

다중 정상 하에서 단일 클래스 분류기법을 이용한 이상치 탐지 : TFT-LCD 공정 사례

주태우 · 김성범[†]

고려대학교 산업경영공학과

A Novelty Detection Algorithm for Multiple Normal Classes : Application to TFT-LCD Processes

Tae Woo Joo · Seoung Bum Kim

School of Industrial Management Engineering, Korea University

Novelty detection (ND) is an effective technique that can be used to determine whether a future observation is normal or not. In the present study we propose a novelty detection algorithm that can handle a situation where the distributions of target (normal) observations are inhomogeneous. A simulation study and a real case with the TFT-LCD process demonstrated the effectiveness and usefulness of the proposed algorithm.

Keywords: Novelty Detection, Multiple Normal Classes, Mahalanobis Distance, Bootstrap Method, Data Mining, TFT-LCD Process

1. 서론

이상치 탐지(novelty detection)는 하나의 정상집단을 특성화하는 모델을 학습시킨 후 새로운 관측치와의 비교를 통해 새로운 관측치의 비정상 여부를 확인하는 기계 학습 기법으로(Kang *et al.*, 2012) 사기 탐지(Issa and Miklos, 2011; Thiprungsri and Miklos, 2011), 침입 탐지(Kumar *et al.*, 2005), 의료(Tarassenko *et al.*, 2006), 제조공정 과정(Clifton *et al.*, 2008) 등 다양한 분야에서 응용되고 있다. 특히 제조 공정 과정에서 불량 제품으로 인한 제작업 증가는 효율성을 감소시키는 주요 원인으로 TFT-LCD 나 PCB와 같은 하이테크 산업에서 이상치 탐지는 중요한 문제로 인식되고 있다(Shin, 2010). 이상치 탐지는 실시간으로 해당 제품 설비를 관리함으로써 불량 제품의 조기 탐지와 품질 성능 개선, 나아가 생산성 향상에 기여한다(Montgomery, 2005).

이상치란 다른 데이터들로부터 벗어나 있는 관측치로 상이한 메커니즘의 결과라고 의심되는 경우이다(Hawkins, 1980;

Barnett and Lewis, 1994). 이상치 탐지는 새로운 관측치가 기존의 데이터와 패턴이 같은지 그렇지 않은지 여부를 판정하는 방법으로 이진 분류와 단일 클래스 분류 관점에서 분석이 가능하다(Kang and Cho, 2009; Clifton *et al.*, 2011). 이진 분류 알고리즘은 정상과 비정상 데이터가 존재하는 데이터를 학습하여 모델을 구축한 후 이를 이용하여 새로운 관측치의 정상 여부를 판단하는 기법이다. 일반적으로 이진 분류기는 정상과 비정상 데이터의 수가 어느 정도 균형 잡힌 경우에 적합하다. 하지만 최근 복잡한 시스템에서는 정상집단의 관측치 수에 비해 비정상 데이터의 수가 현저히 적은 불균형 데이터가 생성되는데, 이 경우 기존 이진 분류기의 무조건적인 사용은 결과의 신뢰성을 현저히 떨어뜨릴 수 있다(Tax, 2001). 이에 대한 문제점을 극복하기 위해 단일 클래스 분류기법이 사용되고 있다. 단일 클래스 분류기법은 소수의 비정상 관측치는 모델 구축에 사용하지 않고 다수의 정상 관측치만을 이용하여 모델을 구축한 후, 새로운 관측치가 왔을 때 정해진 임계값과의 비교를 통

본 연구는 지식경제부의 정보통신연구기반구축사업(NIPA-2011-(B1110-1101-0002))의 지원으로 수행된 연구임.

[†] 연락저자 : 김성범 교수, 136-701 서울시 성북구 안암동 5가 1번지 고려대학교 산업경영공학과, Tel : 02-929-5888, Fax : 02-3290-3397,

E-mail : sbkim1@korea.ac.kr

2012년 11월 15일 접수; 2013년 2월 28일 수정본 접수; 2013년 3월 6일 게재 확정.

해 이상 여부를 판단하는 기법이다(Schölkopf *et al.*, 2001). 즉, 새로운 관측치와 정상집단 내 관측치들과의 거리를 계산하여 그 값이 임계값 보다 크면 이상치로 판정하는 것이다.

단일 클래스 분류기법은 일반적으로 분포를 이용한 추정법, 경계선을 통한 분류 방법, 그리고 재구축 방법으로 구분된다. 대표적인 방법으로는 k 최인접 분류기(nearest neighbor classifier)를 기반으로 한 kNNDD 분류기법(Duda and Hart, 1973)과 지지벡터(support vector)를 이용한 One-class support vector machine 등이 있다(Schölkopf *et al.*, 2001). 단일 클래스 분류기법의 응용분야로 얼굴 인식, 정보검색, 생물정보학, 문서 및 저자 판별 분류, 제조 공정 모니터링 등 다양하게 존재하고 있다(Manevitz and Yousef, 2001; Sanchez-Yanez, 2003; Koppel and Schler, 2004; Liu *et al.*, 2008; Kim *et al.*, 2011; Liu *et al.*, 2011).


기존 단일 클래스 분류기법에서는 정상집단은 하나의 분포로 특성화 된다고 가정하고 있다. 하지만 최근 시스템의 복잡도가 증가하고 다종의 설비에서 생산되는 제품의 경우에는 같은 정상제품이라도 그 특성이 달라 이를 동일한 분포로 가정하기에는 많은 무리가 따른다. 본 연구에서는 이와 같이 정상 데이터 내에 여러 집단이 존재하는(다중 정상) 상황 하에서 정확하고 효과적으로 사용될 수 있는 단일 클래스 분류 기반 이상치 탐지 기법을 제안한다.

본 논문의 구성은 다음과 같다. 제 2장에서는 이상치 탐지

기법에 대해 기술하였고, 제 3장은 제안하는 방법인 다중 정상 이상치 탐지 기법에 대해 설명하였다. 제 4장은 시뮬레이션 데이터를 이용하여 다양한 상황 하에서 제안하는 기법의 특성을 살펴보고 기존 기법과의 비교를 통해 우수성을 입증하였다. 제 5장은 TFT-LCD 공정과정 중 증착(Chemical Vapor Deposition)과정에서 추출된 실제 데이터를 대상으로 제안하는 방법의 사용 가능성과 우수성을 입증하였다. 마지막으로 제 6장에서는 본 연구의 요약과 함께 결론을 맺었다.


2. 다중 정상집단 하에서 이상치 탐지

앞 장에서도 언급했듯이 기존 이상치 탐지 기법은 정상집단을 하나의 분포로 가정하고 있다. 하지만 정상의 종류가 둘 이상 존재하는 경우에 단순히 기존 기법을 적용하게 되면 각각의 정상집단들이 가지고 있는 특성을 고려하지 않게 되어 정확한 탐지가 어려워진다. 본 연구에서 제안한 기법은 단일 클래스 분류기법을 병렬적으로 적용시킨 다중 정상 하에서 이상치 탐지 기법이다. 다중 정상 하에서 이상치 탐지 기법이란 각 정상 집단에 단일 클래스 분류기법을 적용한 후, AND 게이트(gate) 개념을 이용하여 새로운 관측치의 이상치 여부를 판정하는 것이다.

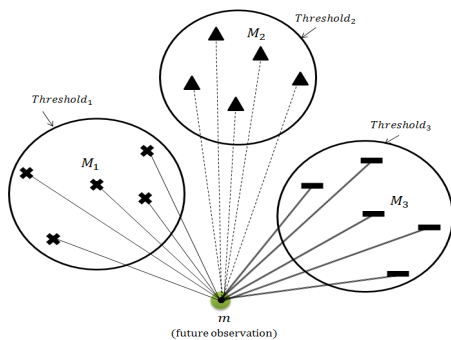


- Novelty score set_k = {MD_k(X_i) | k = class label, i = index of observations}
- MD_k(X_i) = Sum of the between *i*_{th} observation and other observations in *k*_{th} normal class.

(a) Step 1 : Calculating novelty scores within each normal group




(b) Step 2 : Determining the thresholds using bootstrapping



- M_i = Sum of the distances between all observations in *k*_{th} normal class and future observation.

(c) Step 3 : Calculating novelty scores between a future observations and normal observations in each normal group



- input_k = $\begin{cases} 1, & M_k \geq \text{Threshold}_k \\ 0, & M_k < \text{Threshold}_k \end{cases}$

(d) Step 4 : Detection via AND gate

Figure 1. A Process of Proposed Method

제안하는 이상치 탐지 기법은 다음의 4단계로 설명할 수 있다.

Step 1 : 정상집단 내 관측치들의 거리 측정

<Figure 1>(a)에서 보여주고 있는 첫 번째 과정은 정상집단 내에서 각 관측치와 그것을 제외한 나머지 관측치들과의 거리를 측정하여 그 거리 값의 집합을 구하는 과정이다. 이 거리는 정상집단 내의 관측치들만으로 계산되기 때문에 이상치를 판단하는 임계값을 결정하는 데 사용될 수 있다. 본 연구에서는 단순히 물리적 거리만을 측정하는 유클리디안 거리보다 변수 간의 상관관계를 고려한 마할라노비스 거리(Mahalanobis Distance)가 보다 효과적이라고 판단하였고(Franklin *et al.*, 2000), 따라서 식 (1)의 마할라노비스 거리를 기반으로 novelty score 셋을 구성하였다.

$$MD_k(X_i) = \sum_{\forall j \neq i} (X_i - X_j)^T S_k^{-1} (X_i - X_j) \quad (1)$$

여기에서 k 는 정상집단의 클래스이며, n_k 는 클래스 k 의 총 관측치 개수를 말한다. S_k^{-1} 은 정상집단 k 의 공분산의 역행렬을 나타내고 있다. 관측치 X_i 와 그 외의 관측치 $n_k - 1$ 개의 거리 값들을 모두 합하여 하나의 $MD_k(X_i)$ 를 계산하며 n_k 만큼 구해진다. 이렇게 계산된 값을 원소로 하는 novelty score 셋을 다음과 같이 표현할 수 있다.

$$novelty\ score\ set_k = \{MD_k(X_i) \mid i = 1, 2, \dots, n_k\} \quad (2)$$

Step 2 : 붓스트랩 기법을 활용한 임계값 결정

붓스트랩 기법이란 모집단의 확률분포가 알려져 있지 않은 경

우, 주어진 데이터로부터 분포를 추정하는 비모수 추정 방법 중 하나이다(Efron and Tibshirani, 1994). 붓스트랩 기법을 사용하여 임계값을 구하는 방법을 설명하면 다음과 같다. 먼저 Step 1에서 구한 *novelty score set_k*의 원소 $MD_k(X_i)$, $i = 1, 2, \dots, n_k$ 를 n_k 번 복원추출하고, 그 과정을 B번 반복하여 B개의 붓스트랩 샘플 셋을 얻는다. 이후 사용자가 정하는 유의 수준(α)를 통해 각 샘플 셋의 $(1 - \alpha) \times 100$ 분위수 값 P_b ($b = 1, 2, \dots, B$)를 구하고 이들의 평균값을 최종적으로 정상집단 k 의 임계값으로 사용한다. 여기서 유의수준은 제1종 오류로 정상을 비정상으로 판단할 확률이다. <Figure 2>는 임계값 결정을 위한 붓스트랩 기법 과정을 보여주고 있다. <Figure 1>(b)는 Step 2과정이 각 정상집단에 적용된 그림으로써, 각 집단 별 *novelty score set_k*을 기반으로 붓스트랩 기법 과정을 거친 후 각각의 임계값을 구하는 과정이다. 각 집단의 중요한 특성이라 할 수 있는 임계값을 정상집단에 따라 개별적으로 구함을 보여주고 있다.

Step 3 : 새로운 관측치의 거리 측정

새로운 관측치에 대한 이상치 여부는 마할라노비스 거리를 이용한 각 정상 그룹과의 차이를 통해 계산하였다. 새로운 관측치 m 와 정상집단 k 의 관측치들의 마할라노비스 거리의 합인 M 은 다음의 식으로 표현된다.

$$M_k = \sum_{j=1}^{n_k} (m - X_j)^T S_k^{-1} (m - X_j) \quad (3)$$

전체 정상집단이 N개인 경우 다음의 식과 같이 총 N개의 표본이 존재하게 된다.

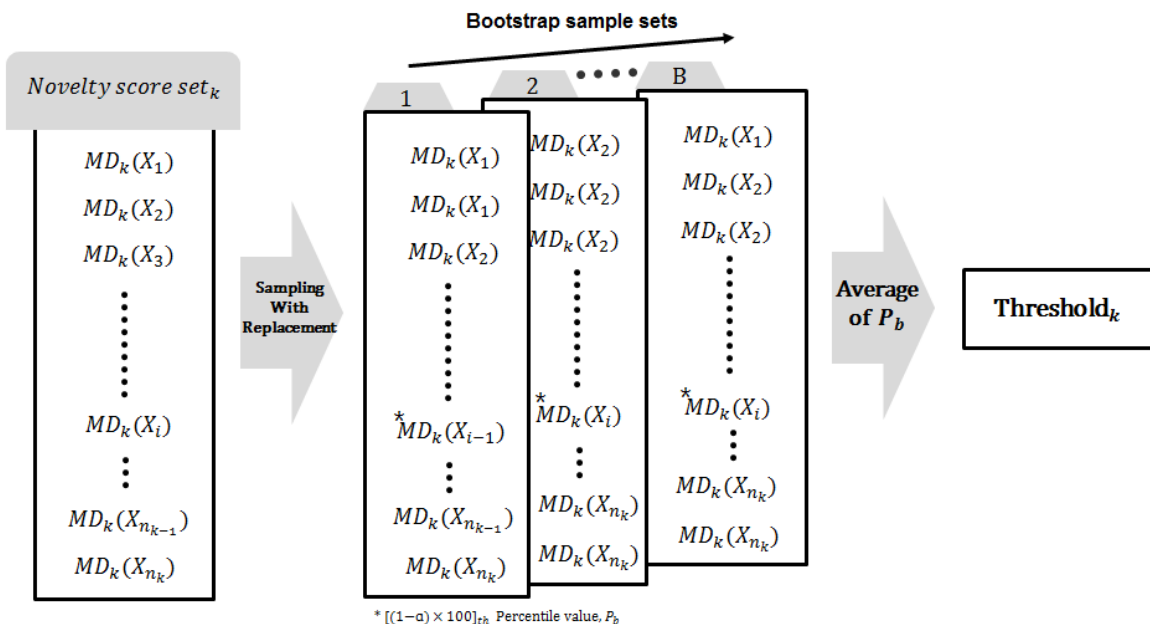


Figure 2. Bootstrapping to determine the threshold in each normal group

$$M_{set} = \{M_k | k = 1, 2, \dots, N\} \quad (4)$$

Step 4 : AND 게이트를 이용한 이상치 탐지

AND 게이트는 하나 혹은 여러 개의 입력을 받아 필요한 출력 값을 만드는 회로 중 하나이다(Mano and Ciletti, 2007). AND 게이트는 입력 2개 이상에 대하여 출력 1개를 얻는 게이트로 논리곱이라 하는데, 이 게이트의 출력은 입력에 따라 결정되고 입력이 모두 1(on)인 경우에만 출력이 1(on)이 되고 입력 중에 하나라도 0(off)가 있으면 출력은 0(off)이 된다(Lim and Hong, 2009). <Figure 3>는 입력이 3개인 AND 게이트를 보여주고 있다.




Figure 3. Illustration of AND gate for three inputs

본 연구에서는 각각의 M_k 값과 $Threshold_k$ 의 비교를 통해 이진수가 AND 게이트의 입력 값으로 주어 졌을 때 위에 설명한 개념을 활용하였다. 즉, M_k 값이 해당 임계값($Threshold_k$)보다 클 경우 1로 표시하고 그렇지 않을 경우 0으로 나타낼 수 있으며 이는 식 (5)와 같다.

$$input_k = \begin{cases} 1, & M_k \geq Threshold_k \\ 0, & M_k < Threshold_k \end{cases} \quad (5)$$

최종적으로 모든 input 값이 1일 경우 해당 관측치는 이상치로 판단되며 하나라도 0일 경우에는 정상으로 판단된다. 이를 다음의 식으로 표현할 수 있다.

$$output_m = \begin{cases} 1, & m \text{ is a novelty} \\ 0, & m \text{ is a normal} \end{cases} \quad (6)$$

3. Simulation



3.1 데이터 설명 및 실험 계획

이번 장에서는 시뮬레이션 데이터를 이용하여 제안하는 다중 정상 단일 클래스 분류기법의 특성을 파악하고 기존기법과의 비교를 통해 제안기법의 우수성을 입증하였다. 실험 유형은 변수들의 상관관계 유무에 따라 크게 2가지 유형으로 나누었다. 각 유형 별 정상 데이터는 다변량 정규 분포를 통해서 생성하였고, 정상이 3개인 다중 정상인 상황을 가정하였다. 또한 각 정상 분포의 차이는 평균 변화를 통해 구현하였다. <Figure 4>는 각 유형 별 정상집단들의 분포를 보여준다.

<Figure 4>(a)는 변수 간 상관관계가 존재하지 않는 경우이며, 각 다변량 정규분포의 평균벡터와 공분산 행렬을 식 (7)에서 보여주고 있다. 실험을 위해 각 분포로부터 10,000개의 데이터를 생성하였다.

$$\begin{aligned} \text{정상}_{11} &\sim N(\mu_{11}, \Sigma_{11}) \\ \text{정상}_{12} &\sim N(\mu_{12}, \Sigma_{12}) \\ \text{정상}_{13} &\sim N(\mu_{13}, \Sigma_{13}) \\ \mu_{11} &= \begin{bmatrix} 1 \\ 1 \end{bmatrix}, \Sigma_{11} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \\ \mu_{12} &= \begin{bmatrix} 9 \\ 1 \end{bmatrix}, \Sigma_{12} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \\ \mu_{13} &= \begin{bmatrix} 5 \\ 5 \end{bmatrix}, \Sigma_{13} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \end{aligned} \quad (7)$$

<Figure 4>(b)는 변수 상관관계가 존재하는 경우이며 식 (8)은 각각 다변량의 정규분포의 평균벡터와 공분산 행렬을 보여주고 있다. 이 경우에도 각 분포로부터 10,000개의 데이터를 생성하였다.



(a) multivariate normal distribution with no correlated variables (b) multivariate normal distribution with correlated variables

Figure 4. Simulated normal datasets from the multivariate normal distribution

$$\begin{aligned}
 & \text{정상}_{21} \sim N(\mu_{21}, \Sigma_{21}) \\
 & \text{정상}_{22} \sim N(\mu_{22}, \Sigma_{22}) \\
 & \text{정상}_{23} \sim N(\mu_{23}, \Sigma_{23}) \\
 & \mu_{21} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}, \Sigma_{21} = \begin{bmatrix} 1 & 0.7 \\ 0.7 & 1 \end{bmatrix} \\
 & \mu_{22} = \begin{bmatrix} 9 \\ 1 \end{bmatrix}, \Sigma_{22} = \begin{bmatrix} 1 & 0.7 \\ 0.7 & 1 \end{bmatrix} \\
 & \mu_{23} = \begin{bmatrix} 7 \\ 5 \end{bmatrix}, \Sigma_{23} = \begin{bmatrix} 1 & 0.7 \\ 0.7 & 1 \end{bmatrix}
 \end{aligned} \tag{8}$$

비정상의 경우는 각 정상집단으로부터 평균을 이동($\lambda=0.5, 1, 2, 3$)하여 생성하였고 이를 <Figure 5>과 <Figure 6>에서 보여주고 있다. 비정상은 각 집단 별로 100개씩 생성하였다.

3.2 시뮬레이션 결과

<Table 1>에서 볼 수 있듯이 본 실험에서 고려하고 있는 두 가지 시나리오 모두 제안하고 있는 기법이 기존의 기법보다 민감도(sensitivity)가 크울 알 수 있다. 예상한 바와 같이 평균 변화 정도가 적은 경우에는 기법에 관계없이 민감도가 작았으

나 변화 정도가 커질수록 민감도가 증가함을 알 수 있었다. 여기서 주목해야 할 점은 기존 기법은 평균 변화가 커져도 민감도가 크게 향상되지 않은 반면 제안하고 있는 기법은 항상 정도가 매우 크울 볼 수 있었다. 이 결과로부터 다중 정상 하에서 기존 방법을 조건 없이 사용한다는 것은 부정확한 결과를 야기할 수 있음을 알 수 있었고 이를 해결하기 위해 본 연구에서 제안한 기법은 매우 우수한 성능을 보이고 있음을 입증하였다.

4. TFT-LCD 공정 데이터를 이용한 실제 사례

본 연구에서는 제안하고 있는 방법의 효용성을 입증하기 위해 TFT-LCD (Thin Film Transistor-Liquid Crystal Display) 제조 과정 중 증착 공정 과정(CVD)에서 추출한 실제 데이터를 사용하여 실험하였다. 이 데이터는 4개의 설비에서 각각 추출되었으며 총 42개의 변수와 2,000개의 정상 관측치, 1,000개의 비정상 관측치로 구성되었다. 일반적으로 비정상의 개수가 정상보다 적은 실제 공정상황을 반영하기 위해 정상 관측치는 2,000개를 모두 사용하되, 비정상 관측치는 1,000개에서 임의로 100개를 추

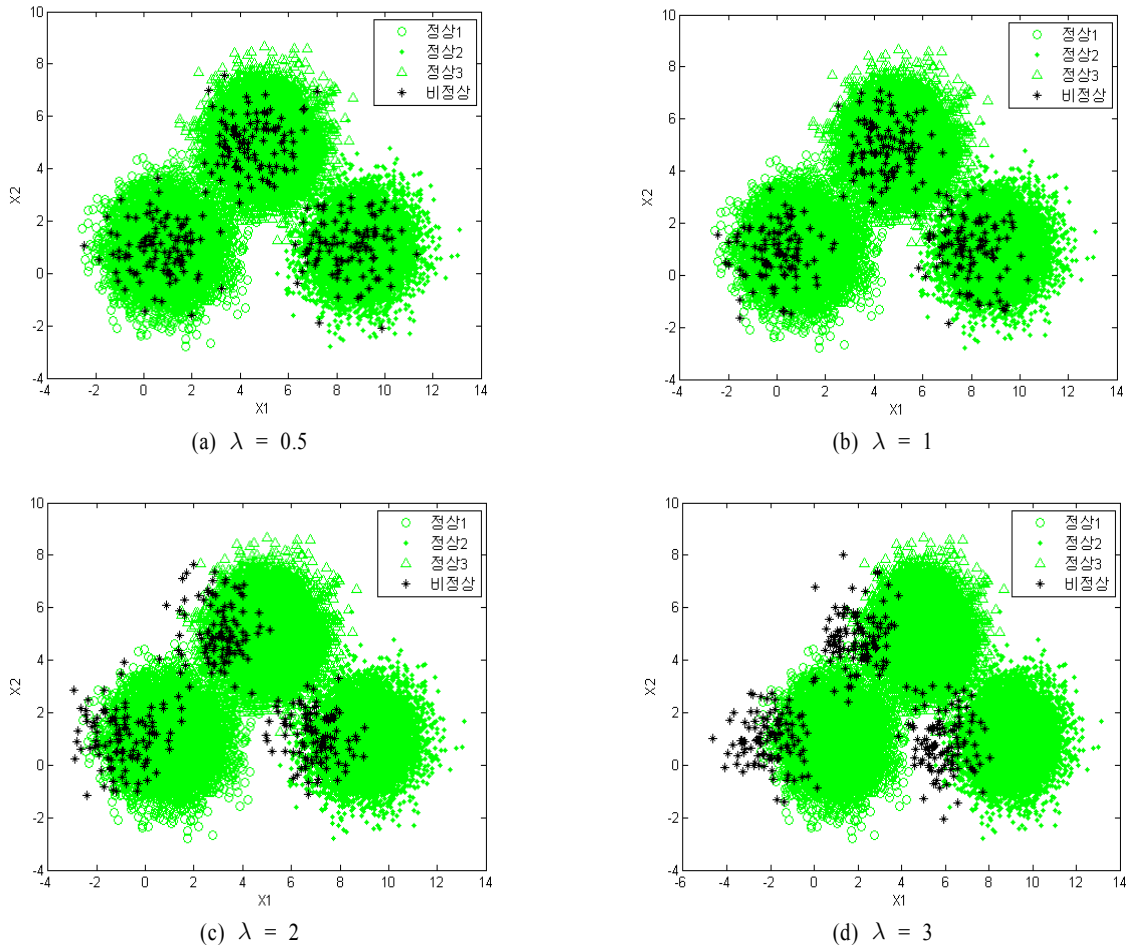


Figure 5. Normal and abnormal datasets from the multivariate normal distribution with no correlation

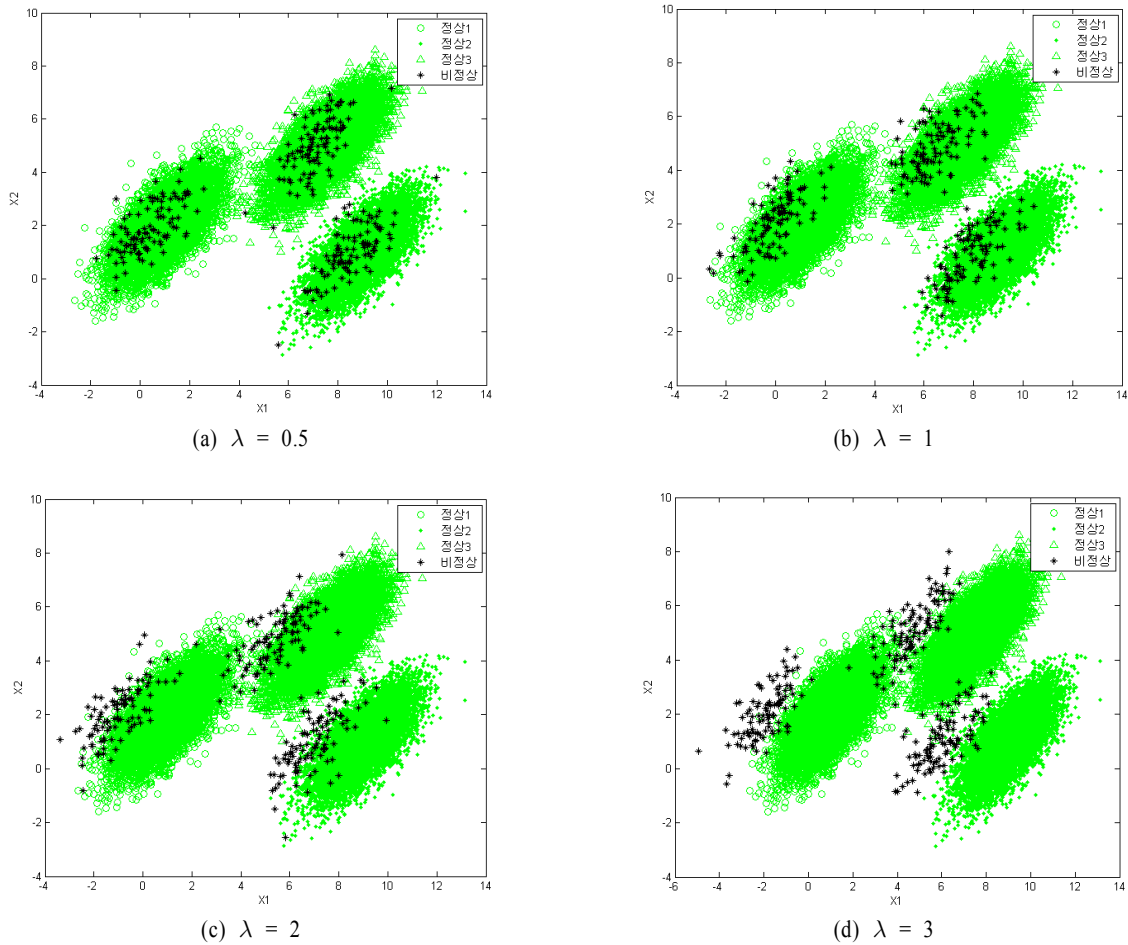


Figure 6. Normal and abnormal datasets from the multivariate normal distribution with correlation

Table 1. Comparison between the traditional and proposed novelty detection algorithms in terms of sensitivity

Scenario	Method	Mean Shift			
		$\lambda = 0.5$	$\lambda = 1$	$\lambda = 2$	$\lambda = 3$
변수 간의 상관관계가 존재하지 않는 경우	단일 정상 하의 탐지 기법	5.65%	7.38%	17.03%	29.83%
	다중 정상 하의 탐지 기법 (제안 기법)	6.66%	13.46%	40.63%	74.85%
변수 간의 상관관계가 존재하는 경우	단일 정상하의 탐지 기법	5.95%	7.45%	17.07%	30.43%
	다중 정상하의 탐지 기법 (제안 기법)	9.17%	21.92%	70.13%	93.79%

출하여 50회 반복 실험하였다. 정상 데이터의 형태를 보기 위해 주성분분석(principal component analysis)을 이용하여 차원을 축소하였고 이로부터 얻어진 첫 번째, 두 번째, 그리고 세 번째 주성분을 축으로 시각화한 결과를 <Figure 8>에서 보여주고 있다. 그림으로부터 정상 데이터는 네 개의 집단으로 나뉘음을 알 수 있었고 이는 각각 다른 설비에서 생성된 것임을 확인할 수 있었다.

제안기법의 적용가능성과 효율성을 입증하기 위해 ROC (Receiver-Operating Characteristic)를 사용하였다. ROC 곡선은

민감도(sensitivity)와 특이도(specificity)의 상관관계를 이차원 평면상에 표현한 그래프로, ROC 곡선의 아래 면적(AUC : Area under the ROC curve)이 넓을수록 좋은 방법이다(Bradley, 1997). 민감도란 판정 과정 중 이상을 정확하게 이상으로 판정한 비율을 말하며, 특이도는 정상을 정확히 정상으로 판정한 비율을 나타내는 지표이다. <Figure 9>의 기존 기법과 제안 기법의 ROC 곡선 결과를 보여주고 있으며 이를 이용하여 AUC를 계산한 결과를 <Table 3>에서 보여주고 있다.

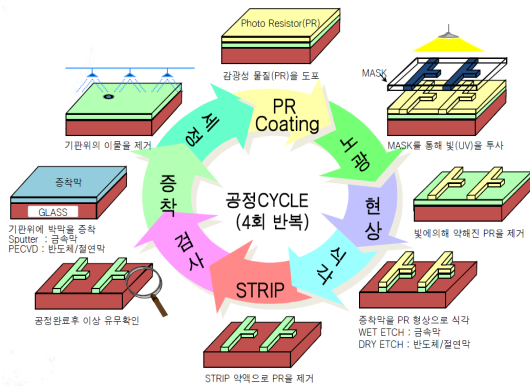


Figure 7. An outline of the TFT-LCD process production process




Figure 8. Three-Dimensional PCA score plot (PC1 vs. PC2 vs. PC3) of normal data generated from four different machines




Figure 9. ROC curve for one-class classification method and proposed method

Table 3. Comparison between the traditional and proposed OCC algorithms in terms of AUC

	AUC
단일 정상하의 OCC 기법	97,878
제안하는 기법	99,672

제안하는 기법의 AUC 값이 큼을 확인할 수 있었고 이는 제안하는 기법이 실제 문제에서도 잘 적용됨을 보여주고 있다. 결론적으로 공정의 이상치 탐지에 있어, 설비에 따른 정상 분포의 정보를 이용하는 것이 효과적이고 정확한 결과를 이끌어 낼 수 있었다.

5. 결론

기존 이상치 탐지 기법은 일반적으로 정상집단이 단일하다는 가정을 갖고 있다. 하지만 현대 공정과 같이 설비 과정이 다양해지고 복잡해지면서, 각 설비에서 생산되는 양품의 분포 특성 또한 다양하다. 이와 같은 문제를 해결하기 위해 본 연구에서는 정상의 종류가 다양한 다중 정상 하에서 이상치 탐지 기법을 제안하였다.

기존 방법인 단일 정상 하의 이상치 탐지 기법을 대조군으로 설정하여 가상 실험과 TFT-LCD 실제 데이터를 활용한 실험을 진행한 결과, 정상 분포들의 특성을 고려하는 제안 기법이 보다 우수한 성능을 보임을 확인하였다.

제조업체의 경쟁력 향상을 위한 필수적인 요소는 제품의 품질 관리이다. 품질이 나빠지면 고객에 대한 신뢰를 잃고 이는 시장의 점유율 감소로 이어질 수 있다. 따라서 이를 막을 수 있는 효과적인 이상치 탐지는 필수사항이라 하겠다. 특히 복잡해진 현대 공정은 기존에 고려되지 않았던 다양한 상황이 지속적으로 발생되는데, 본 연구에서 다룬 다중 정상하의 이상치 탐지 기법은 공장 설비 종류에 따라 다른 분포 특성을 갖게 되는 현상을 반영한 기법이다. 본 연구에서 제안하는 기법은 예로 든 TFT-LCD 공정 뿐 아니라 기타 하이테크 산업과 장치 산업 등에 효과적으로 활용될 수 있을 것이다.

참고문헌

Barnett, V. and Lewis, T. (1994), *Outliers in Statistical Data*, Wiley and Sons, California, USA.

Bradley, A. P. (1997), The Use of the Area Under the ROC Curve in the Evaluation of Machine Learning Algorithms, *Pattern Recognition*, 30(7), 1145-1159.

Clifton, D., Tarassenko, L., Sage, C., and Sundaram, S. (2008), Condition Monitoring of Manufacturing Processes, *In : Proceedings of Condition Monitoring*, Edinburgh, UK, 273-279.

Clifton, D. A., Hugueny, S., and Tarassenko, L. (2011), Novelty Detection with Multivariate Extreme Value Statistics, *Journal of Signal Processing Systems*, 65(3), 371-389.

Duda, R. and Hart, P. (1973), *Pattern Classification and Scene Analysis*, John Wiley and Sons, New York, USA.

Efron, B. and Tibshirani, R. J. (1994), *An Introduction to the Bootstrap*, Chapman and Hall/CRC, London, UK.

Franklin, S., Thomas, S., and Brodeur, M. (2000), Robust Multivariate Outlier Detection Using Mahalanobis' Distance and Modified Stahel-Donoho Estimators, *In: Proceedings of the Second International Conference on*

- Establishment Surveys, Buffalo, New York*, 697-706.
- Hawkins, D. M. (1980), *Identification of Outliers*, Chapman and Hall, London, UK.
- Issa, H. and Miklos A. V. (2011), Application of Anomaly Detection Techniques to Identify Fraudulent Refunds, *Social Science Research Network*.
- Kang, P. and Cho, S. (2009), A Hybrid Novelty Score and its Use in Keystroke Dynamics-Based User Authentication, *Pattern Recognition*, **42** (11), 3115-3127.
- Kang, P. S., Lee, S. K., Kim, D. I., Doh, S. Y. and Cho, S. Z. (2012), Estimating the Reliability of Virtual Metrology Predictions in Semiconductor Manufacturing : A Novelty Detection-Based Approach, *Journal of the Korean Institute of Industrial Engineers*, **38**(1), 45-56.
- Kim, S. B., Sukchotrat, T., and Park, S. K. (2011), A Nonparametric Fault Isolation Approach through One-Class Classification Algorithms, *IIE Transactions*, **43**(7), 505-517.
- Koppel, M. and Schler, J. (2004), Authorship Verification as a One-Class Classification Problem, In : *Proceedings of 21st International Conference on Machine Learning*, New York, 489-495.
- Kumar, V., Srivastava, J., and Lazarevic, A. (2005), *Managing Cyber Threats : Issues, Approaches and Challenges*, Springer, USA.
- Lim, S. G. and Hong, K. H. (2009), *Digital Logic Circuit*, Han Bit Media, Korea.
- Liu, Y. H., Huang, Y. K., and Lee, M. J. (2008), Automatic Inline Defect Detection for a Thin Film Transistor-Liquid Crystal Display Array Process using Locally Linear Embedding and Support Vector Data Description, *Measurement Science and Technology*, **19**(9), 1-16.
- Liu, Y. H., Liu, Y. C., and Chen, Y. Z. (2011), High-Speed Inline Defect Detection for TFT-LCD Array Process using a Novel Support Vector Data Description, *Expert Systems with Applications*, **38**(5), 6222-6231.
- Manevitz, L. M. and Yousef, M. (2001), One-Class Svms for Document Classification. *Journal of Machine Learning Research*, **2**, 139-154.
- Mano, M. M. and Ciletti, M. D. (2007), *Digital Design*, 4th edition, Prentice Hall, USA.
- Montgomery, D. C. (2005), *Introduction to Statistical Quality Control*, 5th edition, John Wiley and Sons, New York, USA.
- Sanchez-Yanez, R. E., Kurmyshev, E. V., and Fernandex, A. (2003), One-Class Texture Classifier in the CCR Feature Space, *Pattern Recognition Letters*, **24**, 1503-1511.
- Schölkopf, B., Platt, J. C., Shawe-Taylor, J., Smola, A. J., and Williamson, R. C. (2001), Estimating the Support of a High-Dimensional Distribution, *Neural Computation*, **13**(7), 1443-1471.
- Shin, H. J. (2010), A Fault Diagnosis Methodology for Module Process of TFT-LCD Manufacture Using Support Vector Machines, *Journal of the Semiconductor and Display Technology*, **9**(4), 93-97, Korea.
- Tarassenko, L., Hann, A. and Young, D. (2006), Integrated Monitoring and Analysis for Early Warning of Patient Deterioration, *British Journal of Anaesthesia*, **97**(1), 64-68.
- Tax, D. M. J. (2001), One-Class Classification : Concept-Learning in the Absence of Counter-Examples, *Ph.D. thesis, Delf University of Technology*, The Netherlands.
- Thiprungsri, S. and Miklos A. V. (2011), Cluster Analysis for Anomaly Detection in Accounting Data, *The International Journal of Digital Accounting Research*, **11**(17), 69-84.