

## SVM을 이용한 TFT-LCD 모듈공정의 불량 진단 방안

신 현 준<sup>†</sup>

<sup>†</sup>상명대학교 경영공학과

## A Fault Diagnosis Methodology for Module Process of TFT-LCD Manufacture Using Support Vector Machines

Hyun Joon Shin<sup>†</sup>

<sup>†</sup>Department of Management Engineering, Sangmyung University

### ABSTRACT

Fast incipient fault diagnosis is becoming one of the key requirements for economical and optimal process operation management in high-tech industries. Artificial neural networks have been used to detect faults for a number of years and shown to be highly successful in this application area. This paper presents a novel test technique for fault detection and classification for module process of TFT-LCD manufacture using support vector machines (SVMs). In order to evaluate SVMs, this paper examines the performance of the proposed method by comparing it with that of multilayer perception, one of the artificial neural network techniques, based on real benchmarking data.

**Key Words** : Fault diagnosis, Support vector machines, Classification, Artificial neural networks, Multilayer perception

### 1. 서 론

최근 들어 다양한 고객의 요구와 급변하는 시장의 변화는 공급자 중심의 생산관리에서 고객중심의 생산관리로의 변화를 이끌어 내고 있으며, 이런 변화와 함께 제조업체들은 제품의 제조방식과 공정이 복잡해지고 다양해짐에 따라 생산능력을 효율적으로 사용하는 데 더욱 어려움을 겪고 있다. 제조공정의 효율성을 방해하는 대표적인 요인으로는 정밀도를 요구하는 불량 진단(fault diagnosis), 불량발생으로 인한 재작업(rework), 순서의존적인 작업준비시간(sequence dependent setup times)과 작업투입시점(release times) 및 주문생산 방식(make-to-order)에 따른 촉박한 납기(due-dates) 등을 들 수 있다. 이 가운데에서도 특히 재작업은 반도체(semiconductor)나 박막트랜지스터 액정표시장치(TFT-LCD)와 같은 하이테크 산업뿐만 아니라 PCB 생산 등의 대다수 장치산업에서도 중요한 이슈가 되고 있다.

제조업체가 경쟁력을 갖추기 위해 필요한 것은 고객의 요구사항을 만족시키는 것이고, 고객의 요구사항은 크게 두 부분으로 요약될 수 있다. 그 하나는 납기 내 적시 인도(delivery in time)이고 또 하나는 품질이다. 만일 고객 주문에 대한 납기 지연이 자주 발생하게 된다면 기업은 고객의 신용을 잃게 될 뿐만 아니라 그에 따라 시장에서의 점유율도 상실하게 된다. 그러므로 고객의 납기 만족을 생산관리의 최우선 목표로 삼아야 한다. 이와 함께 품질이 나빠지면 고객의 신뢰도가 떨어질 것이고 이는 수익 창출에 있어서 해가 될 뿐만 아니라 품질비용 및 기회비용이 증가한다. 또한 가공한 제품의 품질이 일정 기준에 미치지 못하게 된다면 이는 불량관정을 받아서 폐기되거나 재작업을 통해 양품을 만들어야 하기 때문에 추가 발생하는 직접비도 무시할 수 없다. 더욱이 제조공정상의 유무형의 부가치가 더해진 양품의 제품을 만약 불량품으로 오판하여 해당 lot을 폐기하거나 전체 lot을 전수 검사하게 됨으로써 입는 손해는 제조현장에서 최소화해야 할 당면과제이기도 하다. 따라서 정확한 불량 유무 판정 및 진단을 통해 품질비용을 최소화하는 방법론의 개발이 필요하다.

<sup>†</sup>E-mail : hjshin@smu.ac.kr

TFT-LCD 제조공정 중 후반 조립공정에 속하는 Module의 Test공정은 품질검사를 통해 재작업 여부를 판단하는 공정이라 할 수 있다. 이 Test 공정은 전체 제조공정 중 상당한 부가가치가 더해진 거의 마지막 공정이라는 점을 감안할 때, 불량품 진단방법의 정확도 역시 품질비용을 최소화하는데 필수적이다. 따라서 본 논문에서는 support vector machine(SVM)을 이용한 불량 검출 기법을 통해 품질비용을 최소화하는 방안을 제시하고자 한다.

SVM 기법은 대용량 데이터 집합에 대한 분류 성능에서 우수성이 입증되었고, 응용분야로써 텍스트 집산화(categorization), 얼굴인식, 기계 비전분야에서의 개체 인식, 기업평가 등의 분야에 널리 사용되고 있다 [1-5]. 그러나 기계 또는 부속품 불량진단에 대한 기존 연구는 존재하나 제조공정의 불량 진단분야로는 선행 연구를 찾아보기 힘들다[6,7]. 본 논문은 다음과 같이 구성되어 있다. 2장에서는 본 논문의 주요 방법론인 SVM의 기본 작동원리에 대해 설명하고 3장에서는 본 논문이 제안한 Module 테스트 공정의 불량 진단을 위한 SVM 알고리즘에 대하여 기술하고 4장에서는 다양한 환경 하에서 실행된 실험 결과 및 분석을, 마지막으로 5장에서 결론 및 추후 연구 과제를 제시한다.


## 2. SVM 기법

SVM은 1998년 통계학자인 Vapnik에 의해 개발된 기계학습 기법으로, 입력공간(input space)과 관련된 비선형문제를 고차원의 특징공간(feature space)의 선형문제로 대응시켜 나타내기 때문에 수학적으로 분석하는 것이 수월하다[8,9]. 또한, SVM은 조정해야 할 모수의 수가 많지 않아 비교적 간단하게 학습에 영향을 미치는 요소들을 규명할 수 있다. 그리고 구조적위험(structural risk)을 최소화함으로써 과대적합문제에서 벗어날 수 있으며, 볼록함수(convex function)를 최소화하는 학습을 진행하기 때문에 글로벌 최적해를 구할 수 있다는 점에서 인공신경망(artificial neural network; 이하 ANN)보다 성능이 좋은 기계학습기법으로 주목 받고 있다.

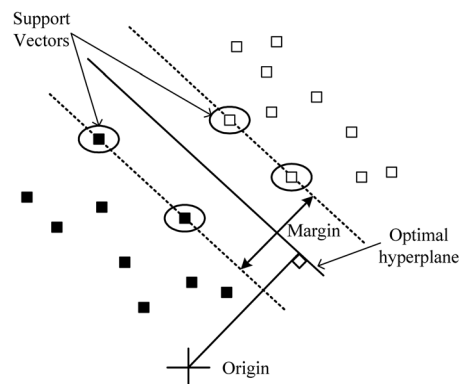
최근 몇 년간 SVM을 사용한 다양한 연구가 진행되었다. 그 예로서 SVM은 고장진단 예측, 주가예측, 영상인식 등에서 뛰어난 일반화 성능을 보여주었다. 본 연구와 가장 유사한 연구로는 SVM을 사용하여 기계의 고장진단을 예측한 연구를 들 수 있다[7]. 이 연구에서 SVM은 일반화에 있어서 ANN이나 판별분석과 같은 다른 분류기법과 비교하여 비슷하거나 더 우수한 성능을 나타낸 것으로 밝혀졌다. 본 연구에서는 이러한

연구배경을 토대로 SVM을 생산 제품의 불량여부를 검출하고 그 유형을 판단하는데 직접 적용하여 보기로 한다. 이를 위해 SVM에 대하여 간단히 설명하면 다음과 같다.

SVM에서는 학습데이터들을 서로 다른 두 개의 클래스로 분류할 때 분류의 기준이 되는 분리경계면(이하 hyperplane)을 학습 알고리즘을 이용하여 찾는다. 따라서 SVM은 입력벡터를 고차원의 특징공간(high dimensional feature space)으로 사상함수(mapping function)를 통해 사상시킨 후(Fig. 1(a) 참조), 두 클래스 사이의 거리 또는 마진(margin)을 최대화시키는 hyperplane을 찾는 것을 목적으로 한다. 여기서 hyperplane에 가장 근접한 훈련 데이터를 support vector라고 부른다. 일반적으로 선형 분류 가능한 데이터의 이진 분류에 있어서 Fig. 1(b)와 같이 두 개의 클래스를 분류할 수 있는 무수히 많은 hyperplane들 중 두 클래스 간 가장 가까운 점들과 hyperplane 간의 거리가 최대가 되는 최적(optimal) hyperplane을 구한다. 따라서, 최적으로 학습된 SVM 프레임워크 하에서 제조공정 중 생산된 제품의 품질 특성치들을 입력데이터로 사용한다면 제품의 양품과 불량품 여부를 효과적으로 구분할 수 있다.



(a) Mapping input space to feature space



(b) Linear separation via hyperplane

Fig. 1. Feature mapping and two-class separation.

### 3. SVM을 이용한 불량진단 알고리즘

$d$ 차 원공간 ( $x_i \in R^d$ ) 내의  $l$ 개의 점들로 표현 되는  $(x_1, c_1), \dots, (x_l, c_l), c_i \in \{-1, +1\}$  형태의 제조공정 고유의 품질특성치(학습 데이터)가 주어졌을 때 hyperplane에 대한 방정식은 다음과 같이 hyperplane에 직교하는 가중치 벡터  $\omega$ 와 바이어스(bias)로 표현된다.

$$(\omega \cdot x) + b = 0 \quad (1)$$

이때 거리를 최대화하기 위해서는 다음의 식 (2)를 최소화하면서 식 (3)을 만족해야 한다.

$$\Phi(\omega) = 1/2(\omega \cdot \omega) \quad (2)$$

$$\{(\omega \cdot x_i) + b\} c_i \geq 1 \text{ for } i=1, 2, \dots, l \quad (3)$$

여기서 식 (2)를 최소화하는 문제는 다음과 같이 라그랑주 승수(Lagrange multiplier)  $\alpha_i$ 를 포함한 Lagrangian 함수로 구한다.

$$L(\omega, b, \alpha) = 1/2(\omega \cdot \omega) - \sum_{i=1}^l [\{(\omega \cdot x_i) + b\} c_i - 1], \quad \alpha_i \geq 0, \forall i=1, \dots, l \quad (4)$$

식 (4)에 대해 Karush-Kuhn-Tucker(KKT) 조건을 적용하면 식 (5)와 같이  $\alpha$ 에 대한 수식으로 전개할 수 있으며 식 (6)을 만족하면서  $Q(\alpha)$ 를 최대화시키는 최적화문제가 된다. 이 때 학습 데이터에 대하여 이차계획(quadratic program-ming; 이하 QP) 문제의 해를 구함으로써  $Q(\alpha)$ 가 최대가 되는  $\alpha_i^*$ 를 계산한다.

Maximize

$$Q(\alpha) = \sum_{i=1}^l \alpha_i - 1/2 \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j c_i c_j (x_i \cdot x_j) \quad (5)$$

Subject to

$$\sum_{i=1}^l \alpha_i c_i = 0, \quad \alpha_i \geq 0, \quad \forall i=1, \dots, l \quad (6)$$

$Q(\alpha)$ 가 최대가 되는  $\alpha_i$ 를 이용하여 KKT 조건에서 유도된 식 (7)과 식 (8)에 대입하여 최적 가중치 벡터  $\omega^*$ 와  $b^*$ 를 구한다.

$$\omega^* = \sum_{i=1}^l \alpha_i^* c_i x_i^* \quad (7)$$

$$b^* = 1 - (\omega^* \cdot x_i^*) \text{ for } c_i = 1 \quad (8)$$

여기서  $x_i^*$ 는 support vector를 나타내고 최종적으로 임의의 입력 데이터(제품의 품질특성치)  $x$ 가 주어졌을 때, 다음 식과 같은 판별함수에 의해 분류된다.

$$f(x) = \text{sign}\{(\omega^* \cdot x) + b\} = \text{sign}\left\{\sum_{i=1}^l \alpha_i^* c_i (x_i^* \cdot x) + b\right\} \quad (9)$$

일반적으로 입력 데이터의 경우 명확하게 선형 분류가 되지 않는 경우가 대부분이며 본 연구의 제품 불량 검출 방법론에서도 예외가 아니다. 선형 분류가 불가능한 경우 커널함수  $K(x_i^* \cdot x) = \Phi(x_i^*) \cdot \Phi(x)$ 를 이용하여 고차원 공간으로의 mapping을 통한 고차원 특징공간에서의 선형 분류가 가능하다. 사상함수  $\Phi$ 를 이용하여 식 (9)의 입력 데이터  $x$ 를 커널함수  $K$ 의 형태로 대치할 수 있고 그 판별함수는 다음과 같다.

$$f(x) = \text{sign}\left\{\sum_{i=1}^l \alpha_i^* c_i K(x_i^* \cdot x) + b^*\right\} \quad (10)$$

위에서 서술한 SVM을 이용한 결과값 도출 과정을 도식화하여 정리해보면 다음 Fig. 2와 같다.

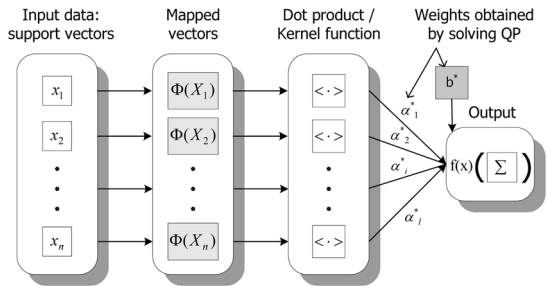


Fig. 2. Conceptual procedure for classification of SVMs.

## 4. 실험 및 결과분석

### 4.1. 실험데이터

본 논문의 대상이 되는 공정은 TFT-LCD 모듈라인 후반부의 불량유무 및 유형을 판단하는 테스트공정이다. LCD액정을 테스트한 후 얻어지는 정보는 일반적으로 Table 1과 같이 2 종류의 정보로 구성이 된다. 하나는 응답속도 오류, 선결함, 얼룩 등의 불량 유무 및 유형에 대한 정보가 포함되는 클래스 라벨(class label)이고, 또 하나는 화면 출력상태(visualization), 컬러(color), 전기신호(electric signal), 구동드라이버(driver) 등의 센서 값을 담고 있는 속성(attributes)이다. 불량률의 경우 둘 이상의 결함이 함께 나타나는 경향을 보일 수 있지만, 본 실험에서는 분류의 간결함을 위해 다중 결

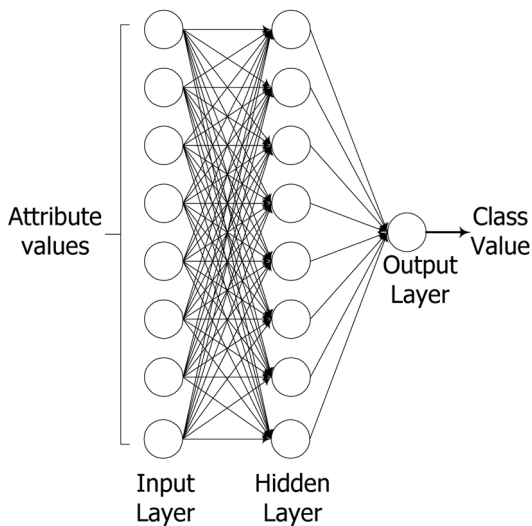
**Table 1.** Attributes and class classification of the experimental data set

Attributes	1. Classification (integer between 1 and 6) 2. Component number (integer) 3. Visual sensing 1 (integer) 4. Visual sensing 2 (integer) 5. Electric sensing 1 (real) 6. Electric sensing 2 (real) 7. Color sensing (integer) 8. Driver sensing (real)
Classes	1. Problems in visualization 2. Unstable response time 3. Faulty driver IC 4. Problems in electric signal 5. Color unbalance 6. Normal operating conditions

함의 경우는 배제하였다.

**4.2. 비교 알고리즘**

본 실험에서는 제안한 SVM의 성능을 평가하기 위한 비교 알고리즘으로 ANN 기법 중의 하나인 다층 퍼셉트론(multilayer perceptron; 이하 MLP)을 사용하도록 한다. 기존 문헌 고찰을 보면 MLP는 그 동안 복잡한 환경의 불량 진단을 위해 성공적으로 사용되어왔다고 알려져 있다[10]. 본 실험의 MLP는 입력층, 은닉층 그리고 출력층으로 구성되어 있다(Fig. 3 참조). 입력층은 Table 1의 속성(attributes)과 같이 8개의 뉴런을 포함하고 있으며 은닉층은 로지스틱 활성화함수(logistic



**Fig. 3.** Multilayer perceptron (MLP) for fault diagnosis.

activation function;  $\theta(\tau) = 1/(1+\exp(-\tau))$ 를 사용한다. 여기서  $\tau$ 는 가중 출력값의 합이다. 그리고 출력층은 Table 1에서 정의된 클래스(1~6) 값 중 하나를 산출한다.

**4.3. SVM 구성**

본 논문의 SVM을 적용하는데 있어서 중요한 요소 중 하나는 커널함수를 선택하는 것이다. 그러나 어떤 커널을 선택하여야 바람직한가는 주어진 제조 공정의 상황에 따라 다르다. 따라서 본 실험에서는 다음과 같은 커널함수들을 제품 불량 검출 알고리즘에 적용해 봄으로써 최적의 커널을 선택하도록 한다.

Linear:  $K(x_i, x_j) = x_i^T x_j$   
 Polynomial:  $K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$   
 Radial basis function (RBF):  
 $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0$   
 Sigmoid:  $K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r).$

여기서,  $\gamma, r, d$ 는 커널 모수으로써 제조공정의 품질검사에 필요한 특성치에 따라 설정할 수 있다. 본 실험은 Geisser S.[11]가 최초 제안한 교차검증(cross validation)을 이용한 사전실험을 통해 각 커널 모수값들을 Table 2와 같이 설정하였다.

**Table 2.** Parameter set for SVMs with different four kernels

Kernel for SVMs	$\gamma$	$r$	$d$
Linear	-	-	-
Polynomial	0.100	0	3
RBF	0.075	-	-
Sigmoid	0.100	0	-

**4.4. 학습(Training)**

MLP와 SVMs를 학습시키기 위해 총 220개의 데이터 set 중 70 set를 사용하였고, 학습 확인(validation)은 임의의 50 set를 선택하여 수행하였다. MLP 학습은 기본적인 역전파(back propagation) 알고리즘을 이용하여 진행하였다. SVMs를 학습하기 위해 본 실험에서는 LIBSVM(version 3.0) 소프트웨어를 MATLAB환경에서 이용하였고, 이는 <http://www.csie.ntu.edu.tw/~cjlin/libsvm>에서 다운로드 받을 수 있다.

**4.5. 결과 및 분석**

본 논문에서 제안한 SVM알고리즘의 성능을 4개의 커널함수들과 함께 평가하고 MLP와 비교한 결과는 Table 3과 같다. Table 3을 보면 RBF커널을 사용한

SVM 알고리즘이 학습과 테스트 성공률에 있어서 가장 우수한 결과를 보이는 것을 알 수 있다. MLP는 99.6%의 학습 성공률과 97.8%의 테스트 성공률을 보여 RBF이외의 다른 커널을 사용한 SVM 알고리즘보다 좋은 성능을 보였다. 이를 통해 적절한 커널함수 및 모수값 선정은 SVM 알고리즘의 성능에 영향을 미친다는 것을 파악하였다.

**Table 3.** Performance comparison between SVMs with different 4 kernels and MLP

Classifier	Type of Kernel	# of classes	#of inputs	Training success rate (%)	Test success rate (%)
MLP	-	6	220	99.6	97.7
SVMs	Linear	6	220	98.6	96.0
	Polynomial	6	220	99.5	97.5
	RBF	6	220	99.9	98.8
	Sigmoid	6	220	99.4	98.0

## 5. 결 론

TFT-LCD 제조과정 중 후 공정에 속하는 Module공정은 Array(Fab) 및 Cell 공정의 높은 부가가치 공정을 거쳐온 LCD액정의 조립과 QI(quality insurance)를 담당한다. 따라서 정확한 QI, 즉 결품 검사를 통한 재작업(rework) 여부 결정은 전체 TFT-LCD 제조공정의 품질비용을 최소화하는데 필수적이다. 이를 위해 본 논문은 Module 공정 중 테스트 공정의 LCD 액정 불량을 진단하기 위한 SVM 알고리즘을 제안하였다. SVM 알고리즘 성능의 우수성을 ANN 중 하나인 다층 퍼셉트론 MLP와의 비교를 통해 평가하였고, SVM 알고리즘은 4개의 커널함수들 중 RBF 커널과 함께 사용하였을 때 가장 우수한 성능을 보인다는 것을 실험결과 알 수 있었다. 본 논문에서 제안한 불량 진단을 위한 SVM 알고리즘이 재작업을 고려한 스케줄링 기법 등과 통합되어 사용된다면 Module 공정뿐 아니라 반도체 조립 라인의 테스트 공정 등에도 효과적으로 사용될 수 있을 것으로 기대된다.

## 감사의 글

이 논문은 2010년도 정부(교육과학기술부)의 재원으로 한국연구재단의 기초연구사업 지원을 받아 수행된 것임(2010-0005660).

## 참고문헌

- Müller K.R., Mika S., Ratsch G., Tsuda K., & Schölkopf B., "An introduction to kernel-based learning algorithms," IEEE Transactions on Neural Networks, Vol. 12, pp. 181-201, 2001.
- Dumais S., Platt J., Heckerman D., & Sahami M., "Inductive learning algorithms and representations for text categorization," J In: Proceedings of ACM-CIKM98, pp. 148-155, 1998.
- Osuna E., Freund R., & Girosi F., "Training support vector machines: an application to face detection," In: 1997 Conference on Computer Vision and Pattern Recognition, pp. 130-136, 1997.
- Roobaert D., & Hulle V.M., "View-based 3d-object recognition with support vector machines," In: 1999 IEEE Workshop on Neural Networks for Signal Processing, pp. 77-84, 1999.
- Park J., & Hong T., "The Prediction of DEA based Efficiency Rating for Venture Business Using Multi-class SVM," Asia Pacific Journal of Information Systems, Vol. 19, pp.139-155, 2009.
- Liu S., Wang Z., Zin H., & Hu S., "Support Vector Machine based fault diagnosis for an unmanned tandem helicopter," In: 2008 IEEE World Congress on Intelligent Control and Automation, pp. 1261-1265, 2008.
- Shin H.J., Eom D.H., Kim S.S., "One-class support vector machines-an application in machine fault detection and classification," Computers & Industrial Engineering, Vol. 48, pp. 395-408, 2005.
- Vapnik V., "The Nature of Statistical Learning Theory," 1995, Berlin:Springer.
- Schölkopf B., & Smola A., "Learning with kernels - support vector machines, regularization, optimization and beyond," 2002, Cambridge, MA:MIT Press.
- McCormick, A.C., & Nandi, A.K., "Real time classification of rotating shaft loading conditions using artificial neural networks," IEEE Transactions on Neural Networks, Vol. 8, pp. 748-757, 1997.
- Geisser, S., "The predictive sample reuse method with applications," Journal of the American Statistical Association, Vol. 70, pp. 320-328, 1975.

접수일: 2010년 11월 30일, 1차심사일: 2010년 12월 6일  
2차심사일: 2010년 12월 11일, 게재확정일: 2010년 12월 17일