

LS-SVM을 이용한 TFT-LCD 패널 내의 결함 검사 방법

A Defect Inspection Method in TFT-LCD Panel Using LS-SVM

최호형* · 이건희** · 김자근** · 주영복*** · 최병재*** · 박길흠* · 윤병주*

Ho-Hyung Choi*, Gun-Hee Lee**, Ja-Geun Kim**, Young-Bok Joo***,
Byung-Jae Choi****, Kil-Houm Park* and Byoung-Ju Yun*

* 경북대학교 전자전기컴퓨터학부

** (주)엘지 디스플레이

*** 연세대학교 컴퓨터과학과

**** 대구대학교 전자공학부

요 약

TFT-LCD 자동 검사 시스템에서 결함 검출을 위한 영상은 라인 스캔 카메라(line scan camera)나 에어리어 스캔 카메라(area scan camera)에 의해서 획득하게 된다. 그러나 임펄스 잡음과 가우시안 잡음, CCD 혹은 CMOS 센서의 한계, 조명 등의 영향으로 열화된 영상이 획득되며, 한도성 결함 영역을 인간의 육안으로 구분하기 어렵게 된다. 본 논문에서는 효율적인 결함 검출을 위해 특징 추출 방법과 결함 검출 방법을 제안한다. 특징 벡터로 웨버의 법칙을 이용한 결함 영역과 주변 배경 영역의 평균 밝기 차와 주변 배경 영역의 밝기 변화를 이용한 표준편차를 이용하며, 결함 영역 검출을 위해 추출된 특징 벡터를 이용하여 비선형 SVM을 적용한다. 실험 결과는 제안한 방법이 다른 방법들 보다 성능이 우수함을 보여준다.

키워드 : TFT-LCD, LS-SVM, 결함 검출, 경험적 데이터 학습, 특징 벡터 추출

Abstract

Normally, to extract the defect in TFT-LCD inspection system, the image is obtained by using line scan camera or area scan camera which is achieved by CCD or CMOS sensor. Because of the limited dynamic range of CCD or CMOS sensor as well as the effect of the illumination, these images are frequently degraded and the important features are hard to discern by a human viewer. In order to overcome this problem, the feature vectors in the image are obtained by using the average intensity difference between defect and background based on the weber's law and the standard deviation of the background region. The defect detection method uses non-linear SVM (Supports Vector Machine) method using the extracted feature vectors. The experiment results show that the proposed method yields better performance of defect classification methods over conveniently method.

Key Words : TFT-LCD, LS-SVM, Defect Detection, Empirical Data Training, Feature Vector Extraction

1. 서 론

최근 몇 년 동안 TFT-LCD (Thin Film Transistor Liquid Crystal Display) 산업은 빠르게 성장해 왔으며, FPD(Flat Panel Display) 시장은 점점 더 경쟁화 되고 관련 산업에서 디스플레이의 품질은 점점 더 문제시 되고 있다. 이러한 이유로 자동 검사 시스템은 제조 분야에서 중요한 분야로 대두 되고 있다. 대부분의 TFT-LCD 제조 산업에서는 인간의 시각 시스템을 이용한 검사를 수행하고 있으며, 여러 가지 문제점들을 갖고 있다. 즉, 인간의 시각 인식의 한계성과 높은 비용 등을 들 수 있다. 따라서 머신 비전(Machine Vision)을 이용한 자동 검사 시스템은 이러한 문제를 해결하기 위해 필요하다.

TFT-LCD 패널 상에서는 대표적으로 특정한 영역에 강하게 나타나며 먼지 등으로 인해 발생하는 점 이물, 넓은 영역에서 발생하는 얼룩(Stain or MURA), 외부의 자극에 의해 발생하는 스크래치성 결함 등을 포함한 결함들이 발생하게 된다. 이러한 결함들을 검사하기 위해 일반적으로 TFT-LCD 패널의 영상 촬영은 그림 1에서 보는 것과 같이 구성된다. 즉, TFT-LCD 패널을 촬영하기 위한 카메라부(일반적으로 라인 카메라를 사용), TFT-LCD 패널을 이송하기 위한 이송장치, 그리고 검사한 이물 정보를 저장하기 위한 서버 컴퓨터 등으로 구성되며, 그림 1과 같은 장비로 촬영된 영상을 기반으로 영상처리 알고리즘을 이용하여 영상 내의 결함 영역을 추출한다. 그러나 촬영된 영상의 가우스 잡음(Gauss noise)과 임펄스 잡음(impulse noise), 0~255의 범위를 갖는 CCD(Charge-Coupled Device sensor)센서 혹은 CMOS(현재는 CMOS를 이용하는 경우가 많음)와 같은 카메라 장치의 동적 폭의 한계성, 주변 환경의

접수일자 : 2009년 8월 9일

완료일자 : 2009년 11월 30일

영향(빈약한 조명성분) 등의 원인으로 결함 영역과 배경영역을 육안으로 식별의 어려움이 빈번하게 발생한다. 즉, FPD상에서는 결함 영역과 배경영역의 식별이 가능하나 촬영 시 여러 가지 요인(카메라 왜곡(camera distortion), CCD 혹은 CMOS의 동적 폭의 한계, 빈약한 조명성분 등)으로 인해 촬영된 영상에서는 식별이 어려운 경우가 발생한다. 이러한 이유로 촬영된 영상으로부터 결함 영역을 검출하는 과정에서 과검출로 인한 결함 후보 영역에 대해서 결함 영역인지 아닌지를 판단해야 하는 경우가 발생한다. FPD 내의 결함을 검출하기 위한 기존의 검출 방법[1][2]에서는 결함 영역의 평균 밝기 값과 주변의 평균 밝기 값의 차에 대한 문턱치를 설정하고 설정된 문턱치를 통해서 결함 영역인지 아닌지를 분류함으로써 결함 영역을 검출한다. 기존의 방법에서는 결함영역을 검출하기 위한 문턱치 결정이 성능을 좌우하는 중요한 요소이며, 이론에 근거한 결정 방법이 아닌 조작원(operator)의 경험에 의해 결정되는 경우가 많고, 일관적이지 못하다.




그림 1. 비전 검사 시스템의 구성도.

Fig. 1. Structure of automatic vision inspection system.

본 논문에서는 이러한 문제를 해결하기 위해 LS-SVM을 이용한 자동 결함 검출 방법을 제안한다. 제안하는 알고리즘은 영상 처리 알고리즘을 이용하여 추출한 결함 후보 영역들의 특징 벡터를 추출하며, 추출된 특징 벡터를 기반으로 머신 러닝(machine learning)을 근간으로 하는 LS-SVM (Least Squares Supports Vector Machine)을 적용하여 결함 영역의 특징 벡터 패턴 데이터를 이용하여 학습함으로써 보다 효과적으로 결함영역과 배경 영역을 분류하고 결함 영역을 검출한다. 제안한 방법에서 결함 후보 영역들의 특징 벡터를 추출하기 위해 웨버의 법칙(weber's law)[3]을 이용한 결함 영역과 주변영역의 평균 밝기 차 (average intensity difference)와 주변 영역의 밝기 변화를 이용한 표준 편차를 이용한다. 제안한 방법으로 추출한 특징 벡터는 결함 후보 영역들을 기반으로 수행하며, 결함 후보 영역과 주변 영역을 비교했을 때 평균 밝기 변화가 존재한다. 반면, 대조군으로써 결함이 아닌 배경 영역들은 주변 영역과 비교했을 때 평균 밝기 변화는 거의 일어나지 않는다. 따라서 제안한 방법은 위에서 언급한 것과 같은 특징을 이용하여 특징 벡터를 추출한다. 결함 영역을 이론에 근거한 일관적인 검출을 목적으로 특징 벡터 패턴을 이용한 자

동 검출함으로써 이전의 방법의 문제점들을 해결한다.

2. 제안한 방법

2.1 특징 벡터 추출

입의 물체의 특징 벡터는 형태, 크기, 장축과 단축 길이의 비율, 면적 등이 있으며, 그 물체를 가장 잘 나타낼 수 있는 것을 특징 벡터로 한다. 그러나 입의 물체에 대해 카메라를 이용하여 촬영할 경우 촬영 장비의 동적 폭의 한계, 주변 환경의 영향으로 인해 영상 정보를 잃어버리거나 인간의 시각 시스템에서 구분이 어려운 경우가 빈번하게 발생하게 된다. 이러한 이유로, 위에서 언급한 것과 같은 물체의 특징 벡터를 이용하기 힘든 경우가 발생한다. 이러한 문제들을 해결하기 위해 인간 시각 시스템에 기인한 웨버 법칙을 이용하여 결함 영역과 배경영역의 최소의 밝기 변화 혹은 결함영역의 평균 밝기와 배경영역의 평균 밝기의 차와 결함 영역 내의 표준 편차를 이용하여 영상의 특징 벡터를 추출한다.

웨버의 법칙[3]을 이용한 결함 영역의 특징 벡터 추출은 그림 2에서 보는 것과 같이 결함 영역의 평균 (μ_{dr})과 배경영역의 평균(μ_{br})의 차를 계산한 후 배경영역의 평균으로 나누어 줌으로써 획득되며 다음과 같다.

$$Feature0 = \frac{\mu_{dr} - \mu_{br}}{\mu_{br}} \quad (1)$$

그리고 또 다른 결함 영역의 특징 벡터를 추출하기 위한 방법은 표준 편차를 이용한 방법이며, 입력 영상 $f(x,y)$ 에 대해서

$$Feature1 = \sqrt{\frac{1}{N} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} (\mu_{dr} - f(x,y))^2} \quad (2)$$

$$\mu_{dr} = \frac{1}{N} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x,y) \quad (3)$$

으로 표현된다. 식(1)과 (2)를 영상의 특징 벡터로 한다.




그림 2. 결함 영역과 배경영역 결정

Fig. 2. Decision of defect and background region.

2.2 결함 영역 검출 방법

제안한 SVM방법을 이용한 검출방법은 추출한 영상의 특징 벡터를 이용하여 결함 영역 검출하는 방법이다. 이를 위해 추출한 벡터 패턴을 이용하여 학습하는 동안 결정함수의 파라미터를 찾는 것이다. 일반적인 검출 방법에서 있어서 과잉 적합의 위험성을 적게 하고 오류 없는 의사 결정 경계를 생성하는 것을 목적으로 한다. 이를 위해서 기존의 선형 SVM과 달리 소프트 마진(soft margin)기법을 도입한

다. 이와 같은 방법은 클래스가 선형으로 분리되지 않는 상황에도 유연하게 선형의 경계를 생성하도록 해준다. 선형으로 분리 되지 않는 상황을 해결하기 위해서 제한 조건에 양의 값을 가진 슬랙 변수(slack variable)를 추가하여 해결할 수 있다. 또한 제안한 방법에서 라그랑지안 승수를 구하기 위해 이중 문제는 제곱 프로그래밍(quadratic programming)을 사용한다. 결과적으로 제안한 LS-SVM을 사용함으로써 잡음을 줄일 수 있으며, 선형으로 분리 되지 않는 상황에서도 효과적으로 분류 할 수 있다.

가. 일반적인 SVM 방법(Standard Supports Vector Machine method)

최대 마진 트레이닝 알고리즘[4][5]은 A와 B클래스의 둘 중 하나에 포함된 n 차원의 패턴 벡터 x에 대한 결정 함수를 찾는 것이다. 트레이닝 알고리즘에서 입력 데이터는 n차원의 라벨 y_i에 대한 x_i 특징 벡터들의 p 집합이다. 즉,

$$(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_p, y_p) \quad (4)$$

$$\text{여기서, } \begin{cases} y_k = 1, & \text{if } x_k \in \text{class A} \\ y_k = -1, & \text{if } x_k \in \text{class B} \end{cases}$$

제안한 방법으로 추출한 영상의 특징 벡터를 이용하여 결함 영역을 검출한다. 이를 위해 추출한 벡터 패턴을 이용하여 학습하는 동안 D(x) 결정함수의 파라미터를 찾는 것이며, 결함 영역을 검출하기 위해서 결함 영역의 벡터 패턴을 이용한 트레이닝 후 알려지지 않는 파라미터는 다음의 규칙에 따라 예측된다.

$$\begin{aligned} x \in A, & \text{if } D(x) > 0 \\ x \in B, & \text{otherwise} \end{aligned} \quad (5)$$

여기에서 결정함수는 파라미터에서 선형적이어야 하며 벡터 x에 선형적선형의존성에 제한되는 것은 아니다. 이들 함수들은 직접적으로 혹은 두 개의 공간 등에서 사용할 수 있으며, 직접적인 공간의 표현은 퍼셉트론 결정함수와 동일하다. 즉,

$$D(x) = \sum_{i=1}^N w_i \phi_i(x) + b \quad (6)$$

여기에서 φ(x)는 벡터 x의 이전에 정의된 함수이며, w_i와 b는 결정함수의 조정 가능한 파라미터이다.

두 개의 공간에서 결정함수는 다음과 같은 형태를 갖는다.

$$D(x) = \sum_{k=1}^p \alpha_k K(x_k, x) + b \quad (7)$$

여기에서 계수 α_i는 조정하기 위한 파라미터들이며, x_k는 트레이닝 패턴이다. 라그랑지언의 평균에 의해서 두 개의 공간에 변환된다. 따라서 이를 수식적으로 표현하면 다음과 같다.

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{k=1}^p \alpha_k [y_k D(x_k) - 1] \quad (8)$$

$$\text{subject to } \alpha_k \geq 0, k = 1, 2, \dots, p$$

여기에서 α_k는 라그랑지 승수 Kuhn-Tucker 계수라

하며, 다음의 조건을 만족해야 한다.

$$\alpha_k (y_k D(x_k) - 1) = 0, k = 1, 2, \dots, p \quad (9)$$

$$\alpha_k > 0$$

즉, 경험적 데이터에 대한 경험적 손실을 최소화가 되는 경계 혹은 초평면(hyperplane)을 결정하기 위한 조건이다. 최적의 문제(optimal problem)는 함수 L(w, b, α)의 중심점을 찾는 것과 동일하며, 이 중심점이 w_i에 기대되는 L(w, b, α)의 최소이며, α(α_k > 0)에 기대되는 최대이다, 여기서 라그랑지안을 최소화하려면, L(w, b, α)를 w와 b에 대하여 미분하고 이 값을 0으로 놓고 풀어야 하며 다음과 같다.

$$\frac{\partial}{\partial w} = 0 \Rightarrow w^* = \sum_{k=1}^p \alpha_k^* y_k \phi_k \quad (10)$$

$$\frac{\partial}{\partial b} = 0 \Rightarrow \sum_{k=1}^p \alpha_k^* y_k \quad (11)$$

라그랑지 승수의 값은 모르므로 w와 b에 대한 해는 구할 수 없다. 만약 부등식 조건대신 등식만을 포함한다면, w, b, α_k에 대한 가능한 해를 구하기 위해 등식조건 N개의 식과 식(10), (11)을 사용할 수 있다. 등식 조건에 대한 라그랑지 승수는 어떠한 값도 가질 수 있는 자유 매개 변수이다. y_kD(x_k) = 1을 만족하는 패턴들은 주어진 패턴들이며 식(11)에 의하여 최대 마진에 대한 초평면의 조건인 w*는 주어진 패턴의 선형적인 조합이며, α* ≠ 0인 패턴들이다. 위의 최적화 문제를 푸는 것은 w, b, α_k 등 많은 수의 매개 변수들을 포함하기 때문에 매우 힘겨운 작업이다. 이 문제는 라그랑지언을 라그랑지 승수들만의 함수로 변환함으로써 간소화할 수 있다(이는 이중 문제(dual problem)로 알려져 있다). 이를 위해, 먼저 식(10)와 (11)을 식(8)로 대치하면 다음과 같은 최적화 문제의 이중 형태로 표현할 수 있다.

$$J(\alpha, b) = \sum_{k=1}^p \alpha_k - \frac{1}{2} \sum_{k,l} \alpha_k \alpha_l y_k y_l x_k \cdot x_l \quad (12)$$

여기에서 x_k · x_l은 두 벡터의 내적을 나타낸다. 고정된 바이어스 b에 대해서, α*는 α_k ≥ 0의 조건하에서 최대가 되는 J(α, b)에 의해서 획득된다. 결정함수의 결과는 다음과 같다.

$$\begin{aligned} D(x) &= w^* \cdot \phi(x) + b \\ &= \sum_k y_k \alpha_k^* K(x_k, x) + b \quad \alpha_k^* \geq 0 \end{aligned} \quad (13)$$

여기에서 주어진 패턴은 영의 값이 아닌 가중치의 합이다.

나. LS-SVM(Least Squares Supports Vector Machine)

트레이닝 데이터 셋 {x_i, d_i}_{i=1}^N이 주어졌을 때, x_i ∈ R^p는 p차원 입력 데이터와 d_i = y_i + z_i를 표현하며, d_i ∈ R은 출력의 스칼라 값이다. d_i는 잡음 z_i에 의해서 오염된 y_i 시스템의 출력을 표현한다. LS-SVM [6][7]의 목표는 y = f(x)을 구성하는 것이다. 이것을 정의할 때 아래와 같이 표현된다.

$$y = \sum_{i=1}^h w_i \phi_i(x) + b = w^T \phi(x) + b \quad (14)$$

$$w = [w_1, w_2, \dots, w_h]^T, \quad \phi = [\phi_1, \phi_2, \dots, \phi_h]^T$$

여기에서 $\phi(\cdot): R^p \rightarrow R^h$ 는 비선형적인 함수이며, 이는 보다 고차원(가능한 무한대)의 특징 벡터 공간(feature space)에 대응된다.

위에서 언급한 표준 SVM과 중요한 다른 점은 LS-SVM은 부등식조건 (inequality constraints) 대신에 등식조건 (equality constraint)을 사용하는 것과 리스트 스퀘어 코스트 함수(least squares cost function)를 사용하는 것이다. 최적의 문제와 등식조건들은 다음과 같다.

$$\min_{w, b, e} J_p(w, e) = \frac{1}{2} w^T w + C \frac{1}{2} \sum_{i=1}^N e_i^2 \quad (15)$$

$$\text{such that } e_i = y_i - [w^T \phi_k + b], i = 1, \dots, N$$

이것은 라그랑지언

$$\begin{aligned} L(w, b, e; \alpha) \\ = J_p(w, e) - \sum_{i=1}^N \alpha_i \{w^T \phi(x_k) + b + e_k - y_k\} \end{aligned} \quad (16)$$

으로 주어진다.

최적화를 위한 조건은

$$\begin{aligned} \frac{\partial L}{\partial w} = 0 &\rightarrow w = \sum_{k=1}^N \alpha_k \phi(x_k) \\ \frac{\partial L}{\partial b} = 0 &\rightarrow w = \sum_{k=1}^N \alpha_k = 0 \\ \frac{\partial L}{\partial e_k} = 0 &\rightarrow \alpha_k = C e_k, \quad k = 1, \dots, N \\ \frac{\partial L}{\partial \alpha_k} = 0 &\rightarrow w^T \phi(x_k) + b + e_k - y_k = 0, k = 1, \dots, N \end{aligned} \quad (17)$$

$C \in R^+$ 는 보다 유연한 해법과 트레이닝 오류사이에 교환하는 파라미터이며, 해법은

$$\begin{bmatrix} 0 \\ \vec{I} \end{bmatrix} \vec{I}^T \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (18)$$

$$y = \{y_1, y_2, \dots, y_N\}, \alpha = [\alpha_1, \alpha_2, \dots, \alpha_N],$$

$$\vec{I} = [1, \dots, 1], \Omega_{i,j} = K(x_i, x_j) = \phi^T(x_i) \phi(x_j)$$


이다. 여기서 $K(x_i, x_j)$ 는 커널을 나타내며, 그 결과는 다음과 같다.

$$y = \sum_{i=1}^N \alpha_i K(x, x_i) + b \quad (19)$$


3. 실험 결과

제안한 방법의 실험을 위해서 BLU (Back Light Unit) 상에 임의의 결함들을 발생시켰으며, 이러한 결함들을 검출하는 실험을 하였다. 실험에 사용하기 위한 임의로 발생시킨 결함은 그림 3과 같이 다양한 크기와 다양한 밝기 값을

갖는다. (a)는 BLU 영상 촬영 영상이며 (b)는 (a)의 내부의 결함 영역들을 표현하기 위해서 히스토그램 조정을 통해서 표현한 것이다. (b)에서 오른쪽 하단으로 갈수록 결함의 크기가 크고 배경 영역의 평균 밝기 값과 결함 영역의 평균 밝기 값이 차이가 많이 난다. 반면 왼쪽 상단으로 갈수록 반대의 경우이다.



(a)



(b)

그림 3. BLU상의 결함 (a) 원 영상 (b) 히스토그램 평활화된 영상

Fig. 3. Defects in BLU (a) Original image (b) result image of histogram equalization.

그림 4는 그림 3(a)의 좌측상단에 존재하는 특정 결함영역과 배경영역을 보여준다. (a)는 결함영역을 나타내며, 주변영역과 밝기 값의 차를 인간의 시각시스템으로 인지하기 어렵다. 결함 영역은 붉은 색 영역으로 표시하였다. 그러나 FPD상에서 인간의 육안으로 구분이 가능하다. (b)는 (a)의 한도 영상에 대해서 인간의 시각에 의해서 구분이 되도록 히스토그램 평활화 한 결과 영상이다. (c)는 그림 3의 영상 내에 있는 배경영역을 나타낸다. 제안한 방법은 (a)와 (b)에서 보는 것과 같은 결함 영역의 평균 밝기 변화와 그 주변 영역의 평균 밝기 변화의 차를 이용하여 특징 벡터를 추출하였다. 그리고 검출을 위한 대조군으로써 (c)를 사용하였

으며 (a)의 사각형의 영역과 동일한 위치의 평균밝기 값과 그 주변의 평균 밝기 값의 차를 구하였다. 이렇게 함으로써 (a)와 같은 결함 영역이 있는 영역에서는 평균 밝기의 차가 존재하지만 (c)와 같은 영역에서는 평균 밝기 차이가 존재하지 않는다. 그림 5는 그림 4의 배경영역과 결함 영역의 히스토그램 특성을 설명하는 것이며, 그림 5에서 y축은 영상의 밝기 값의 빈도수를 나타내고 x축은 영상의 밝기 값을 나타낸다. 배경영역과 결함영역에 가장 빈번하게 발생하는 밝기 값은 각각 128과 130이다. 따라서 이들의 차는 2이며, 이는 인간의 시각적으로 구분하기 어려울 뿐만 아니라 영상 처리 알고리즘을 적용하여 그 영상의 형태, 크기, 장축의 길이 등의 특징 벡터를 추출하기 어려움을 보여주고 있다.




그림 4. 결함 영역과 배경 영역 (a) 결함 영역 (b) (a)를 기반으로 한 히스토그램 평활화한 영상 (c) 배경 영역
 Fig. 4. Defect and background region (a) defect region, (b) result image of histogram equalization based on (a), and (c) background region




그림 5. 결함영역과 배경 영역의 히스토그램
 Fig. 5. Histogram of the defect and background region.

기존의 검출 방법에서는 결함 영역의 평균 밝기 값과 주변의 평균 밝기 값의 차에 대한 문턱치를 설정하고 설정된 문턱치를 통해서 결함 영역인지 아닌지를 판단하였으며, 이론에 근거한 결정 방법이 아닌 조작성의 경험에 의해 결정되는 경우가 많고, 일관적이지 못하다. 제안한 방법에서는 경험적 데이터 패턴을 기반으로 학습하여 결함영역을 자동 검출함으로써 문턱치 결정의 어려움들을 피할 수 있다. 표

1은 그림 3에서 설명한 방법을 기반으로 하여 제안한 방법에서 사용될 특징벡터들의 값을 추출한 결과 값을 보여준다. Feature0은 식(1)을 기반으로 얻은 값이며, Feature1은 식(2)을 근간으로 하여 측정된 값이다. 또한 표 1(a)은 결함 영역에 대해서 특징 벡터를 추출한 것이며, 표 1(b)은 배경 영역의 특징 벡터를 추출한 것이다. 표 1의 정량적 측정값을 비교했을 때 Feature1의 경우 대부분 비슷한 벡터 값을 나타내지만 반면에 feature0의 경우 제안한 방법으로 추출한 벡터 값은 존재하지만 배경 영역의 벡터 값은 거의 존재하지 않음을 볼 수 있다. 따라서 가정했던 결과를 만족하며 이러한 데이터들은 영상의 특징을 나타내는 특징 벡터를 잘 나타낼 수 있음을 표 1에서부터 알 수 있다.

표1. 결함영역과 배경영역에 대한 특징 벡터 추출 결과
 Table 1. Result of the feature vector extraction with the defect and background region

(a)	Feature0	Feature1	(b)	Feature0	Feature1
1	0.078055	2.2062	1	0.003841	2.175
2	0.070264	2.1874	2	0.001242	2.1773
3	0.063016	2.1673	3	0.001127	2.1745
4	0.054696	2.184	4	0.000131	2.1645
5	0.047428	2.1672	5	0.000336	2.1627
6	0.039085	2.1695	6	0.000331	2.1626
7	0.03108	2.1713	7	0.000838	2.1789
8	0.023871	2.1638	8	0.00039	2.1699
9	0.015965	2.1596	9	0.000287	2.1717

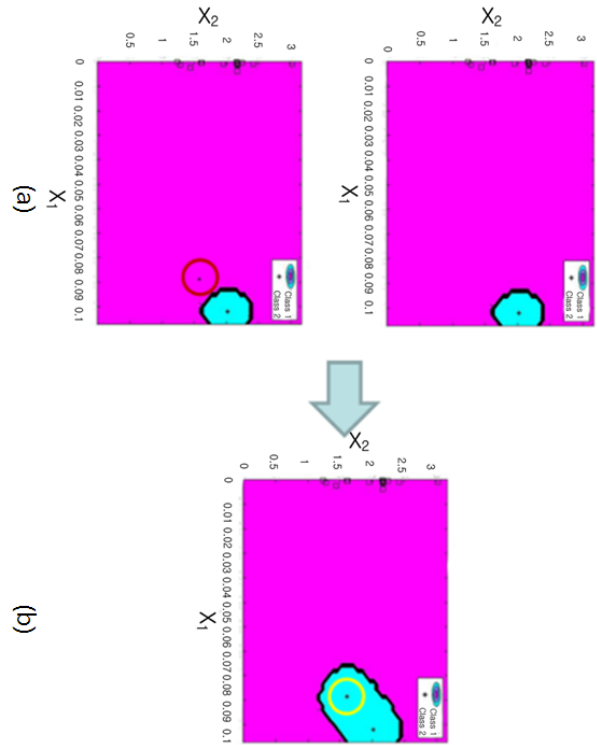


그림 6. 경험적 데이터 학습 결과
 Fig. 6. Training result of empirical feature data.

그림 6은 첫 번째 경험적 데이터가 입력되었을 때 LS-SVM을 이용한 결과와 두 번째 입력 데이터가 입력되었을 때의 결과를 보여준다. 첫 번째 입력 데이터를 기반으로 초평면(hyperplane)이 결정된 후 두 번째의 입력 데이터가 입력되었을 경우 즉, 그림 6(a)에서의 원내의 특징 벡터가 입력되었을 때 초평면의 검출 범위를 벗어나게 된다. 그러나 학습을 통해 새로운 경계영역을 만들고 초평면을 갱신하게 되며, 6(b)의 원으로 표시한 것과 같이 학습을 통해 검출하게 된다. 그림 7은 입력 데이터에 대한 경계영역 결정 파라미터인 라그랑지 승수($\alpha^* > 0$)와 바이어싱 상수(b)를 Matlab 시뮬레이션한 결과를 나타낸다. 그림 (a)는 첫 번째 데이터가 입력되었을 때의 결과이며, 그림 6(a)의 경우 발생하는 결정 파라미터이다. 그리고 (b)는 두 번째 데이터가 입력되었을 때 결과이다. 이는 그림 6(b)의 경우 발생하는 결정 파라미터이다. 그림 7에서 볼 수 있듯이 경계영역 결정 파라미터는 입력 데이터에 대한 라그랑지 승수와 바이어싱 상수에 의해 경계영역이 결정되며 초평면이 갱신된다.

All plotting is done with this simple command. It looks for the best way of displaying the result.

This concludes the demo
>> alpha

alpha =

1.3286
0.1635
-0.0141
-0.0489
0.0101
0.2119
0.2396
0.3977
0.2247
0.1442

>> b

b =

0.4614

>>

(a)

All plotting is done with this simple command. It looks for the best way of displaying the result.

This concludes the demo
>> alpha

alpha =

1.0451
1.0451
0.2075
-0.0058
-0.0465
0.0160
0.3348
0.3784
0.6234
0.3564
0.2261

>> b

b =

0.1496

>>

(b)

그림 7. 경계 결정 파라미터 (a) 첫 번째 입력 데이터 (b) 두 번째 입력 데이터

Fig. 7. Boundary decision parameter (a) First input data (b) second input data.

그림 8은 입력 데이터가 검출 범위 내에 있을 때와 검출 범위를 벗어 날 경우를 보여준다. (a)는 검출 범위 내에 있을 경우를 나타내며, 원내의 데이터가 입력되었을 때 결함

영역에 속하므로 검출의 경계영역의 업데이트 없이 초평면이 결정된다. 그러나 (b)에서의 원내의 데이터가 입력되었을 경우 학습을 통해 경계영역을 업데이트 한 후 초평면을 갱신하여 결함영역으로 검출하게 되며, (c)의 원으로 표시 것과 같다. 그림 8은 그림 7의 방법과 동일한 방법으로 경계 영역이 결정되며 초평면이 갱신된다. 그림 8은 그 결과를 도식적으로 나타낸 것이다.

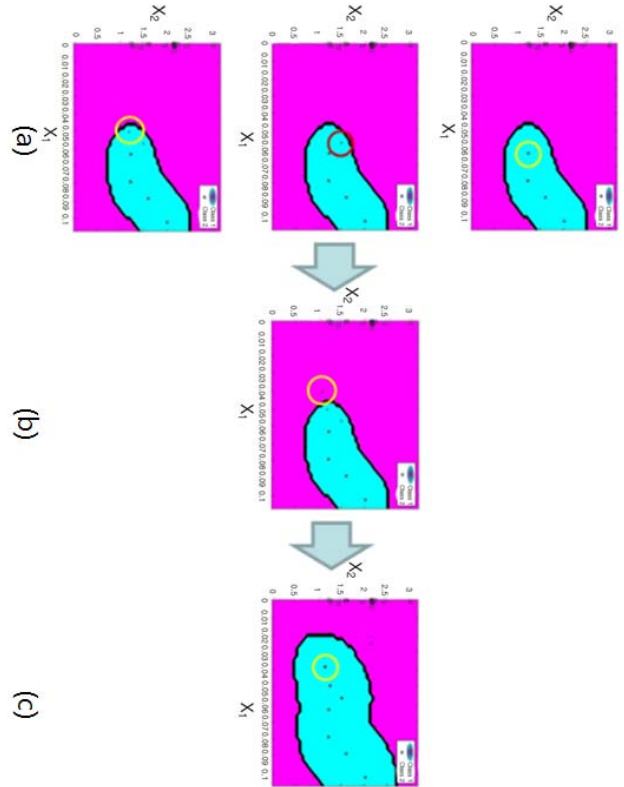


그림 8. 경험적 데이터 학습 결과
Fig. 8. Training result of empirical feature data.

표 2는 추출된 특징 벡터를 기반으로 선형적 SVM (Linear SVM)을 이용하였을 경우와 LS-SVM을 이용하였을 경우를 비교한 결과이며, 25개의 결함 영역 영상과 23개의 배경영역 영상을 적용하였다. 그 결과 표 2에서 보는 것과 같이 선형적인 SVM을 이용하였을 경우 결함 영역에 대해서 84%의 검출 정확도를 보였으며, 배경영역에 대해서 100%의 검출 정확도를 보였다. 반면, LS-SVM을 이용하였을 경우 결함 영역에 대해서 100%의 검출 정확도를 보였으며, 또한 배경 영역에 대해서도 100%의 검출 정확도를 보였다.

표 2. 이전의 방법과 LS-SVM 방법에 대한 정확도 비교 (단위: %)

Table 2. The comparison of the algorithms for accuracy (unit: %)

	Linear SVM		LS-SVM	
	결함영역	배경영역	결함영역	배경영역
정확도(Accuracy)	84	100	100	100

4. 결 론

본 논문에서는 열화된 영상이나 혹은 영상 정보를 잃어 버리는 경우 형태, 크기, 장축과 단축의 길이의 비율 등을 포함한 영상 특징 벡터를 추출하기 어려운 한도영상에 대해 자동 결함 검출 방법을 제안하였다. 제안한 방법에서 영상의 특징 벡터를 추출하기 위해 웨버의 법칙에 기인한 방법으로 결함 영역에 대한 특징 벡터를 추출하고 그리고 표준편차를 이용하였다. 적용결과 인간의 시각적으로 구분하기 어려운 영상내의 결함 영역과 배경영역에 대한 특징 벡터를 보다 효과적으로 추출 할 수 있었다.

위에서 언급한 방법으로 추출한 특징 벡터를 기반으로 경험적 데이터를 이용한 학습 방법인 LS-SVM방법을 적용하였다. 실험 결과 이전의 방법인 선형적인 SVM을 적용하였을 경우 결함 영역의 영상에 대해 84%의 검출 정확도를 보인 반면, 제안한 방법에서 100%의 검출 정확도를 보여주었다. 실험 결과는 제안한 방법이 이전의 방법보다 우수한 성능을 보임을 입증하였다.

참 고 문 헌

- [1] Woo-Seob Kim, Jong-Hwan Oh, Chan-Ho Han, and Kil-Houm Park, "Image Enhancement for Automated TFT-LCD Inspection System Using Estimation of Intensity Flow," *IEICE Trans. Electron.*, vol. E90-C, no. 11, November 2007.
- [2] Liang-Chia, Chen, and Chia-Cheng kuo, "Automatic TFT-LCD mura defect inspection using discrete cosine transform-based background filtering and 'just noticeable difference' quantification strategies," *Meas. Sci. Technol.*, vol 19, pp. 1-10, March 2008.
- [3] Rafael C. Gonzalez and Richard E. Wood, *Digital Image Processing*, second edition Addison Wesley, 2002.
- [4] Vladimir N. Vapnik, *Statistical learning theory*, John Wiley & Sons, 1998.
- [5] Bernhard E. Boser, Isabelle M. Guyon, and Vladimir N. Vapnik, "A Training Algorithm for Optimal Margin Classifiers," *In COLT* pp.144-152, 1992.
- [6] Johan A.K.Suykens, Tony Van Gestel, Jos De Brabanter, Bart De Moor, and Joos Vandewalle, *Least Squares Support Vector Machines*, World Scientific, 2002.
- [7] Jozsef Valyon, and Gabor Horvath, "A Robust LS-SVM Regression," *PWASET* vol. 7, ISSN 1307 - 6884, August 2005.

저 자 소 개



최호형(Ho-Hyung Choi)

2001년 : 경주대학교 컴퓨터전자공학부 공학사
2003년 : 경주대학교 컴퓨터전자공학과 석사
2009년~현재 : 경북대학교 정보통신학과 박사과정

관심분야 : 영상처리, 신경망 알고리즘, 유전자 알고리즘 등
Phone : 010-6771-6680
Fax : 053-950-5508
E-mail : chhman2000@msn.com



이건희(Gun-Hee Lee)

1993년 : 경북대학교 전자공학과 공학사
2009년~현재 : 경북대학교 정보통신학과 석사과정
2007년~현재 : LG-Display 생산기술 센터

관심분야 : Display검사/Repair 신기술/장비개발 등
Phone : 054-478-2970
Fax : 054-478-2609
E-mail : lgh1234@lgdisplay.com



김자근(Ja-Geun Kim)

1999년 : 국민대학교 전산과학과 공학사
2003년 : 국민대학교 전산과학과 공학석사
2008년~현재 : LG Display 생산기술 센터

관심분야 : Review/Repair System, 검사 알고리즘 개발
Phone : 031-933-0748
Fax : 054-478-2609
E-mail : richroot@lgdisplay.com

주영복(Young-Bok Joo)

한국지능시스템학회 논문지 2009. Vol 19. No.3 참조

최병재(Byung-Jae Choi)

한국지능시스템학회 논문지 2009. Vol 19. No.3 참조

박길흠(Kil-Houm Park)

한국지능시스템학회 논문지 2009. Vol 19. No.3 참조



윤병주(Byoung-Ju Yun)

1993년 : 경북대학교 전자공학과 학사
1996년 : 한국과학기술원 전기 및 전자공학과 석사
2002년 : 한국과학기술원 전자전산학과 박사
2003년 ~ 현재 : 경북대학교 전자 전기 컴퓨터 학부 부교수

관심분야 : 영상신호 처리, 영상압축, 객체기반 영상 부호화, 객체 추적 컴퓨터 비전 등

Phone : 053-950-7329

Fax : 053-950-5508

E-mail : bjisyun@ee.knu.ac.kr