

# 특징점 기반의 머신러닝 기술을 이용한 OLED 결함 분류 기술

## I. 서론

머신비전 기술은 자동화 검사장비에서 영상을 이용하여 결함을 검출하고 분류하는 기술을 말한다. 현재 대부분의 머신비전 검사장비는 결함검출에 초점이 맞춰져 있으며 결함분류는 필요한 기능이긴 하지만 우선순위에 밀리는 경향이 있다. 머신비전에서 결함을 분류하여 분석하면 전반적인 공정에서 문제되는 부분을 파악하여 개선할 수 있는 장점이 있다. 머신비전을 이용한 검사장비는 다양한 제품에 따라 장비 구성이 달라지고 검사하는 품목에 따라서도 달라지기 때문에 단일 분류기로 모든 것을 해결하기는 어렵고 여러 가지 분류기들을 복합적으로 결합하여야만 좋은 결과를 도출할 수 있다. 기존의 연구들을 살펴보면, 대부분의 논문들은 support vector machine (SVM), k nearest neighborhood (KNN)을 이용하여 다양한 형태의 특징들을 구성하여 분류하는 구조를 가지고 있다<sup>[1-4]</sup>. 본 연구에서는 Organic Light Emitting Diode (OLED) 검사장비에서 다중구조 분류기를 이용하여 결함을 분류하는 기술을 제안한다. 실험결과로부터 제안한 특징선택기술과 다중 분류기는 1차분류기에서 93%이상 2차분류기에서 85%이상의 결과를 나타내는 것을 확인하였다. 본 논문의 구성은 다음과 같다. 2장에서는 OLED 결함분류 기술에 대해 설명하고 3장에서는 실제 데이터를 이용하여 분류한 결과에 대해 분석하고, 4장에서 결론 및 향후연구에 대해 서술한다.



최학남  
인하대학교 정보통신공학과



김학일  
인하대학교 정보통신공학과

## II. OLED 결함 분류 기술

### 1. OLED 결함 종류 및 조명환경

OLED 디스플레이는 <그림 1>과 같이 다중구조로 구성된다. 최상단


에 글래스가 있고 그 아래로 다양한 레이어들이 있는데 이중 하나라도 불량이면 전체 불량이 되기 때문에 표면검사 장비에서는 다양한 불량들을 효과적으로 검출할 수 있도록 조명과 카메라를 구성하여야 한다.

OLED 디스플레이의 결함은 크게 두 그룹으로 나뉘게 되는데 하나는 글라스 결함(glass defect) 이고 다른 하나는 셀 결함(cell defect)이다. 결함들은 굽힘, 오염, 머리카락, 먼지, 액넵침과 같은 형태로 나타나게 되는데 굽힘과 같은 결함은 실제결함(Genuine defect)라고 하고, 머리카락, 먼지 등과 같이 에어로 불어내면 사라지는 불량들은 거짓결함(Fake defect)라고 한다. 글라스 결함은 굽힘을 제외한 대부분 결함들은 거짓결함이고, 셀 결함은 대부분 내부결함으로 실제결함이다. <표 1>은 결함종류와 대응되는 코드 및 결함별 특성을 정리한 표이다. 표에서 G(Genuine)는 실제 결함을 나타내고 F(Fake)는 거짓 결함을 나타낸다.


다양한 결함들을 효과적으로 영상화하기 위하여 제품 특성 혹은 결함특성을 고려하여 조명과 카메라를 설계해야 하는데, 본 연구에서는 <그림 2>와 같이 여섯 가지 조명 및 카메라 조건(S0~S5)에서 획득된 영상을 사용한다.

<표 1> defect type and corresponding codes


Type	Description	Code
Crack	the defects appear as breaks on the hidden layers	G00
Flaking	the defects caused by the non-fit between two layers	G01
Spacer broken	the defects caused by the breaks on the spacer inserted between layers	G02
Liquid overflow	the defects exist due to the liquid over-flowing on the layer surfaces. The liquid is unable to clean	G03
Liquid drop	Similar to G03 whereas the liquid is gathered as drops on the layer surfaces	G04
Surface scratch	the defects represent the scratches on the layer surfaces	G05
Back pit	the holes and scratches on the below surface of the glass substrate, that can be imaged by only S2 illumination	G06
Pollution	the defects caused by easily cleanable pollution such as water on the layer surfaces	F00
Dust	the dust drops between the layers	F01
Artifact	some other solid artifacts such as hair, worsted.	F02



<그림 1> Layer structure of OLED display




<그림 2> Camera and illumination setups for defect imaging



<그림 3> Defect samples and corresponding mask of each defect type

## 2. 특징점 기반의 분류기술

본 연구에서는 OLED 디스플레이 결함의 특성에 따라 <그림 4>와 같이 다중 분류기를 설계한다. FG 분류기(1차 분류기)를 이용하여 거짓결함과 실제결함을 분류하고, Fake 분류기와 Genuine 분류기로 구성된 2차 분류기를 이용하여 세부 결함들을 분류하는 구조이다. FG,



〈그림 4〉 hierarchical structure of the classifiers

〈표 2〉 texture and shape features

Type	Name	Code	Definition	Description
Texture	Mean	T00	$T00 = \sum_{i=0}^{L-1} i \times p(h_i)$	Average intensity value in the ROI
	Standard deviation	T01	$T01 = \sqrt{\sum_{i=0}^{L-1} (i - T00)^2 \times p(h_i)}$	Standard deviation of intensity values in the ROI
	Mode	T02	$T02 = \max_{i=0 \sim L-1} h_i$	Peak in the histogram of the ROI
	Entropy	T03	$T03 = - \sum_{i=0}^{L-1} h_i \times \log(p(h_i))$	Represent the image's complexity and uncertainty.
	Contrast	T04	$T04 = \frac{\sum_{i=0}^{L-1} i \times (i - T00)^2 \times h_i}{\ R\ }$	Describe the grey level differences in the ROI
	Skew-ness	T05	$T05 = \sum_{i=0}^{L-1} \left( \frac{h_i - \bar{h}}{\sigma_h} \right)^3$	Measure the asymmetry of the histogram
	Kurtosis	T06	$T06 = \sum_{i=0}^{L-1} \left( \frac{h_i - \bar{h}}{\sigma_h} \right)^4$	Measure the "peakedness" of the histogram distribution
	Sum of gradient	T07	$T07 = \sum_{i=0}^R \nabla I$	Sum of edge intensity of the ROI
Shape	Aspect ratio	S00	$S00 = \frac{H_B}{W_B}$	Ratio of the height and width of a blob
	Roundness	S01	$S01 = \frac{4\pi A_B}{P^2}$	Measure the circularity of the blob
	Number of blobs	S02	$S02 = N_B$	Total number of blobs
	Rectangularity	S03	$S03 = \frac{A_B}{A_R}$	Ratio between the area of the blob and the area of the bounding box of the blob
	Compactness	S05	$S05 = \frac{A_B}{P^2}$	Measure the degree to which a blob is compact

Fake, Genuine 분류기에는 KNN, SVM, RF(Random Forest)와 같은 다양한 분류기들이 적용될 수 있는 구조이다.

본 연구에서는 결함 분류에 초점을 맞추었기 때문에 결함검출은 되었다고 가정한다. 사용된 데이터는 〈그림 3〉과 같이 결함영역이 검출된 영상이다. 〈그림 3〉은 〈표 1〉에서 설명된 G00~G06, F00~F02 불량에 대한 샘플영상을 나타내고, 이진 영상은 분할된 결함영역을 나타낸다. 결함영역 분할은 Otsu 이진화 기법을 이용하여 검출하였다.

결함영역 영상과 이진화 된 마스크 영상을 이용하여 결함의 특징들을 추출한다. 사용된 특징들은 〈표 2〉와 같다. 특징들은 관심영역내의 평균, 분산, 엔트로피, 컨트라스트 등과 같은 텍스처 기반의 특징점과, 관심영역의 높이와 너비의 비를 나타내는 aspect ratio, 원형인지 사각

형진지를 판단할 수 있는 roundness, 블립의 개수, 관심영역 내에서의 결함의 면적들이 차지하는 비율을 확인할 수 있는 compactness 특징 등과 같은 기하학적 특징이 있다. 텍스처 특징은 영상의 밝기정보를 이용한 특징이고, 기하학적특징은 모양이나 면적으로부터 얻어지는 특징이다.


본 연구에서는 위에서 언급된 특징들 외에도  $0, \frac{\pi}{5}, \frac{2\pi}{5}, \frac{3\pi}{5}, \frac{4\pi}{5}$  방향특성을 가지는 다섯 개의 Gabor 특징과 일곱 개의 Hu moment<sup>[5]</sup> 특징들을 포함하여 총 24개의 특징들로 특징벡터를 구성하였다.

위에서 정의한 24개의 특징들은 서로의 장단점을 가지고 있지만 본 연구에서 분류하고자 하는 결함에 대해서 어떻게 작용될지 알 수 없다. 따라서 본 연구에서는 특징선택 기술을 적용하여 유효하고 효과적인 특징들을 선택하여 사용하였다. 특징선택 방법은 흔히 Principle Component Analysis (PCA)<sup>[6-7]</sup>를 이용한 차원 축소방식과 Random forest<sup>[8]</sup>를 이용한 두 가지 방식이 있는데 본 연구에서는 주성분 분석을 이용하여 특징을 선택하였고, Random forest를 이용하여 분류계수(variable)를 선택하는 방식을 취하였다. Random forest를 이용한 분류계수 선택방식은 〈그림 5〉와 같이 샘플데이터를 랜덤하게 두 그룹으로 나누어서 특징점들의 중요도를 판단하여 최종적으로 중요한 트리노드에 있는 파라미터들을 선정하는 방식이다.


선택된 특징들을 이용하여 최종적으로 분류기를 적용하여야 하는데, 본 연구에서는 위에서 설명한 것과 같이 분류기는 KNN, SVM, RF 방법을 적용하였는데 그 외의 분류기를 사용하여도 무방하다.

KNN방식<sup>[9]</sup>은 가장 간단한 방식인데 학습데이터를 이용한 학습공간을 구성하고 새로운 데이터가 입력되면 특징벡터공간상에서 자기와 특정거리 내에 어떤 클래스의 데이터가 많은지를 판단하여 해당 클래스로 새로 입력된 데이터를 분류한다. KNN은 주변영역을 정하는 반지름의 크기의 영향을 많이 받는데 본 연구에서는 특징공간상에서의 반지름을 1로 설정하였다.


SVM<sup>[3-4]</sup>은 〈그림 6〉과 같이 특징벡터공간상의



〈그림 5〉 Random forest를 이용한 분류계수 선택 개념도



〈그림 6〉 Support vector machine concept



〈그림 7〉 Random forest 분류기의 개념도

support vector들에 의하여 두 집단을 최대한 잘 분류할 수 있도록 설계되었다. SVM 분류기는 선형, 비선형방식이 있지만 본 연구에서는 선형 방식을 취하였고, SVM에서 사용되는 C값은 다양하게 설정하여 테스트하였다. SVM에서 C 값을 크게 설정하면 〈그림 6〉의  $\rho$ 값에 해당하는 마진 값이 줄어들고, 작게 설정하면 마진 값이 증가하게 된다. 본 연구에서는 C값을 5로 설정하였다.

RF분류기는 트리구조의 분류기이다<sup>[8]</sup>. 〈그림 7〉과 같이 많은 트리들을 구성하여 통계학적으로 어떤 트리의 어느 루트에서의 분류결과가 좋은지를 판단하여 최종 분류기를 선택하는 방식이다. RF 분류기 사용 시 중요한 변수는 트리의 개수와 각각 트리의 깊이로 본 연구에서는 200, 15를 사용하였다. RF분류기는 학습시간이 상대적으로 빠르고 레이블 노이즈에 강인하고 멀티 클래스 분류에 효과적이며 고차원의 특징데이터에서 좋은 성능을 내는 장점이 있다.

### III. 실험결과

#### 1. 실험환경

본 연구에서는 OLED 디스플레이 검사장비에서 획득한 3,502장의 결합영상을 이용하였다. 결합의 종류는 총 10가지이고 그 중 7가지는 실제결합이고 나머지 3가지는 거짓 결합이다. 각 결합별 데이터 개수는 〈표 3〉과 같다. 본 연구에서는 Window 10 환경에서 Visual Studio 2010 (OpenCV2.4.9) 기준으로 알고리즘을 개발하고 테스트 하였다.

#### 2. 평가방법 및 실험결과

본 연구에서 제안한 다중구조 분류기에 대한 성능을 평가하기 위하여 분류율을 평균분류율(Average classification rate)과 전체 분류율(Total classification rate) 두 가지 방식을 사용하였다. 이 두 방식은 각 클래스별 데이터 개수가 같으면 결과도 같게 나오게 되는데 클래스별 데이터 개수가 틀릴 때에는 두 가지 결과를 다 볼 필요가 있다. 전체 분류율은 클래스와 상관없이 전체 데이터 중 정확하게 분류된 영상개수와 전체 데이터의 비를 나타내고, 평균분류율은 각 클래스별 분류율에 가중치를 주어 계산하는 방식으로 아래의 식 1과 같이 표현된다.

$$CR(\%) = \frac{1}{N} \sum_{i=1}^N w_i \cdot \frac{C_i}{T_i} \times 100 \quad (1)$$

〈표 3〉 결합별 데이터 샘플

Defect type	Total samples	Training	Testing
	3,502	1,748	1,754
G00	132	66	66
G01	105	52	53
G02	73	36	37
G03	371	185	186
G04	67	33	34
G05	594	297	297
G06	160	80	80
F00	313	156	157
F01	955	477	478
F02	732	366	366

〈표 4〉 최종 분류결과

1차 분류기	SVM (C=5)	KNN (K=1)	RF (MD=15)	RF (MSC=20)	RF (D)	RF (D)	RF (D)	KNN (K=1)	RF (MD=15)	RF -20	RF (D)	RF (D)
특징 선택	PCA -20	RF -20	RF -20	RF -20	RF -22	RF -22	ALL	RF -20	RF -20	RF -20	RF -22	ALL
2차 분류기	KNN (K=1)	KNN (K=1)	KNN (K=1)	KNN (K=1)	KNN (K=1)	KNN (K=1)	KNN (K=1)	RF -18	RF -18	RF -18	RF -18	RF -18
G2G	82.2	79.1	94.5	94.1	95.7	93.7	96	78.3	94.1	92.5	94.9	95.7
F2F	92.8	96.6	93.5	91.9	91.1	91.2	91.6	96.1	92.8	92.9	90.1	91
G intra	73.5	71.1	83	82.2	84.2	81.8	83.8	72.3	83	82.2	83.8	84.2
F intra	86.5	89.6	87	85.7	85.1	85.1	85.5	90.8	87.8	88.2	85.5	86.7
Average	80	80.35	85	83.95	84.65	83.45	84.65	81.55	85.4	85.2	84.65	85.45
Total	84.6	87	86.4	85.2	85	84.7	85.3	88.2	87	87.3	85.2	86.3

여기서 CR은 classification rate를 의미하고, N은 클래스의 개수,  $w_i$ 는  $i$ 번째 클래스 데이터 개수와 전체 데이터 개수의 비율을 나타내고,  $C_i$ 는  $i$ 번째 클래스에서 정확하게 검출한 데이터 개수를 나타내며,  $T_i$ 는  $i$ 번째 클래스의 전체 데이터 개수를 나타낸다.

〈표 4〉는 제안한 다중구조 분류기의 다양한 파라미터 세팅에 따른 결과들을 포함하고 있다. 1차 분류기는 FG분류기를 나타내고, 2차 분류기는 Fake 분류기와 Genuine 분류기를 나타내고, 특징선택은 사용된 특징선택 알고리즘을 나타낸다. 또한 G2G는 Genuine에서 Genuine으로 정확하게 분류된 결과를 나타내고, F2F는 Fake를 Fake로 정확하게 분류한 결과를 나타내고, G intra는 2차 분류기의 Genuine 분류기에서 정확하게 분류된 결과를 나타내고, F intra는 2차 분류기의 Fake 분류기에서 분류된 결과를 나타내고, Average는 평균 분류율을 나타내며 total은 전체 분류율을 나타낸다. 각 분류기의 괄호안의 수치들은 해당 분류기에서 사용된 파라미터를 나타내며 D는 Default 세팅을 말하는데 SVM 분류기의 C 값은 5이고, KNN의 k값은 1이며, RF의 Max Depth(MD)는 9, Min Sample Count(MSC)는 35, 트리의 개수는 200으로 세팅하였다.

〈표 4〉에서 보시다시피 1차 분류기의 분류율은 94%, 92%의 좋은 성능을 보였고, 2차분류기의 분류율은 83%, 87%의 만족할 만 한 성능을 보였다. 이는 본 연구에서 디자인한 다중구조 분류기가 충분히 OLED 디스플레이 검사장비에 적용하여 OLED 디스플레이의 생산 공정과정

에서 발생하는 다양한 문제점들을 파악할 수 있는 유의미한 데이터를 제공해줌으로써 생산성 향상에 기여할 수 있음을 보여준다.

## VI. 향후 연구 및 결론

본 연구에서는 OLED 디스플레이의 검사장비에 사용 가능한 다중구조 결함분류 기술에 대해 제안하였다. 다중구조 분류기는 기존의 다양한 분류기들을 쉽게 조합하여 사용가능하게 해주는 장점이 있다. 따라서 다양한 제품에 따른 서로 다른 불량들의 특성에 맞게 분류기들을 선택하여 비교적 빠르게 기존의 시스템을 수정하여 실제 현장에 적용가능하다. 또한 특징선택기술을 적용하여 많은 특징들을 사용하더라도 유효하고 효과적인 특징들만 선택하여 사용가능한 장점이 있다.

본 연구에서 제안하는 방식은 기본적으로 특징들을 정의하고 적용하는 작업이 필요하다. 최근에 딥러닝 기술이 빠르게 다양한 분야에 적용되는데 Convolutional Neural Network(CNN) 기술은 특징추출 및 분류를 동시에 처리해준다. 즉 특징들을 사용자가 디자인 할 필요가 없는 구조이다. CNN은 대용량 영상이 있으면 아주 좋은 성능을 보장해주지만 특정제품의 불량영상들을 다량 보유하기는 현실적으로 어렵다. 하지만 적은 데이터로 학습할 수 있는 다양한 Data Augmentation 방법들이 개발되고 있어 향후 이러한 기술을 불량 검사장비에 적용해볼 필요가 있다.



### 참고문헌

- [1] Lim, D., D.-G. Seo, and D. Jeong. Defect classification for the inspection of TFT LCD glass, 2005.
- [2] Kang, S., et al. Automatic defect classification of TFT-LCD panels using machine learning, in Industrial Electronics, 2009. ISIE 2009. IEEE International Symposium on, 2009. IEEE.
- [3] Mitchell, T.M., Machine learning. 1997. Burr Ridge, IL: McGraw Hill, 1997. 45.
- [4] Burges, C.J., A tutorial on support vector machines for pattern recognition. Data mining and knowledge discovery, 1998. 2(2): p. 121-167.
- [5] Hu, M.-K., Visual pattern recognition by moment invariants. Information Theory, IRE Transactions on, 1962. 8(2): p. 179-187.
- [6] Guyon, I. and A. Elisseeff, An introduction to variable and feature selection. The Journal of Machine Learning Research, 2003. 3: p. 1157-1182.
- [7] Jolliffe, I., Principal component analysis. 2002: Wiley Online Library.
- [8] Genuer, R., J.-M. Poggi, and C. Tuleau-Malot, Variable selection using random forests. Pattern Recognition Letters, 2010. 31(14): p. 2225-2236.
- [9] Altman, N.S., An introduction to kernel and nearest-neighbor nonparametric regression. The American Statistician, 1992. 46(3): p. 175-185.



최학남

- 2000년 8월 연변대학교 응용수학 학사
- 2007년 2월 상명대학교 컴퓨터과학과 석사
- 2011년 8월 인하대학교 정보공학과 박사
- 2012년 3월~현재 인하대학교 정보통신공학과 조교수

〈관심분야〉  
머신비전, 병렬영상처리, 컴퓨터비전



김학일

- 1983년 서울대학교 제어계측공학과 학사
- 1985년 퍼듀대학교 전기컴퓨터공학과 석사
- 1990년 퍼듀대학교 전기컴퓨터공학과 박사
- 1990년~2001 인하대학교 자동화공학과 전임강사, 조교수, 부교수
- 2001년~현재 인하대학교 정보통신공학과 교수
- 2012년~현재 한국바이오인식협회 회장
- 2002년~현재 ISO/IEC JTC1-SC37 전문위원

〈관심분야〉  
영상처리, 컴퓨터비전, 딥러닝