

실리콘 웨이퍼 마이크로크랙을 위한 대표적 분류 기술의 성능 평가에 관한 연구

김상연* · 김경범†

*한국교통대학교 대학원, †한국교통대학교 항공·기계설계학과

A Study on Performance Evaluation of Typical Classification Techniques for Micro-cracks of Silicon Wafer

Sang Yeon Kim* and Gyung Bum Kim†

*Graduate school, Korea National University of Transportation,

†Aeronautical & Mechanical Design Engineering, Korea National University of Transportation

ABSTRACT

Silicon wafer is one of main materials in solar cell. Micro-cracks in silicon wafer are one of reasons to decrease efficiency of energy transformation. They couldn't be observed by human eye. Also, their shape is not only various but also complicated. Accordingly, their shape classification is absolutely needed for manufacturing process quality and its feedback. The performance of typical classification techniques which is principal component analysis(PCA), neural network, fusion model to integrate PCA with neural network, and support vector machine(SVM), are evaluated using pattern features of micro-cracks. As a result, it has been confirmed that the SVM gives good results in micro-crack classification.

Key Words : Classification technique, Micro-crack, Silicon wafer

1. 서 론

태양전지의1 주재료인 실리콘 웨이퍼는 태양전지 제조비용의 66% 이상을 차지하며, 제조 원가를 절감하기 위해 두께를 더 얇게 제작하고 있는 추세이다. 실리콘 웨이퍼의 두께가 얇아짐에 따라 열응력, Wire-sawing, 물리적 충격으로 인해 실리콘 웨이퍼에 마이크로크랙이 발생할 확률이 높아진다. 마이크로크랙이 발생한 실리콘 웨이퍼는 취성에 약하기 때문에 작은 충격으로도 결함 방향을 따라서 균열이 성장하기 쉽고, 웨이퍼의 파손으로 연결되는 치명적 불량이며, 에너지변환 효율을 감소시키는 원인이 된다.

태양전지 시장은 대량생산을 기반으로 하는 규모의 경

제이기 때문에 마이크로크랙을 분류하여 제조공정상의 피드백을 통해 발생원인을 파악해서 마이크로크랙 발생율을 1%만 줄여도 제조비용 절감에 있어서 큰 영향을 미친다. 따라서 마이크로크랙의 검사를 위한 수요가 발생하고 이에 따라 다양한 검사 시스템이 개발되어 왔다.^{1,2} 지금까지 개발된 방법들로는 공진 초음파 진동(RUV : resonance ultrasonic vibration), 전자 스펙클 패턴 간섭법(ESPI : electronis speckle pattern interfermetry), 고정화 열상법(LIT : lock-in thermography), 전계발광(EL : electroluminescence), 광발광(PL : photoluminescence)와 같이 여러 가지 방법들이 존재한다.³ 그러나 대부분의 검사 방법은 마이크로크랙의 유무를 판단 하는데 초점이 맞춰져 있으며, 실시간 검사가 불가능한 단점이 있다.

본 논문에서는 실리콘 웨이퍼의 마이크로크랙의 대표적 분류 기술인 주성분분석(PCA : principal component

†E-mail: kimgb@ut.ac.kr

analysis), 신경회로망(neural network), 주성분분석과 신경회로망의 융합모델⁴, SVM(support vector machine)을 적용하여 마이크로크랙을 분류하였으며, 그 중에서 SVM의 분류성능이 가장 뛰어난 것을 확인하였다.

2. 마이크로크랙 시편 규격 및 실험조건

실제 공정 중 발생한 마이크로크랙 시편은 입수하기 어려우며, 마이크로크랙을 지니는 실리콘 웨이퍼는 운반, 취급 중에 깨질 위험이 크다. 이러한 시편 확보의 어려움 때문에 분류 실험을 위해 마이크로크랙의 형태를 Fig 1과 같이 5가지로 예측하여 가공하였다. 폭(W : width) 75, 125, 175 μm 와 길이(L : length) 1000, 1250, 1500, 1750 μm 의 12가지 크기를 가진 Pattern 1, 2, 3과 폭 100 μm 와 길이 1000, 1250, 1500, 1750 μm 의 4가지 크기를 가지는 Pattern 4, 5로 총 44개의 마이크로크랙 시편을 가공하였다. 가공된 시편은 근적외선 광학계를 이용하여 영상으로 획득하였으며, 영상의 잡음제거 및 마이크로크랙 영역에서의 대비를 높이기 위해 $\lambda_f=0.25$, $K=15$, $t=5$, $\alpha=0.3$ 조건의 비등방 확산 필터⁵를 적용하였다. 이 때, 각 영상의 크기는 70×50으로 편집하였으며, 분류실험에 사용한 마이크로크랙 특징 데이터는 PCA와 Neural Network 에 Area, Perimeter, Convex perimeter, Elongation, Sum of pixel, Sum of moment의 6개를 적용하였고, PCA와 Neural network 융합모델과 SVM에는 Eigenvalue를 추가하여 7개를 적용하였다.

3. 대표적 분류 기술 성능 실험 및 고찰

3.1 주성분분석 기반 분류 실험

주성분분석⁶은 다차원의 변수를 분산을 최대로 유지함을 목표로 차원축소를 행하는 작업을 한다. 영상에 대한 공




Fig. 1. The shape of micro-cracks machined.

$$m = \frac{1}{M} \sum_{n=1}^M x_n \quad (1)$$

$$C = \frac{1}{M} \sum_{n=1}^M (x_n - m)(x_n - m)^T \quad (2)$$

$$y = W_p^t(x_{test} - m), \quad W_p = [\mu_1, \mu_2, \dots, \mu_t] \quad (3)$$

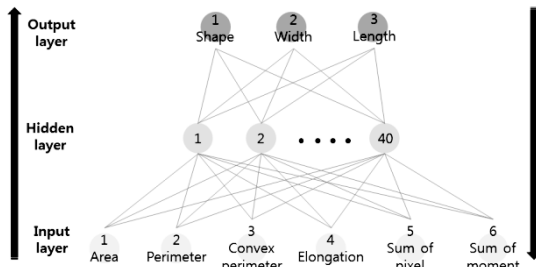
분산(covariance) 행렬의 고유벡터가 영상내의 정보들의 독립성을 유지하는 기저벡터(base vector)가 되며, 고유벡터를 선형결합으로 원본영상을 복원한다. 여기서, 영상으로부터 고유벡터를 구하는 방법은 우선 식 (1)과 같이 M개의 학습영상에 대한 벡터집합 x_n 의 평균벡터 m 을 구한 후 식 (2)와 같이 각 벡터집합과 평균벡터의 차이를 이용하여 공분산 행렬 C를 계산한다. 공분산 행렬은 고유값 λ 와 고유벡터 μ 를 구하는데 사용되며, 고유벡터를 재배열하면 M개의 고유영상을 얻을 수 있다. 따라서 학습영상에 대한 평균벡터, 고유벡터와 입력영상에 대한 벡터집합 x_{test} 를 식 (3)을 이용하여 얻은 가중치 y 로 유클리디안 거리를 비교하여 영상인식을 할 수 있다. 주성분분석을 이용한 마이크로크랙 분류실험은 준비한 44개의 영상을 학습시킨 뒤 5°, 10°, 15°로 회전한 132개의 마이크로크랙 영상을 입력하였다. 모든 픽셀은 벡터로 표현이 가능하므로 이진 영상 내의 객체를 정의하는 픽셀을 모아서 벡터 집합을 구성할 수 있다. 학습영상으로부터 평균벡터를 계산한 뒤 입력영상의 벡터와 평균 벡터의 차이 벡터를 이용하여 입력영상에 대한 가중치를 구한 뒤 유클리디안 거리가 최소인 영상을 분류결과로 결정한다. Table 1은 그 결과이며 각 패턴에 대한 분류율을 나타내며 5가지 형태에 대한 평균 분류율은 38.9%로 획득되었다. 주성분분석의 특성상 학습영상 중에서 가장 큰 고유값을 갖는 영상을 선택하여 학습하기 때문에 상대적으로 큰 고유값을 가지는 Pattern 4, 5가 Pattern 1, 2, 3보다 더 높은 분류율을 보여주었다. 그렇기 때문에 형태가 매우 복잡하고 다양한 형태를 지니는 마이크로크랙의 특성상 고유값이 작은 마이크로크랙에 대해서는 분류하기 어려운 단점이 존재한다.

3.2 신경회로망 기반 분류 실험

신경회로망은 대용량의 복잡한 데이터를 분석하는 동시에 데이터의 특성을 학습하고, 학습된 특성으로 기존 데이터와 유사한 새로운 문제를 해결할 수 있다. 마이크로크랙 분류 과정에서 발생하는 오류를 은닉층으로 되돌려 학습하여 더 이상의 오류가 발생하지 않도록 하는 오

Table 1. Classification rate and average eigenvalue according to PCA

Shape	Classification rate(%)	Average Eigenvalue
Pattern 1	19.4	3.4×10^4
Pattern 2	2.8	2.0×10^5
Pattern 3	5.6	6.4×10^5
Pattern 4	66.7	2.5×10^6
Pattern 5	100	6.3×10^6
Average	38.9	

**Fig. 2.** A Classification design by neural network

$$NET_j = \sum_{i=1}^n x_i w_{ij} \quad (4)$$

$$f(NET_j) = \frac{1}{1 + \exp^{-NET_j}} \quad (5)$$

$$\Delta w_{ij} = \eta \cdot \delta_{pj} \cdot o_{pi} \quad (6)$$

류역전파(back-propagation) 알고리즘을 이용하여 분류를 한다. 오류역전파의 학습은 신경망의 전 방향으로 계산된 값과 목표값을 비교하여 오차의 제곱 합이 최소가 되도록 연결강도를 조정하게 되며, 오차가 일정 수준 이하가 될 때까지 반복한다. 연결강도의 조정은 식 (6)을 이용한다. 여기서 η 는 학습률, δ 는 현재층의 오차, o 는 이전층의 활성화값이다. NET_j 는 j 번째 출력에 들어오는 외부자극의 가중합을 의미하며, x 는 외부자극, w 는 출력과 x 사이의 연결강도를 의미한다. 이때, 출력의 반응값은 식 (5)에 나타낸 시그모이드(sigmoid) 함수를 사용한다. 마이크로크랙을 분류하기 위해 Fig 2와 같이 6 개의 노드(node)로 구성된 입력층, 3개의 노드로 구성된 출력층으로 신경회로망을 설정하였다. 출력에 대한 목표값은 Table 2에 나타내었으며, 은닉 층은 각 층수에 대하여 경험적으로 설정해본

결과 가장 높은 분류율을 보여준 단일층으로 이루어진 40개의 노드로 설정하였다.⁹ 44개의 마이크로크랙 중에서 무작위로 선정한 5개의 입력에 대하여 연결강도 0.0001 이내로 학습하였다.

Table 2. Target values for neural network

Shape	Size(W-L)	Target value		
		Shape	Width	Length
Pattern 1	75-1000 μ m	0.1	0.1	0.1
	75-1250 μ m	0.1	0.1	0.4
	75-1500 μ m	0.1	0.1	0.7
	75-1750 μ m	0.1	0.1	1.0
:	:	:	:	:
Pattern 5	100-1000 μ m	1.0	1.0	0.1
	100-1250 μ m	1.0	1.0	0.4
	100-1500 μ m	1.0	1.0	0.7
	100-1750 μ m	1.0	1.0	1.0

Table 3은 학습된 신경망 모델을 이용하여 획득한 출력값이고, Table 4는 목표값에 대한 출력값의 정확도로 분류율을 의미한다. 분류 결과 각 형태에 대한 평균 분류율은 82.2%로 획득되었다.

Table 3. Output values obtained by neural network learning

Shape	Size(W-L)	Output		
		Shape	Width	Length
Pattern 1	75-1500 μ m	0.0784	0.5079	0.6969
Pattern 2	75-1750 μ m	0.2926	0.0903	0.7749
Pattern 3	125-1500 μ m	0.4500	0.0850	0.7134
Pattern 4	100-1500 μ m	0.6774	0.4382	0.5817
Pattern 5	100-1750 μ m	0.9000	0.8419	0.5500

Table 4. The Classification rates of between target and output

Shape	Size(W-L)	Classification rate(%)		
		Shape	Width	Length
Pattern 1	75-1500 μ m	78.4	59.2	89.9
Pattern 2	75-1750 μ m	90.0	90.4	99.0
Pattern 3	125-1500 μ m	90.0	85.0	92.1
Pattern 4	100-1500 μ m	93.4	43.8	75.1
Pattern 5	100-1750 μ m	90.0	84.2	71.0
Average		88.4	72.5	85.6
		82.2		

3.3 융합모델 기반 분류 실험

경험적인 설정 결과에 의해 은닉층은 가장 높은 분류율을 보여주었던 단일층에 15개의 노드로 구성된 2개의 층으로 구성하였다. Table 5는 학습된 신경망 모델을 이용하여 획득한 출력값이고, Table 6은 목표값에 대한 출력값의 정확도로 분류율을 의미한다. 기존에 적용한 6개의 특징은 마이크로크랙 영역에 해당하는 국부적 특징(local feature)이지만, 주성분분석을 통해 획득한 고유값은 포괄적 특징(global feature)으로 값이 클수록 마이크로크랙 특징의 특성이 크고, 값이 작을수록 마이크로크랙 특징의 특성이 작아진다. 따라서 마이크로크랙 형태에 따라서 민감하게 특징값이 변하기 때문에 더 신뢰성있는 특징으로 판단하여 신경회로망에 적용하였던 6개의 특징 이외에 주성분분석으로 획득한 고유값을 추가하여 7개의 입력 노드로 구성하여 실험을 진행하였다. 분류 결과 각 형태에 대한 평균 분류율은 89.2%로 획득되었다.

Table 5. Output values obtained by to neural network and PCA fusion model learning

Shape	Size(W-L)	Output		
		Shape	Width	Length
Pattern 1	75-1500 μm	0.0994	0.0958	0.6861
Pattern 2	75-1750 μm	0.2950	0.0945	0.5500
Pattern 3	125-1500 μm	0.4646	0.0910	0.7697
Pattern 4	100-1500 μm	0.6749	0.9307	0.5504
Pattern 5	100-1750 μm	0.6625	0.9793	0.7197

Table 6. The Classification rates between target and output

Shape	Size(W-L)	Classification rate(%)		
		Shape	Width	Length
Pattern 1	75-1500 μm	99.4	95.9	88.5
Pattern 2	75-1750 μm	90.8	94.5	71.0
Pattern 3	125-1500 μm	92.9	91.0	99.3
Pattern 4	100-1500 μm	93.1	93.1	71.0
Pattern 5	100-1750 μm	66.3	97.9	92.9
Average		88.5	94.5	84.5
		89.2		

3.4 SVM 기반 분류 실험

SVM(Support Vector Machine)은 통계학자인 Vapnik에 의해 개발된 분류기법으로, 입력공간과 관련된 비선형문제를 고차원의 특징공간에서의 선형문제로 대응시켜 적은 수의 표본만으로도 상대적으로 우수한 예측성능을 기

대할 수 있는 최근 가장 주목 받고 있는 분류 기법이다.⁷⁸

두 클래스를 선형 분리할 수 있는 결정평면(decision surface)에 가장 가까이 존재하는 각 클래스의 샘플을 SV(support vector)라고 하는데, SVM은 결정평면과 SV 사이의 거리, 즉, 마진(margin)이 최대가 되는 결정평면을 훈련에 사용되는 각 클래스의 샘플을 이용하여 구하는 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 $wx + b = 0$ 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.

$$\Phi(w) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (7)$$

두 클래스에 포함된 샘플들이 선형적으로 완전 분리가 어려운 경우에는 식 (7)와 같이 오류에 대해 슬랙 변수 ξ_i 를 적용한 비용함수를 통해 최적화가 가능하며 이를 소프트 마진 기법이라고 한다. 이때 훈련 샘플들을 이용하여 마진의 최대화와 분류 허용 패널티에 대한 조절 인자인 C의 적절한 값을 경험적으로 결정해야 한다. 그러나 직선으로 분류되지 않는 케이스에 대해서는 소프트 마진 기법 이외에 새로운 해결 방안인 커널함수를 논의할 필요가 있다. 비선형 변환함수를 이용하여 보다 고차원의 공간으로 사상(mapping)시키면 Fig. 3과 같이 선형 분리 가능한 평면을 얻을 수 있다. 하지만, 일반적인 SVM은 이분류(binary classification) 문제만 해결할 수 있도록 설계되어 있기 때문에 이를 다분류 문제에 적용하기 위해서는 SVM을 변형 혹은 확장시킬 필요가 있다. 그 방법으로 이분류 SVM 모형을 여러 개 만들어 결합하는 방식인데, 여기에는 분류할 클래스 개수만큼 이분류 SVM모형을 구축해 분류할 전체 등급에 대해 구성될 수 있는 모든 쌍(pair)별로 독립된 SVM모형을 구축하는 One-Against-One(OAO) 방법을 적용하였다. 분류 허용 패널티인 C값은 100으로 고정하고 적용 커널은 식 (8)과 같은 Polynomial 커널을 이용하여 분류실험에 적용하였다. SVM의 파라미터인 w 는 10, b 는 1로 설정하였으며, 커널함수의 파라미터 r 는 1, d 는 3으로 3차 식으로 설정하였다. 학습에 적용한 특징 조건은 융합모델과 동일하다. Table 7은 44개의 마이크로크랙모집단 중 무작위로 5개를 추출하고 39개의 데이터를 학습시킨 뒤 10번의 분류실험을 진행하였을 때




Fig. 3. Description of kernel functions.

Table 7. Classification rates by SVM

Classification case	Classification rate(%)
Test 1	80
Test 2	100
Test 3	100
Test 4	100
Test 5	80
Test 6	80
Test 7	100
Test 8	100
Test 9	100
Test 10	100
Average	94

분류율을 나타낸 표이다. 분류 결과 10번의 분류 실험에 대한 평균 분류율은 94%로 획득되었다.

$$K(x_i, x) = (x_i \cdot x + r)^d \quad (8)$$

3.5 마이크로크랙 분류 성능 평가 및 고찰

주성분분석, 신경망회로, 주성분분석과 신경망회로의 융합모델, SVM 총 4가지의 대표적인 분류 기술을 적용하여 마이크로크랙 분류실험을 진행하였다. Fig. 4는 각 분류실험에 대한 결과를 나타낸 표이다. 분류결과 주성분분석이 38.9%로 가장 낮은 분류율을 보여주었으며, SVM이 94%로 가장 높은 분류율을 보여주었다. 마이크로크랙의 특징을 가장 많이 포함하는 데이터에 대한 분류율은 높지만, 그렇지 않은 데이터에 대한 분류율은 낮았다. 다시 말해서, 다양하고 복잡한 형태를 지니는 마이크로크랙의 특성상 주성분분석은 마이크로 크랙의 형태에 따라서 고유값이 큰 데이터를 주성분으로 선정하여 학습하기 때문에 상대적으로 고유값이 작은 형태에 대한 분류에는 한계가 있다. 그러나 신경회로망만 적용하였을 때보다 신경회로망과 주성분분석의 융합모델을 적용하였을 때 약 7% 분류율이 향상되었기 때문에 주성분분석만 적용하는

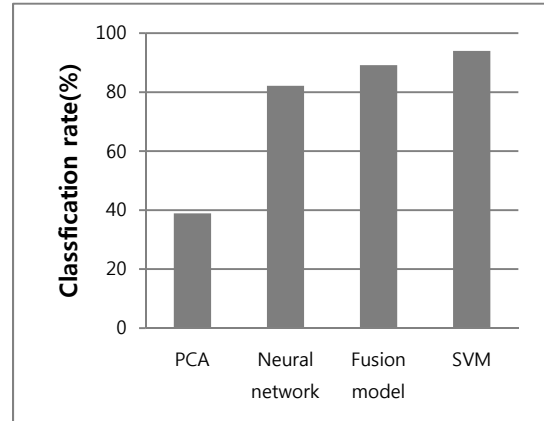


Fig. 4. Performance evaluation for classification results.

것 보다 마이크로크랙 분류를 위한 특징데이터로 고유값을 적용하는 것이 분류 향상에 있어 더 유리하다. SVM은 서포트 벡터에 해당하는 데이터만 학습에 사용하기 때문에, 학습데이터가 많지 않았던 본 논문의 실험조건에서 4가지 패턴인식 알고리즘 중 가장 높은 분류율을 보여주었다. SVM의 파라미터, 커널함수의 다양한 적용을 통해 최적화 과정을 거친다면 마이크로크랙 분류에 있어 더 좋은 성능을 보여줄 것이라고 판단된다.

4. 결 론

본 논문에서는 주성분분석, 신경망회로, 주성분분석과 신경망회로의 융합모델, SVM 총 4가지의 패턴인식 알고리즘을 적용하여 마이크로크랙 분류실험을 진행하였다. 그 결과 SVM이 94%의 분류율로 가장 뛰어난 성능을 보여줌으로써 마이크로크랙 분류실험에 가장 적합한 분류 기술인 것을 확인하였다.

감사의 글

이 논문은 정부의 재원으로 한국연구재단의 지원을 받아 수행된 기초 연구사업(2012R1A1A4A01001630), (2015R1D1A1A01056691)의 지원을 받아 수행되었습니다.

참고문헌

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,” *Journal of the Korean Society of Precision Engineering*, pp. 463-470, 2015.
 5. Seo, H. J. and Kim, G. B., “Optimal Parameter Selection of Anisotropic Diffusion Filter based on Design of Experiment for Silicon Wafer Crack Detection,” *Journal of the Semiconductor & Display Technology*, Vol. 13, No, 3, 2014.
 6. Moon, H. and Phillips, P. J., “Computational and Performance Aspects of PCA-Based Face-Recognition Algorithms,” *Perception-London*, Vol. 30, No. 3 pp. 303-322, 2001.
 7. Hsu, C.-Y. and Lin, C.-J., “A Comparison of Methods for Multi-class Support Vector Machines,” *Neural Networks, IEEE Transactions on*, Vol. 13, No. 2, pp. 415-425, 2002.
 8. Chang, C. and Lin, J., “LIBSVM: a Library for Support Vector Machines,” *J. ACM Transactions on Intelligent Systems and Technology*, Vol. 2, Issue 3, 2011.
-
- 접수일: 2016년 8월 11일, 심사일: 2016년 9월 9일,
게재확정일: 2016년 9월 23일