

# 주성분분석과 신경회로망의 융합을 통한 실리콘 웨이퍼의 마이크로 크랙 분류에 관한 연구

## A Study on Classification of Micro-Cracks in Silicon Wafer Through the Fusion of Principal Component Analysis and Neural Network

서형준<sup>1</sup>, 김경범<sup>2,✉</sup>  
Hyoung Jun Seo<sup>1</sup> and Gyung Bum Kim<sup>2,✉</sup>

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

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

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

Manuscript received: 2015.1.7. / Revised: 2015.3.23. / Accepted: 2015.4.7.

*Solar cell is typical representative of renewable green energy. Silicon wafer contributes about 66 percent to its cost structure. In its manufacturing, micro-cracks are often occurred due to manufacturing process such as wire sawing, grinding and cleaning. Their detection and classification are important to process feedback information. In this paper, a classification method of micro-cracks is proposed, based on the fusion of principal component analysis(PCA) and neural network. The proposed method shows that it gives higher results than single application of two methods, in terms of shape and size classification of micro-cracks.*

KEYWORDS: Classification (분류), Neural network (신경회로망), Micro-Crack (마이크로크랙), Silicon wafer (실리콘 웨이퍼), Principal component analysis (주성분분석)

### 1. 서론

최근 환경문제, 기후변화협약, 화석에너지 고갈로 인해 청정하고 무한한 태양에너지를 이용한 태양광 발전산업이 각광받고 있다. 이에 따라 세계 태양광 발전의 설치량은 2013년 35.1GW로 2017년까지 61GW로 성장할 것으로 전망된다.<sup>1</sup>

태양전지의 85% 이상이 결정질 실리콘 웨이퍼를 기반으로 생산되며, 실리콘 웨이퍼는 태양전지 제조비용 중 66%를 차지한다. 따라서 원가 절감의

일환으로 실리콘 웨이퍼의 두께를 기존 180 $\mu$ m 이상에서 160 $\mu$ m 이하로 박형화 되어간다. 그로 인해 실리콘 웨이퍼 제조공정 중 절단, 연마, 세척, 핸들링 등으로 인한 마이크로 크랙의 발생 확률이 높아진다. 실리콘 웨이퍼에 존재하는 크랙은 전자의 흐름을 방해하기 때문에 에너지 변환 효율 및 공정품질에 악영향을 끼친다. 따라서 실리콘 웨이퍼의 마이크로 크랙 검출 및 분류는 매우 절실히 요구되고 있다.<sup>2-4</sup>

그동안 사용되었던 실리콘 웨이퍼 마이크로 크

랙에 대한 검사방법<sup>1,2,5,6</sup>에는 공진 초음파 진동 (RUV : Resonance Ultrasonic Vibration), 전자 스페클 패턴 간섭계(ESPI : Elestronis Speckle Pattern Interfermetry), 적외선 열화상(IRT : Infrared Ray Thermal), 전계발광(EL : electroluminescence), 광발광(PL : photoluminescence) 등과 같이 방사선, 열 또는 빛 등을 이용한 다양한 방법들이 개발되어 왔다. 하지만 지금까지 개발된 검사 장비들은 크랙 검출율은 우수하지만 분류에는 아직 미흡하며, 현장에 적용되기 까지 많은 시간이 요구된다. 또한 새로운 형태의 크랙이 발생될 때마다 분류기의 변경작업이 요구되며, 전문가만이 할 수 있기 때문에 기술의 의존도가 매우 높고 고비용의 유지보수가 요구되기 때문에 우수한 크랙 분류기를 개발하기가 쉽지 않다. 따라서 우수한 분류기를 개발하기 위한 연구가 현재까지도 진행되고 있다.

본 연구에서는 실리콘 웨이퍼의 마이크로 크랙을 분류하기 위해 주성분분석(PCA : principal component analysis)과 신경회로망(neural network)을 적용하여 분류 가능성을 확인하였으며, 주성분분석과 신경회로망의 융합을 통해 분류율을 향상시켰다.

## 2. 주성분분석을 이용한 실리콘 웨이퍼의 마이크로 크랙 분류

### 2.1 주성분분석 개념

주성분분석<sup>7</sup>은 고차원의 정보를 유지하면서 차원축소를 통하여 데이터의 특징을 밝히거나 변수의 관계를 규명하는 다변량 분석기법이다. 주성분분석은 주로 신호처리, 특징추출, 자료의 차원 감소, 영상인식 등 많은 분야에 사용되며 특히 영상인식 분야에서는 영상내의 특징추출에 매우 효율적인 방법이다.

주성분분석으로 영상을 인식하는 방법은 학습영상에 대한 공분산(covariance) 행렬의 고유벡터가 영상내의 정보간의 상관관계를 제거하는 기저벡터(base vector)가 되며, 고유벡터를 선형결합으로 원본영상을 복원한다. 따라서 고유벡터를 통해 영상을 인식할 수 있다. 여기서, 영상으로부터 고유벡터를 구하는 방법은 우선 식(1)과 같이 M개의 학습영상에 대한 벡터집합  $x_n$ 의 평균벡터  $m$ 를 구한 후 식(2)와 같이 각 벡터집합과 평균벡터의 차이를 이용하여 공분산 행렬 C을 계산한다. 공분산 행렬은 고유값  $\lambda$ 와 고유벡터  $\mu$ 를 구하는데 사용되며, 고유벡터를 재배열하면 M개의 고유영상을 얻을

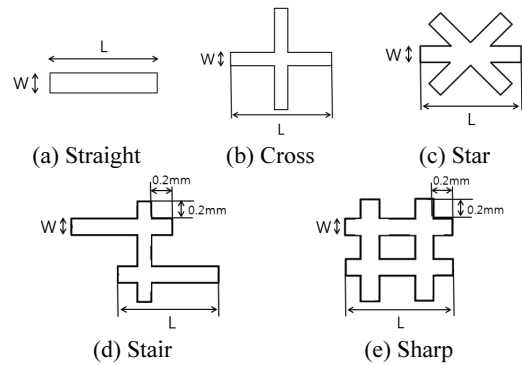


Fig. 1 Shape of micro cracks machined




Fig. 2 Flow chart of PCA algorithm

수 있다. 따라서 학습영상에 대한 평균벡터, 고유벡터와 입력영상에 대한 벡터집합  $x_{test}$ 을 식(3)을 이용하여 얻은 가중치  $y$ 로 유클리디안 거리를 비교하여 영상인식을 할 수 있다.

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

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

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

### 2.2 주성분분석에 의한 마이크로 크랙 분류

주성분분석에 의한 실리콘 웨이퍼 마이크로 크랙 분류실험에 앞서 실험의 모의성 및 편의성을 위해 Fig. 1에 나타난 것과 같이 폭(W ; width) 75, 125, 175 $\mu$ m와 길이(L ; length) 1000, 1250, 1500, 1750 $\mu$ m의 12가지 크기를 가진 직선(straight), 십자(cross), 별(star) 형태와 폭 100 $\mu$ m와 길이 1000, 1250, 1500, 1750 $\mu$ m의 4가지 크기를 가진 계단(stair), 샵(sharp) 형태로 총 44개의 크랙시편을 가공하였다. 또한 실리콘 웨이퍼 마이크로 크랙을 검출하기 위해 구성된 근적외선 광학계로 가공된 시편의 근적외선 영상을 획득하였다. 하지만 근적외선 영상은 마이

Table 1 Eigen values of learning images

No	Eigen value	No	Eigen value
01	34652.76	02	62517.54
03	65060.54	04	70984.67
05	82484.93	06	92409.86
⋮	⋮	⋮	⋮
43	11687882	44	1.68E+09

Table 2 Eigen vectors of learning images

Eigen vector \ No	No			
	1	2	...	44
1	0.018565	-0.00225	...	0.012606
2	0.018639	-0.00244	...	0.023159
3	0.018765	-0.00281	...	0.011571
4	0.018842	-0.00167	...	0.011177
⋮	⋮	⋮	⋮	⋮
3500	0.014662	-0.00544	...	-0.03302

크로 크랙의 경계선이 뚜렷하지 않고, 잡음을 포함한 저대비 영상이기 때문에 전처리 과정으로  $\lambda_f=0.25$ ,  $K=15$ ,  $t=5$ ,  $\alpha=0.3$  조건의 비등방 확산 필터<sup>8,9</sup>를 적용하여 잡음제거 및 마이크로 크랙의 경계선을 강조하였다.

Fig. 2와 같이 주성분분석에 의한 학습방법은 다음과 같다. 학습영상으로 가공된 마이크로 크랙 시편에 대한 44개의 근적외선 영상을 벡터집합으로 구성한다. 이 때 각 영상의 크기를 70×50픽셀로 편집하였으며 크랙은 영상 중앙에 위치하도록 하였다. 다음으로 식(1)을 이용하여 학습영상에 대한 평균벡터를 계산하고, 식(2)을 이용하여 Table 1, 2와 같이 공분산 행렬로부터 고유값, 고유벡터를 구한다.

입력영상으로 44개의 학습영상과 차이를 주기 위해 시계방향으로 3, 5, 10으로 회전한 132개의 영상을 식(3)을 이용하여 고유벡터와 입력영상으로부터 가중치를 구한 뒤 유클리디안 거리가 최소인 영상을 도출하였다. 그 결과 132개의 입력영상에 대한 분류율은 Table 3에서 보여준다. 따라서 132개의 입력영상에 대한 평균분류율은 24.24%로 나왔다. 하지만 각 형태에 대한 크기분류율(DCS ; Dimension Classification rate according to Shape)은 직선형은 19.4%, 십자형은 2.8%, 별형은 5.6%로 저조하였지만 계단형은 83%, 삼형은 100%로 우수하였다. 이와 같이 마이크로 크랙의 형태에 따라 분류율이 크게 차이가 난 이유는 가공한 직선, 십자,

Table 3 Classification rate of micro cracks using PCA

Shape	Classification $\epsilon$ (%)		
	Total	DCS	SC
Straight	24.24	19.4	100
Cross		2.8	22.2
Star		5.6	27.8
Stair		83	100
Sharp		100	100
Average $\epsilon$ (%)		-	42.2

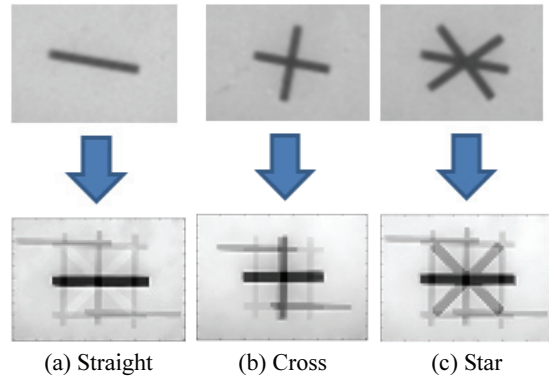


Fig. 3 Reconstructed images for near-infrared input images

별 형태의 결함의 크기가 폭에 따라 길이가 중복되기 때문에 학습과정 중 평균영상에서 마이크로 크랙의 각 크기가 나타나지 않기 때문이라고 판단하였다. 또한 마이크로 크랙의 크기가 아닌 형태(SC ; Shape Classification rate)만을 분류하였을 때는 직선형은 100%, 십자형은 22.2%, 별형은 27.8%, 계단형은 100%, 삼형은 100%의 분류율을 나타낸다. 그 이유는 Fig. 3의 입력영상에 대한 재구성된 영상을 통해 확인하였다. (a)의 입력영상이 직선인 경우 재구성된 영상에서도 직선으로 나오지만, (b, c)와 같이 입력영상이 십자와 별인 경우 재구성된 영상은 본래의 형태에 대한 잔상은 있지만 직선이 뚜렷하게 나온다. 이는 십자와 별 형태의 학습영상에 직선형이 포함되어 직선에 대한 성분벡터가 크기 때문이다. 따라서 주성분 분석에 의한 마이크로 크랙 분류는 형태와 크기에 대한 분류보다 마이크로 크랙의 형태만 분류하는 것이 타당하기 때문에 마이크로 크랙의 크기를 분류할 수 있는 또 다른 방법을 보완해야 한다. 따라서 본 연구에서는 신경회로망을 적용하여 실리콘 웨이퍼 마이크로 크랙의 분류를 시도하였다.

### 3. 신경회로망을 이용한 실리콘 웨이퍼의 마이크로 크랙 분류

#### 3.1 신경회로망 개념

신경회로망은 대용량의 복잡한 데이터를 분석하는 동시에 데이터간의 유사성 또는 데이터의 특성을 학습하고, 학습된 특성으로 기존 데이터와 유사한 새로운 문제를 해결할 수 있다. 본 연구에서는 입력층과 출력층 사이에 한 개 이상의 은닉층(hidden layer)으로 이루어진 다층 퍼셉트론(multi-layer perceptron)을 이용한 오류역전파(back-propagation) 알고리즘<sup>10,11</sup>으로 실리콘 웨이퍼 마이크로 크랙을 분류하였다.

오류역전파의 계산은 입력층에 들어온 입력값의 가중합을 활성화함수를 통해 적절한 반응을 출력하게 된다. 여기서 입력값의 가중합은 식(4)와 같다. NET<sub>j</sub>는 j번째 출력에 들어오는 외부자극의 가중합을 의미하며, x는 외부자극, w는 출력과 x사이의 연결강도를 의미한다. 이때, 출력의 반응 값은 식(5)에 나타낸 시그모이드(sigmoid) 함수를 사용한다.

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

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

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

오류역전파 알고리즘에 의한 학습은 신경망의 전 방향으로 계산된 값과 학습을 위한 목표값을 비교하여 오차의 제곱 합이 최소로 할 수 있도록 연결강도를 조정하게 되며, 오차가 일정 수준 이하가 될 때까지 반복한다. 이 때 연결강도의 조정은 식(6)을 이용한다. 여기서 η는 학습률, δ는 현재 층의 오차, o는 이전층의 활성화값이다

#### 3.2 신경회로망에 의한 마이크로 크랙 분류

실리콘 웨이퍼 마이크로 크랙을 분류하기 위해 근적외선 영상을 기반으로 특징을 추출하였다. 특징추출 방법으로 MIL(matrox image library)에서 제공하는 인스펙터(Inspector)의 블랍(blob)을 사용하였다. 블랍은 영상내의 픽셀(pixel) 중 다른 정보를 가진 픽셀영역을 추출하여 분석을 통해 여러 정량적인 특징값을 제시해준다. 따라서 크기에 대한 마이크로 크랙의 특징으로 크기가 증가할수록 특

Table 4 Feature values according to shape and size of micro cracks

Shape	Size(W-L)	A	P	...	CP
Straight	75-1000 $\mu\text{m}$	43	47.41	...	2
	75-1250 $\mu\text{m}$	54	58	...	2
	75-1500 $\mu\text{m}$	64	69.41	...	2
	75-7500 $\mu\text{m}$	68	80.83	...	2
:	:	:	:	:	:
Sharp	100-1000 $\mu\text{m}$	205	114.63	...	24
	100-1250 $\mu\text{m}$	250	190.63	...	24
	100-1500 $\mu\text{m}$	295	232.63	...	24
	100-1750 $\mu\text{m}$	370	274.28	...	24

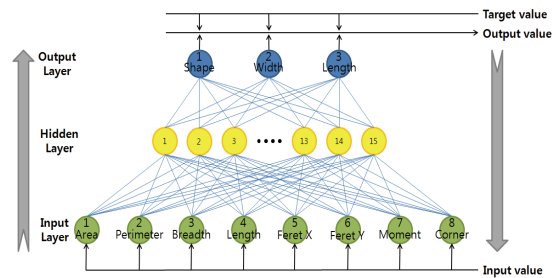


Fig. 4 Neural network configured to classification of the cracks

징값이 선형적인 형태를 보여주는 면적(A ; area), 둘레(P ; perimeter), 폭(B ; breadth), 길이(L ; length), 마이크로 크랙 영역의 최대 X길이(feret X), Y길이(feret Y), 모멘트(M ; moment)로 선정하였다. 하지만 형태가 다른 마이크로 크랙일지라도 크기에 따라 특징값이 중복될 수 있으므로 크기에 상관없이 마이크로 크랙의 형태를 분별할 수 있는 코너 포인트(CP ; corner point)를 특징으로 추가하였다. 선정된 8개의 특징값을 Table 4에서 보여준다.

본 연구에서 마이크로 크랙을 분류하기 위해 구성된 신경회로망은 Fig. 4와 같다. 입력층은 선정된 특징에 대한 8개의 노드(node), 출력층은 마이크로 크랙의 형태와 크기를 나타내는 폭, 길이에 대한 3개의 노드로 설정하였으며, 출력에 대한 목표값을 Table 5에서 보여준다.

은닉층은 각 층수에 따른 5, 10, 15, 20, 25개의 노드 중에서 오차와 반복수가 작게 나온 단일층으로 이루어진 15개의 노드로 지정하였다.

44개의 마이크로 크랙 시편 중 임의의 마이크로 크랙 5개를 선택하여 3번의 분류실험을 하였다. 실험 1은 직선형 75-1500 $\mu\text{m}$ , 십자형 125-1750 $\mu\text{m}$ , 별

Table 5 Target values for neural network

Shape	Size(W-L)	Target value		
		Shape	Width	Length
Straight	75-1000 $\mu$ m	0.1	0.1	0.1
	75-1250 $\mu$ m	0.1	0.1	0.4
	75-1500 $\mu$ m	0.1	0.1	0.7
	75-7500 $\mu$ m	0.1	0.1	1.0
:	:	:	:	:
Sharp	100-1000 $\mu$ m	1.0	1.0	0.1
	100-1250 $\mu$ m	1.0	1.0	0.4
	100-1500 $\mu$ m	1.0	1.0	0.7
	100-1750 $\mu$ m	1.0	1.0	1.0

Table 6 Output values obtained by to neural network learning

Classification Test No. 01				
Shape	Size(W-L)	Output		
		Shape	Width	Length
Straight	75-1500 $\mu$ m	0.0981	0.1487	0.9239
Cross	125-1750 $\mu$ m	0.3164	0.2988	0.9037
Star	75-1250 $\mu$ m	0.5282	0.6814	0.3588
Stair	100-1000 $\mu$ m	0.7693	0.9335	0.1378
Sharp	100-1250 $\mu$ m	0.9819	0.9927	0.9475
Classification Test No. 02				
Shape	Size(W-L)	Output		
		Shape	Width	Length
Straight	175-1250 $\mu$ m	0.0943	0.7159	0.2753
Cross	125-1500 $\mu$ m	0.3185	0.4578	0.7323
Star	75-1750 $\mu$ m	0.547	0.1537	0.9198
Stair	100-1250 $\mu$ m	0.7726	0.9978	0.2684
Sharp	100-1750 $\mu$ m	0.9878	0.9952	0.8179
Classification Test No. 03				
Shape	Size(W-L)	Output		
		Shape	Width	Length
Straight	125-1250 $\mu$ m	0.1068	0.3914	0.4874
Cross	75-1000 $\mu$ m	0.3167	0.0937	0.1193
Star	75-1500 $\mu$ m	0.5458	0.0889	0.8179
Stair	100-1500 $\mu$ m	0.7597	0.9991	0.9889
Sharp	100-1250 $\mu$ m	0.991	0.994	0.3528

형 75-1250 $\mu$ m, 계단형 100-1000 $\mu$ m, 삼형 100-1250 $\mu$ m 이며, 실험 2은 직선형 175-1250 $\mu$ m, 십자형 125-1500 $\mu$ m, 별형 75-1750 $\mu$ m, 계단형 100-1250 $\mu$ m, 삼형 100-1750 $\mu$ m 마지막으로 실험 3은 직선형 125-1250 $\mu$ m, 십자형 75-1000 $\mu$ m, 별형 75-1500 $\mu$ m, 계단형 100-1500 $\mu$ m, 삼형 100-1250 $\mu$ m을 추정하였으며, 나머지 39개의 마이크로 크랙을 연결강도 0.001 이내

Table 7 The error rates of between target and output

Classification Test No. 01				
Shape	Size(W-L)	Error (%)		
		Shape	Width	Length
Straight	75-1500 $\mu$ m	1.90	48.7	31.99
Cross	125-1750 $\mu$ m	2.65	25.3	9.63
Star	75-1250 $\mu$ m	3.96	2.66	10.3
Stair	100-1000 $\mu$ m	0.74	6.65	37.8
Sharp	100-1250 $\mu$ m	1.81	0.73	35.36
Average		2.21	16.81	25.01
		14.68		
Classification Test No. 02				
Shape	Size(W-L)	Error (%)		
		Shape	Width	Length
Straight	175-1250 $\mu$ m	5.70	2.27	31.18
Cross	125-1500 $\mu$ m	2.00	14.45	4.61
Star	75-1750 $\mu$ m	0.55	53.7	8.02
Stair	100-1250 $\mu$ m	0.31	0.22	32.9
Sharp	100-1750 $\mu$ m	1.22	0.48	18.21
Average		1.96	14.22	18.98
		11.72		
Classification Test No. 03				
Shape	Size(W-L)	Error (%)		
		Shape	Width	Length
Straight	125-1250 $\mu$ m	6.8	2.15	21.85
Cross	75-1000 $\mu$ m	2.55	6.30	19.3
Star	75-1500 $\mu$ m	0.76	11.1	16.84
Stair	100-1500 $\mu$ m	1.97	0.09	41.27
Sharp	100-1250 $\mu$ m	0.90	0.60	11.8
Average		2.6	4.05	22.21
		9.62		

로 학습하였다. 그 결과 학습을 통해 추정된 출력 값을 Table 6에 나타내며, 출력된 결과와 목표치간의 오차율을 Table 7에서 나타낸다. 3번의 분류실험 모두 15%이내의 오차율을 나타내지만, Table 7에 표시된 것과 같이 간혹 마이크로 크랙의 폭과 길이에 대한 오차가 30~50%를 나타낸다. 따라서 마이크로 크랙의 크기에 대한 큰 오차를 줄이기 위해 PCA와의 융합을 통해 특징을 추가 수행하고자 한다.

#### 4. 주성분분석과 신경회로망을 융합한 실리콘 웨이퍼의 마이크로 크랙 분류

주성분분석에 의한 마이크로 크랙 분류는 마이크로 크랙의 형태에 대한 분류는 가능하지만 마이크로 크랙의 크기에 대한 분류에는 취약하였다.

Table 8 The output value obtained through to fusion PCA and neural network by learning

Classification Test No. 01				
Shape	Size(W-L)	Output		
		Shape	Width	Length
Straight	75-1500 $\mu$ m	0.1005	0.1268	0.8096
Cross	125-1750 $\mu$ m	0.3264	0.4578	0.9837
Star	75-1250 $\mu$ m	0.5537	0.7143	0.4465
Stair	100-1000 $\mu$ m	0.7278	0.9504	0.1158
Sharp	100-1250 $\mu$ m	0.8159	0.9958	0.7419
Classification Test No. 02				
Shape	Size(W-L)	Output		
		Shape	Width	Length
Straight	175-1250 $\mu$ m	0.1022	0.7061	0.3215
Cross	125-1500 $\mu$ m	0.3213	0.4572	0.7224
Star	75-1750 $\mu$ m	0.538	0.0892	0.9269
Stair	100-1250 $\mu$ m	0.7671	0.9929	0.3357
Sharp	100-1750 $\mu$ m	0.9839	0.9991	0.8975
Classification Test No. 03				
Shape	Size(W-L)	Output		
		Shape	Width	Length
Straight	125-1250 $\mu$ m	0.0997	0.3812	0.4487
Cross	75-1000 $\mu$ m	0.3333	0.0864	0.1133
Star	75-1500 $\mu$ m	0.5571	0.0741	0.761
Stair	100-1500 $\mu$ m	0.7944	0.9982	0.8671
Sharp	100-1250 $\mu$ m	0.9876	0.9933	0.4315

또한 신경회로망에 의한 마이크로 크랙 분류는 마이크로 크랙의 폭과 길이에 대하여 30%가 넘는 큰 오차율을 보이는 경우가 있었다. 따라서 두 분류기법의 문제점을 보완하기 위해 주성분분석법과 신경회로망을 융합하여 실리콘 웨이퍼 마이크로 크랙을 분류하였다. 그 방법으로 기존 8개의 신경회로망의 입력층 노드에 주성분분석을 통해 얻어진 Table 1의 고유값을 추가하였다. 그 이유는 주성분분석을 이용한 마이크로 크랙 분류실험의 결과를 나타낸 Table 3에서 직선, 십자, 별 형태의 마이크로 크랙은 편집된 근적외선 영상에서 같은 위치에 폭과 길이가 중복되어 직선에 대한 주성분이 커져 분류율이 저조하였지만 마이크로 크랙이 중복되지 않는 계단과 삼 형태의 마이크로 크랙의 분류율이 좋은 것으로 보아 형태뿐만 아니라 크기에 대한 성분도 포함될 것이라 판단되기 때문이다.

주성분분석과 신경회로망을 융합한 마이크로 크랙 분류실험은 9개의 노드를 가진 입력층, 15개

Table 9 The error rates of between target and output

Classification Test No. 01				
Shape	Size(W-L)	Error (%)		
		Shape	Width	Length
Straight	75-1500 $\mu$ m	0.50	26.8	15.66
Cross	125-1750 $\mu$ m	0.43	14.45	1.63
Star	75-1250 $\mu$ m	0.67	2.04	11.63
Stair	100-1000 $\mu$ m	6.09	4.96	15.8
Sharp	100-1250 $\mu$ m	18.41	0.42	5.99
Average		5.22	9.73	10.14
		8.37		
Classification Test No. 02				
Shape	Size(W-L)	Error (%)		
		Shape	Width	Length
Straight	175-1250 $\mu$ m	2.20	0.87	19.63
Cross	125-1500 $\mu$ m	1.14	14.3	3.20
Star	75-1750 $\mu$ m	2.18	10.8	7.31
Stair	100-1250 $\mu$ m	1.02	0.71	16.08
Sharp	100-1750 $\mu$ m	1.61	0.09	10.25
Average		1.63	5.35	11.29
		6.09		
Classification Test No. 03				
Shape	Size(W-L)	Error (%)		
		Shape	Width	Length
Straight	125-1250 $\mu$ m	0.30	4.70	12.18
Cross	75-1000 $\mu$ m	2.55	13.6	13.3
Star	75-1500 $\mu$ m	1.29	25.9	8.71
Stair	100-1500 $\mu$ m	2.50	0.18	23.87
Sharp	100-1250 $\mu$ m	1.24	0.67	7.88
Average		1.58	9.01	13.19
		7.92		

의 노드를 가진 단일층의 은닉층 그리고 3개의 노드를 가진 출력층으로 Table 7의 신경회로망에 의한 마이크로 크랙 분류실험과 동일한 조건으로 진행하였다. 그 결과 출력값을 Table 8에서 보여주며, 목표치와 출력값간의 오차율을 Table 9에서 보여준다. 신경회로망을 이용한 마이크로 크랙의 분류실험에서는 마이크로 크랙의 크기에 대한 폭과 길이의 오차율이 30%넘는 것이 있었지만, 주성분분석과 신경회로망의 융합에 의한 마이크로 크랙의 분류에서는 오차율이 감소한 것을 확인할 수 있었다. 또한 Fig. 5에서 신경회로망과 주성분분석과 신경회로망의 융합을 이용한 3번의 분류실험에서 마이크로 크랙의 형태, 폭, 길이에 대한 평균 오차를 비교하면, 신경회로망만을 이용했을 때보다 3~7% 감소하였다. 여기서, 신경회로망을 이용한 분류 실험

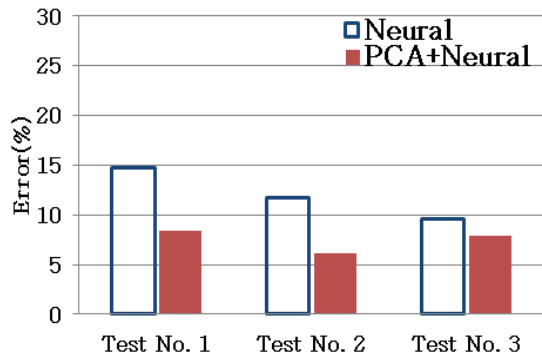


Fig. 5 The error comparison of neural network and the fusion of PCA and neural network

험에서는 은닉층의 최적설계를 통해 분류실험을 하였지만 주성분분석과 신경회로망의 융합에 의한 분류실험에서는 신경회로망을 이용한 분류실험과 동일한 조건으로 분류실험을 하였다.

### 5. 결론

본 연구에서는 주성분 분석과 신경회로망을 적용하여 실리콘 웨이퍼 마이크로 크랙을 분류하였다. 주성분 분석을 이용한 실리콘 웨이퍼 마이크로 크랙의 분류는 형태에 대한 분류 가능성을 나타냈으며, 신경회로망을 이용한 마이크로 크랙의 분류는 간혹 크기에 대한 폭과 길이에 대한 오차율이 30% 이상을 나타냈다.

두 분류 기법의 문제점을 보완하기 위해 주성분 분석과 신경회로망의 융합을 통한 마이크로 크랙을 분류하였다. 그 결과 주성분 분석을 통한 고유값을 신경회로망의 특징으로 추가함으로써 기존 신경회로망보다 평균 오차율이 대폭 감소하는 것을 확인하였다.

실리콘 웨이퍼 마이크로 크랙의 실제 시편의 확보가 충분히 이루어지고, 주성분분석과 신경회로망의 융합방법에 대한 은닉층등의 변수 최적설계가 이루어진다면 마이크로 크랙의 분류결과는 향후 더 좋아질 것이라 예상된다.

### 후 기

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

### REFERENCES

1. 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.
2. 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.
3. Ko, S.-S., Liu, C.-S., and Lin, Y.-C., "Optical Inspection System with Tunable Exposure Unit for Micro-Crack Detection in Solar Wafers," Optik-International Journal for Light and Electron Optics, Vol. 124, No. 19, pp. 4030-4035, 2013.
4. Yeon, J. and Kim, G., "Investigation of Laser Scattering Pattern and Defect Detection based on Rayleigh Criterion for Crystalline Silicon Wafer Used in Solar Cell," J. Korean Soc. Precis. Eng., Vol. 28, No. 5, pp. 606-613, 2011.
5. Byelyayev, A., "Stress Diagnostics and Crack Detection in Full-size Silicon Wafers using Resonance Ultrasonic Vibrations," Ph.D. Thesis, Department of Electrical Engineering, University of South Florida, 2005.
6. Dallas, W., Polupan, O., and Ostapenko, S., "Resonance Ultrasonic Vibrations for Crack Detection in Photovoltaic Silicon Wafers," Measurement Science and Technology, Vol. 18, No. 3, pp. 852-858, 2007.
7. 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.
8. Seo, H. J. and Kim, G. B., "Optimal Parameter Selection of Anisotropic Diffusion Filter based on Design of Experiment for Silicon Wafer Crack Detection," J. Korean Soc. Precis. Eng., pp. 905-906, 2014.
9. Tsai, D.-M., Chang, C.-C., and Chao, S.-M., "Micro-Crack Inspection in Heterogeneously Textured Solar Wafers using Anisotropic Diffusion," Image and Vision Computing, Vol. 28, No. 3, pp. 491-501, 2010.
10. Lee, D., Hong, S., Cho, S., and Joo, W., "A Study on the Pattern Recognition of Hole Defect using Neural

- Networks,” J. Korean Soc. Precis. Eng., Vol. 20, No. 2, pp. 146-153, 2003.
11. Pal, S. K. and Mitra, S., “Multilayer Perceptron, Fuzzy Sets, and Classification,” IEEE Transactions on Neural Networks, Vol. 3, No. 5, pp. 683-697, 1992.