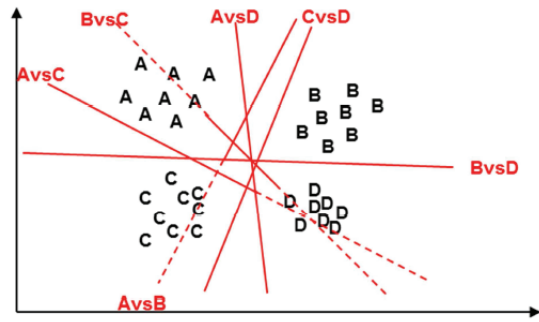


Fig. 2 Description of one-against-one




Fig. 3 Near-Infrared images of micro-crack




Fig. 4 The shape of micro-cracks machined

3. 마이크로크랙 분류의 성능 실험

3.1 마이크로크랙 시편

취성에 약하여 매우 깨지기 쉬운 실리콘 웨이퍼의 특성상 마이크로크랙 시편의 확보가 매우 어려운 실정이다. 본 논문에서는 이와 같은 문제로 5가지 패턴의 마이크로크랙 형태를 가공하여 분류 실험에 적용하였으며 그 형태는 Fig. 3과 같다. Fig. 4는 각 형태별 폭과 길이에 대해 보여주며 폭 (W: width) 75, 125, 175 μm와 길이 (L: length) 1000, 1250,

1500, 1750  $\mu\text{m}$ 의 12가지 크기를 가진 Pattern 1, 2, 3과 폭 100  $\mu\text{m}$ 와 길이 1000, 1250, 1500, 1750  $\mu\text{m}$ 의 4가지 크기를 가지는 Pattern 4, 5로 총 44개의 마이크로크랙 시편을 가공하였다.

### 3.2 분류 실험 Case 1

Fig. 5는 분류 실험 Case 1에 사용한 광학계이다. 회전, 밝기, 배율등의 변화를 고려하여 총 660개의 마이크로크랙 영상을 확보하였으며, LIBSVM을 사용하여 분류실험을 진행하였다.<sup>8</sup> 먼저 SVM과 관련된 파라미터인  $w$ 와  $b$ 의 변화에 따른 분류율을 확인하기 위해  $C$ 값을  $10^3$ 으로 고정한 상태에서  $w$ 와  $b$ 값을 변경하면서 3종류 커널에 대하여 학습 616개, 입력 44개로 실험 조건을 구성하였다. 최대 마진을 결정하는 직선의 기울기에 관련된 값인  $w$ 는 20도 간격으로  $\tan 20^\circ - 160^\circ$ 에 해당하는 값으로 구성하였고, 0과 1사이의 범위를 가지도록 특징 데이터를 구성하였기 때문에 이를 고려하여  $b$ 값을 구성하였다. 실험결과  $w$ 와  $b$ 값에 따른 분류율에 변화는 없었으며, Polynomial 커널일 때 40.91%, RBF 커널일 때 36.36%, Sigmoid 커널일 때 50%로 커널 함수에 따라서 분류율이 달라지는 것을 확인하였다. SVM 이론에 의하면 분류 직선의 각도나 위치에 따라 고려되는 서포트 벡터가 달라질 것이고, 그에 따른 최대 마진이 달라지겠지만 마이크로크랙의 특징 데이터는 비선형 케이스에 해당하기 때문에 비선형 데이터에 고려되는  $C$ 값을 고정으로 하였기 때문에 분류율의 변화가 없었다고 판단하였다. 따라서 이후 실험에는  $b$ 는 1,  $w$ 는 10으로 고정하여 분류 실험을 진행하기로 한다. Tables 2부터 4는 커널함수와  $C$ 에 따른 분류율이다. 분류 실험에 사용한 특징 데이터는 Area, Perimeter, Convex Perimeter, Elongation, Sum of Pixel, Sum of Moment, Eigenvalue 총 7가지이다.<sup>9</sup> 실험결과  $C$ 값과 분류율은 비례관계에 있으나 일정 값 이상이 되면 분류율이 다시 감소하는 것을 확인하였다. 세 가지 커널함수 중 Sigmoid 함수가  $C$ 값이  $10^9$  일 때 가장 높은 분류율을 보여주었다.  $\pm \infty$ 로 갈수록 양극화되는 Sigmoid 함수의 형태가 마이크로크랙을 분류하는데 유리하게 데이터를 사상시켰다고 판단하였다. 그러나 Tables 2부터 4의 분류실험에서 사용한 특징 데이터는 분류 클래스별 군집화가 제대로 이루어진 특징이 아니기 때문에 매우 비선형적인 케이스이다. 그럼에도 불구하고 97.73%의 분류율을 획득할 수 있었던 이유는 비분류 데이터에




Fig. 5 Case I experiment

Table 2 Classification rates for cost parameters

Kernel function	C	Classification rate (%)
Polynomial	$10^1$	27.27
	$10^2$	29.55
	$10^3$	43.18
	$10^4$	31.82
	$10^5$	31.82
	$10^6$	56.82
	$10^7$	34.09
	$10^8$	34.09
	$10^9$	34.09

Table 3 Classification rates for cost parameters

Kernel function	C	Classification rate (%)
RBF	$10^1$	36.36
	$10^2$	36.36
	$10^3$	36.36
	$10^4$	40.91
	$10^5$	56.82
	$10^6$	68.18
	$10^7$	86.36
	$10^8$	79.55
	$10^9$	79.55

Table 4 Classification rates for cost parameters

Kernel function	C	Classification rate (%)
Sigmoid	$10^1$	50.00
	$10^2$	50.00
	$10^3$	50.00
	$10^4$	52.27
	$10^5$	68.18
	$10^6$	81.82
	$10^7$	93.18
	$10^8$	95.45
	$10^9$	97.73

Table 5 Condition of classification test

	learning image	Input image	Feature data
Condition 1	616	44	Area, Perimeter, Convex perimeter, Elongation, Sum of pixel, Sum of moment, Eigenvalue
Condition 2	44	616	Area, Perimeter, Convex perimeter, Elongation, Sum of pixel, Sum of moment, Eigenvalue,
Condition 3	44	616	Eigenvalue
Condition4	616	44	Eigenvalue, SURF, Corner point

Table 6 Classification rates for polynomial kernel

C	Condition 1	Condition 2	Condition 3	Condition 4
10 <sup>1</sup>	27.27	56.66	67.69	27.27
10 <sup>2</sup>	29.55	56.66	67.69	29.55
10 <sup>3</sup>	43.18	56.66	67.69	43.18
10 <sup>4</sup>	31.82	56.66	71.43	31.82
10 <sup>5</sup>	31.82	60.39	78.57	31.82
10 <sup>6</sup>	56.82	71.43	92.05	31.82
10 <sup>7</sup>	34.09	85.55	89.94	36.36
10 <sup>8</sup>	34.09	65.75	75.32	34.09
10 <sup>9</sup>	34.09	64.94	74.51	34.09

대한 패널티값인 C를 크게 할당하였기 때문이며, 그 대신 분류를 위한 학습시간이 길어진다는 단점이 있다.

따라서 실험 데이터의 구성 조건에 따른 분류율을 살펴보기 위해 Table 5와 같이 실험 조건을 구성하였다. 조건 1은 형태별 군집화가 제대로 이루어지지 않은 특징으로 구성하였다. 1번 조건과 학습과 인식영상의 조건을 반대로 하여 2번 조건을 구성하였으며 3번 조건은 2번 조건과 동일한 조건에서 특징 데이터를 Eigenvalue의 1차원으로 구성하였다. 마지막 조건 4는 1번 조건과 동일하고, 특징데이터를 형태별로 군집화된 Eigenvalue, SURF (Speeded Up Robust Feature),<sup>10</sup> Corner point<sup>11</sup>의 3차원으로 구성하였다.

Tables 6부터 8은 세가지 커널에 구성된 실험 조건을 적용했을 때 분류율이다. 첫 번째로, 실험

Table 7 Classification rates for RBF kernel

C	Condition 1	Condition 2	Condition 3	Condition 4
10 <sup>1</sup>	36.36	58.44	66.40	56.82
10 <sup>2</sup>	36.36	58.44	66.40	56.82
10 <sup>3</sup>	36.36	58.44	66.40	56.82
10 <sup>4</sup>	40.91	58.44	67.69	61.36
10 <sup>5</sup>	56.82	59.90	76.62	77.27
10 <sup>6</sup>	68.18	68.83	90.58	81.82
10 <sup>7</sup>	86.36	70.08	89.45	88.63
10 <sup>8</sup>	79.55	79.55	91.88	84.09
10 <sup>9</sup>	79.55	76.14	92.37	84.09

Table 8 Classification rates for sigmoid kernel

C	Condition 1	Condition 2	Condition 3	Condition 4
10 <sup>1</sup>	50.00	50.32	45.78	50.00
10 <sup>2</sup>	50.00	52.44	45.78	52.27
10 <sup>3</sup>	50.00	52.44	45.78	65.90
10 <sup>4</sup>	52.27	52.44	45.78	79.55
10 <sup>5</sup>	65.91	52.44	51.14	93.18
10 <sup>6</sup>	81.82	57.95	59.42	95.45
10 <sup>7</sup>	93.18	63.96	67.05	97.73
10 <sup>8</sup>	95.45	43.34	67.69	97.73
10 <sup>9</sup>	97.73	39.77	66.56	97.73

조건 1, 2의 평균 분류율을 비교했을 때 Polynomial 커널은 조건 2가 약 28%, RBF 커널은 조건 2가 약 8%, Sigmoid 커널은 조건 1이 약 19% 높은 분류율을 보여주었고, 조건 1 Sigmoid 커널에서 C값이 10<sup>9</sup> 일 때 97.73%로 가장 높은 분류율을 획득하였다.

두 번째로, 조건 2, 3을 비교했을 때 전체 실험에 대하여 조건 3이 약 5% 더 높은 분류율을 보여준 것으로 보아, 특징데이터의 차원이 높다고 유리한 것은 아니며 형태별로 군집화된 특징데이터를 적용하는 것이 분류율 향상에 더 큰 이점이 있다는 것을 확인하였다. 세 번째로, 조건 4는 형태별로 군집화된 특징인 Eigenvalue, SURF, Corner point의 3차원으로 구성하였다. 조건 1과 비교해봤을 때 Sigmoid 함수에서 더 낮은 C값으로 최대 분류율을 획득하였다.

### 3.3 분류 실험 Case 2

Fig. 6은 분류 실험 Case 2에 사용한 광학계이다. 분류 실험 Case 1보다 마이크로크랙 영역에서 대비값이 약 10배 더 높은 영상을 획득한다. 높은 품






Fig. 6 Case II experiment




Fig. 7 Case III experiment

질의 영상을 획득하여 분류 실험에 적용했을 때 어떤 영향을 미치는지 알아보는 것이 본 실험의 목적이다. 44개의 마이크로크랙 영상에 밝기, 회전, 배율을 변화시켜서 총 400개의 마이크로크랙 영상을 분류 실험에 사용하였다. Table 9는 분류 실험 결과이며, 실험 조건은 Case 1에서의 결과를 참고하여 가장 성능이 좋았던 Sigmoid 커널,  $C$ 값  $10^9$ , Eigenvalue, SURF, Corner point의 세가지 특징을 적용하였다. 임의로 50개의 영상을 선정하여 350개의 영상을 인식한 결과 약 95%의 분류율을 획득하였다. Case 1 학습데이터의 약 8%만으로 근접한 성능을 보여주었으며, 비슷한 조건인 Table 5의 Condition 2 보다 약 10% 높은 분류율을 획득하였다.

### 3.4 분류 실험 Case 3

분류 실험 Case 3는 여러 광학계를 적용하여 각 산업현장에서 전송받은 영상 조건을 간접적으로 반영하였다. Case 1, 2는 한가지 광학계를 사용하여 모집단 내에서만 실험을 진행하였기 때문에 다른 조건의 광학계를 사용하였을 때 분류율에 대해 분석하기 위한 실험이다. Case 1, 2에서 사용된 마이크로크랙 영상과 Fig. 7과 같이 다른 성능을 가지는 광학계로부터 308개의 영상을 추가로 더 획득

Table 9 Classification rate by experiment of case II

Kernel function	C	Learning image	Input image	Classification rate (%)
Sigmoid	$10^9$	50	350	95.43

Table 10 Classification rates by experiment of case III

Kernel function	C	Learning image	Input image	Classification rate (%)
Sigmoid	$10^9$	812	512	61.7
Sigmoid	$10^9$	922	402	83.8

하여 총 1324개의 영상에 대하여 분류 실험을 진행하였다.

Table 10은 그 분류율을 나타내는 표이다. 812개의 영상을 학습시켰을 때 61.7%의 분류율을 획득하였다. Case 1의 실험결과에 따라 학습영상을 더 추가해서 분류 실험결과 922개의 영상을 학습에 사용하였을 때 약 83.8%의 분류율을 획득할 수 있었다.

### 3.5 분류 성능 고찰

본 논문에서는 실리콘 웨이퍼의 마이크로크랙을 분류하기 위해 SVM을 적용하여 총 세가지 케이스로 나누어 연구를 진행하였다. Case 1을 통해 SVM 파라미터들이 분류실험에 미치는 영향에 대하여 분석하였다. 마이크로크랙 특징 데이터와 같은 비선형 케이스에 대해서  $w$ 와  $b$ 는 분류율에 영향을 미치지 않는 것을 확인하였으며, Sigmoid 커널과 높은  $C$ 값일 때 분류율이 향상되었다. 특징 데이터의 경우 분류 형태별 군집화가 잘 이루어진 데이터를 사용할 때 분류율이 향상되었으며 특징 데이터 차원이 높아도 분류 성능에는 큰 영향이 없었다. Case 2에서는 더 높은 품질의 영상과, 형태별 군집화가 이루어진 특징 데이터를 사용했을 때 분류 성능이 향상되는 것을 확인할 수 있었다. Case 3는 마이크로크랙이 발생한 현장에서 사용되는 광학계로부터 영상을 받을 때의 조건을 반영하기 위해 세 가지 광학계로부터 획득한 영상을 사용하였으며, 마이크로크랙 영상의 모집단 내에서 진행한 실험의 분류율보다 분류율이 상대적으로 낮아지는 것을 확인하였다. 각각 다른 조건과 성능을 가지는 광학계로 획득한 영상이기 때문에 마이크로크랙 형태별 특징 데이터의 군집화가 잘 이루어지지 못했기 때문에 얻어진 결과라고 판단된다. 그러나 학습과 입력 데이터의 구성,  $C$ , 특징 데

이터의 군집화를 통해 분류 성능이 향상될 수 있는 것을 확인하였다.

#### 4. 결론

본 논문에서 세 가지의 분류 실험을 통해 마이크로크랙 분류 향상에 대한 연구를 진행하였다. SVM 기반의 분류율 향상 방안에 대해 정리하면 Cost 값은 높을수록, 데이터를 이분류하기 위해 양극화 시키는 Sigmoid 커널의 선정, 군집화된 데이터 분포를 나타내는 특징을 선정한다면 SVM 특성상 상대적으로 적은 수의 학습데이터로도 높은 분류율을 기대할 수 있다. 그러나 위에 제시된 방안이 충족되지 않을 경우 분류 성능을 위해 많은 수의 학습데이터가 요구된다.

#### 후 기

이 논문은 정부의 재원으로 한국연구재단의 기초 연구 지원 사업 (2012R1A1A4A01001630), (2015R1D1A1A01056691)의 지원을 받아 수행되었습니다.

#### REFERENCES

1. Chiou, Y.-C., Liu, J.-Z., and Liang, Y.-T., "Micro Crack Detection of Multi-Crystalline Silicon Solar Wafer Using Machine Vision Techniques," *Sensor Review*, Vol. 31, No. 2, pp. 154-165, 2011.
2. Ko, S.-S., Liu, C.-S., and Lin, Y.-C., "Optical Inspection System with Tunable Exposure Unit for Micro-Crack Detection in Solar Wafer," *Optik-International Journal for Light and Electron Optics*, Vol. 124, No. 19, pp. 4030-4035, 2013.
3. Abdelhamid, M., Singh, R., and Omar, M., "Review of Microcrack Detection Techniques for Silicon Solar Cells," *IEEE Journal of Photovoltaics*, Vol. 4, No. 1, pp. 514-524, 2014.
4. Seo, H. J. and Kim, G. B., "A Study on Classification of Micro-Cracks in Silicon Wafer through the Fusion of Principal Component Analysis and Neural Network," *J. Korean Soc. Precis. Eng.*, Vol. 32, No. 5, pp. 463-470, 2015.
5. Bin, Z., Yong, L., and Shao-Wei, X., "Support Vector Machine and Its Application in Handwritten Numeral Recognition," *Proc. of 15<sup>th</sup> International Conference on Pattern Recognition*, pp. 720-723, 2000.
6. Hsu, C.-W. and Lin, C.-J., "A Comparison of Methods for Multi-Class Support Vector Machines," *IEEE Transactions on Neural Networks*, Vol. 13, No. 2, pp. 415-425, 2002.
7. Takahashi, F. and Abe, S., "Decision-Tree-Based Multiclass Support Vector Machines," *Proc. of 9<sup>th</sup> International Conference on ICONIP*, pp. 1418-1422, 2002.
8. Chang, C.-C. and Lin, C.-J., "LIBSVM: A Library for Support Vector Machines," *ACM Transactions on Intelligent Systems and Technology*, Vol. 2, No. 3, p. 27, 2011.
9. Seo, H. J., Kim, G. B., and Kim, S. Y., "Correlation Analysis between Micro-Crack Shape and Near-Infrared Image Pattern of Silicon Wafer," *Proc. of KSPE Spring Conference*, pp. 903-904, 2014.
10. Oyallon, E. and Rabin, J., "An Analysis of the SURF Method," *Image Processing On Line*, Vol. 5, pp. 176-218, 2015.
11. Harris, C., and Stephens, M., "A Combined Corner and Edge Detector," *Proc. of Alvey Vision Conference*, pp. 147-152, 1988.