

통계적 패턴인식에 의한 유도가열 솥의 비파괴 불량 검사 방법

A Defect Inspection Method of the IH-JAR by Statistical Pattern Recognition

오 기 태, 이 순 겐
(Ki-Tae Oh and Soon-Geul Lee)

Abstract : A die-casting junction method is usually used to manufacture the tub of an IH(induction heating) jar. If there is a very small air bubble in the junction area, the thermal conductivity is deteriorated and local overheat occurs. Such problem brings serious inferiority of the IH jar. In this paper, we propose a new method to detect such defect with simply measured thermal data. Thermal distribution of preheated tubs is obtained by scanning with infrared thermal sensors and analyzed with the statistic pattern recognition method. By defining the characteristic feature as the temperature difference between sensors and using ellipsoid function as decision boundary, a supervised learning method of genetic algorithm is proposed to obtain the required parameters. After applying the proposed method to experiment, we have proved that the rate of recognition is high even for a small number of data set

Keywords : induction heating jar, statistical pattern recognition, decision boundary, genetic algorithm


I. 서론

가열 (induction heating) 압력밥솥은 유도가열 방법을 이용하여 취사를 하는 가전제품이다. 즉, 금속체로 이루어진 솥에 맴돌이전류(eddy current)를 발생시키고 그로 의한 마찰열을 이용하여 밥통내부의 고온고압 상태를 유지하도록 고안되어 있다. 따라서 솥은 맴돌이전류를 잘 발생시키며 고온, 고압에 잘 견뎌야 한다.

가전제품으로 사용되는 압력 밥솥으로는 알루미늄과 스테인레스를 다이캐스팅으로 접합시키는 방법으로 제조하는 것이 있다[1]. 그러나 다이캐스팅 접합 과정에서 미소한 공기방울의 유입이 있게 되면 첫째 공기의 단열성으로 인해 불균일한 취사가 이루어 지는 문제가 발생하며, 둘째 가열시 공기방울이 솥의 열전달을 억제하여 국부적인 과열이 발생하여 솥과 인접한 플라스틱 수지를 녹이고 또한 부분적으로 밥이 타게 되는 등의 문제를 야기한다.

그림 1(a)는 공기방울의 인입에 따라 가열시 발생하는 솥의 불균일한 열 분포에 대한 화상을 보여준다. 그림에서 좌측 상단의 밝게 보이는 부분이 불량인 부위로 국부적인 과열이 발생하였음을 보여준다. 양품의 솥의 경우는 그림 1(b)에 나타난 것처럼 비교적 균일한 열 분포의 경향을 보여준다.

이와 같은 제조공정에서의 불량에 대처하는 기존의 방법은 샘플검사에 의존하는 수동적인 방법이 주가 되어 왔다[1]. 일부, 음향[10]을 이용하거나 비전시스템[11] 또는 X-ray 기기[12] 등에 의한 비파괴 검사방



(a) 불량 솥의 경우 (b) 양품 솥의 경우

그림 1. 적외선 카메라로 찍은 솥 바닥의 열화상.

Fig. 1. Thermal picture captured with a infrared camera.

법도 사용되고 있으나 장비가 고가이고 작업이 용이하지 못한 단점이 있다.

본 논문에서는 이와 같은 제조공정에서의 불량을 식별하여 제조공정을 개선하는 방법으로서 써모파일(thermopile)이라는 적외선센서에 의해서 온도 분포 데이터를 측정하고, 통계적 패턴인식에 근거하여 기포의 생성 여부를 판단하는 새로운 방법에 대해 연구했다. 이 같은 기포 생성여부의 판별은 해석적인 방법에 의해서도 가능하나, 가열장치와 센서장치에서 일어날 수 있는 여러 불확실성 등으로 인해 정확한 결과물 도출해내기 어렵다. 패턴인식 방법은 일반적으로 발생할 수 있는 시스템 변수나 측정상의 불확실성하에서도 데이터에 약간의 규칙성만 있으면 실질적으로 유용하게 사용할 수 있다. 이 방법은 방사능 동위원소를 사용하는 X-ray 방법보다 안전성, 보관성, 가격성 측면에서 우수하다.

본 연구에서는 패턴인식을 위하여 먼저 decision boundary함수를 설정하고, 데이터를 이용하여 변수들을 설정하는 방법을 사용하였다. 일반적으로 패턴인식

접수일자 : 1999. 5. 26, 수정완료 : 1999. 10. 8

오기태 LG 생활연구소

이순걸 : 경희대학교 기계·산업시스템공학부

* 본 연구는 96년도 경희대학교 신입교수 지원과제비에 의하여 연구되었습니다. 또한 본연구에 도움을 주신 인제대 부광석 교수께도 감사드립니다.


방법으로 많이 사용되는 maximum likelihood 방법은 확률밀도함수(probability density function)를 미리 알아야 하지만, 본 논문에서 사용된 방법은 이와는 달리 샘플 수가 적을 때도 비교적 빨리 변수의 최적치에 근접하는 장점을 갖고있고 또한 학습된 판독기의 성능이 outlier 샘플들에 상대적으로 덜 민감하므로 실제 현장에서 사용되는 검사시스템에서는 매우 유용하다.

II. 시스템 구성

다이캐스팅 접합내의 미소한 공기는 눈으로 식별될 수 없으므로 이를 검사하는 방법으로는 X-ray를 사용하는 비파괴 검사방법이 있으나 이는 고가이고 관리의 어려움이 있어 실 시스템의 적용에는 효과적이지 않다. 보다 효율적인 검사 방법을 위해 비파괴 검사 장치를 제작하였으며 그림 2(a)는 이 시스템의 개략적인 개요를 그린 것으로 솔을 가열기로 가열하고 표면 온도를 측정하여 제안된 알고리즘에 의해 기포의 생성 유무를 판별하는 간접적인 검사 시스템이라고 할 수 있다. 그림에서 A로 표시된 부분은 유도가열 장치이며 수직으로 하강, 상승할 수 있고 B는 검사 대상인 솔로 모터에 의해 일정속도로 회전할 수 있다. 유도가열 장치가 하강하여 약 40초 동안 가열을 한 후 상승하면, B가 회전하게 되고 이 회전과 동기 시켜 C부의 적외선 온도 센서들로

구성된 스캐너에 의해 솔의 온도 분포를 측정한다. 적외선 온도 센서로는 써모파일 센서를 4개 사용하는데, 이 센서는 열전대(thermocouple)와 같이 Zeebeck 효과를 갖으므로 투입된 적외선강도에 따라 전압을 차별화하여 발생시킨다[2]. 이러한 써모파일 적외선 센서는 가전 제품에도 적용된 바 있다[3]. 그림 2(b)에서는 이 같은 원리로 제작된 실 자동화 장치가 가열된 솔의 온도를 측정하는 과정을 보여주고 있다.

그림 3은 측정을 위한 적외선 센서의 배치상태와 그에 따른 조사 과정을 보여준다. 인접한 센서는 반지름 방향으로 광각이 조금씩 겹치도록 배치하여 센서 경계부에서 줄어드는 광량이 일정하도록 보정하였다. 솔의 회전과 함께 센서는 시간에 따른 온도 데이터를 얻게 되고 이를 다시 회전축 중심, 즉 솔의 중앙에서 센서 측정점까지의 반경에 대해 보정하면 솔의 온도분포 데이터를 얻을 수 있게 된다. 측정된 데이터는 조사영역에 대해 반경방향으로 1부터 4까지의 적외선 센서로 나타나고 원주방향으로는 주어진 측정시점에 따른 샘플 번호로 표시한다. 따라서 그림에서 음영으로 표시된 부분은 j번째 센서의 j번째 관찰 영역을 표시한다.



(a) 검사장치의 기능도



(b) 실 제작된 검사 자동화 장치

그림 2. 유도가열과 적외선센서 스캐너를 이용한 비파괴 검사 장치.

Fig. 2. Non-destructive inspect device using induction heater and infrared sensor scanner.




그림 3. 스캐닝 방식.
Fig. 3. Scanning method.

III. 패턴인식 방법

1. 개요

바람직한 유도가열을 위해서는 솔과 유도가열체가 완벽하게 곡면 접촉이 되어야 하나 현실적으로는 제작상 발생하는 요철에 의해 많은 비접촉 부위가 존재하며 가열 후 솔의 온도 분포가 균일하지는 못하다. 또한 적외선 센서는 일반적으로 피사체로부터 투입되는 적외선 양을 온도 데이터로 변환하기 때문에 피사체와의 거리, 피사체의 형상 및 곡률에 영향을 많이 받는다. 이 같은 이유로 인하여 비록 내부에 기포가 없는 양품의 솔이라 할지라도 조사된 데이터가 일정하게 나타나지 않게 된다. 이를 고려한 정확한 열적 해석을 통한 판별은 매우 어렵고 비용도 많이 들게 되므로 양품에 대해 측정된 표준 데이터와 불량률의 경우 측정된 표준 데이터를 이용하여 판독기를 학습시키고 샘플 데이터가 주어졌을 때 주어진 샘플이 어느 패턴에 가까운가를 테스트하여주는 방법이 현장에서 보다 실용적이며 본 논문에서도 이러한 접근 방법을 사용하였다.

따라서 불량 판독 방법으로 타원 함수를 decision boundary 함수로 설정하고 필요한 변수들을 합격과 불합격의 데이터들을 이용하여 설정하는 방법을 제안한다. 이런 방법은 확률밀도함수를 직접 구하는 방법보다 적은 수의 데이터로서 상대적으로 빠르게 시스템변수를 목표치에 근접하게 되는 장점이 있다. M 개의 센서가 조사할 때 샘플링을 매 α° 마다 한다면 1회전에 대해 N , 즉 $360/\alpha$ 회 하므로 매회 조사할 때마다 데이터는 센서 개수 M 과 각도분해능 N 의 곱만큼 생성된다. 물론 신뢰도를 높이기 위해서 조사를 1회전 이상 수행할 수도 있다.

i 번째 센서의 j 번째 조사지점에서 과열이 발생할 사건을 $\omega_1(i, j)$ 라 하고, 발생하지 않을 사건을 $\omega_0(i, j)$ 라 하면, 과열의 발생 유무는 검사를 수행하기 전에는 알 수 없으므로 랜덤 변수 $\omega(i, j)$ 로 정의할 수 있다. 따라서 차원 공간에서 합격과 불량률의 사건도 다음과 같이 ω_0 와 ω_1 에 의하여 정의될 수 있다.

$$\begin{aligned} \omega_0 &= \text{합격} = \text{사건}\{\text{솔의 모든 지점에서 국소적 과열이 없음}\} \\ &= \prod_{i=1}^M \prod_{j=1}^N \omega_0(i, j) \\ \omega_1 &= \text{불합격} = \text{사건}\{\text{솔이 한 지점 이상에서 국소적으로 과열됨}\} \\ &= U - \omega_0 \end{aligned} \tag{1}$$

여기서 U 는 전체 사건을 의미한다. (1)을 다시 표현하면 솔의 불량 여부는 어느 한 지점에서 과열이 발생되었는지에 대한 문제로 정의된다.




그림 5. 전형적인 센서 데이터
Fig. 5. Typical sensor data

2 특징량 선정

솔의 불량률의 발생을 인지하기 위해서는 얻어지는 데이터의 패턴을 고려하여 그 특징적인 유형에 의해 판정을 하여야 한다. 즉 정량적인 데이터 수치에 의한 것이 아닌 정성적인 형태에 의한 데이터의 분석이 필요하며 그에 따른 특징량의 선정이 중요하다. 특징량을 구하고자 할 때 고려할 사항들은 다음과 같다.

1) 초기 가열시 솔의 위치별로 접촉량 편차에 의한 가열편차가 발생하고, 이로 인한 솔의 온도 분포는 부위

별로 차이가 있으며

2) 각 센서마다 물체 표면과의 거리가 다르며, 광각 내에 관찰되는 물체의 곡률 또한 불균일 하다.

3) 센서의 보정이 정확히 일치하지 않으므로 개별 센서들 사이에 적지 않은 편차가 존재하고

4) 주위 온도와 같은 주변환경의 변화로 인하여 일간, 계절간의 검사에 따라 솔의 표면 온도에 차이가 발생되고

5) 시간이 지남에 따라 솔의 표면온도가 급속히 냉각되므로 각각의 센서 데이터는 시간축에 대해 평균적으로 하강한다.

그림 5는 양품의 경우에 대해 2.5주기, 즉 솔의 2.5회전 동안 측정된 센서 데이터를 나타낸다. 그림에서 측정 데이터는 전술한 고려 사항에 대한 충분한 근거를 보여준다. 점선으로 표시된 부분은 인접한 부위에서도 가열편차에 의한 온도 차이가 있음을 보여주며 각 센서의 측정치는 가열 편차 및 센서 편차에 의한 차이, 시간축에 대해 평균적으로 하강하는 온도는 솔의 시간에 따른 냉각현상을 나타낸다. 이 같은 사항들은 검사의 신뢰성을 저하시키고 그릇된 판정 결과를 야기할 수 있으므로 특징량을 선정할 때 충분히 주의하여야 한다.

그림 6(a)는 양품의 솔들에서 얻어진 센서 데이터를, 그림 6(b)는 불량 솔들에서 측정된 센서 데이터를 보여주고 있다. 이들을 비교해보면, 양품의 경우는 센서 데이터간 간격은 거의 균일한 양상을 보여주나 불량품 솔의 경우는 과열지점에서 상당한 차이가 발생한다.

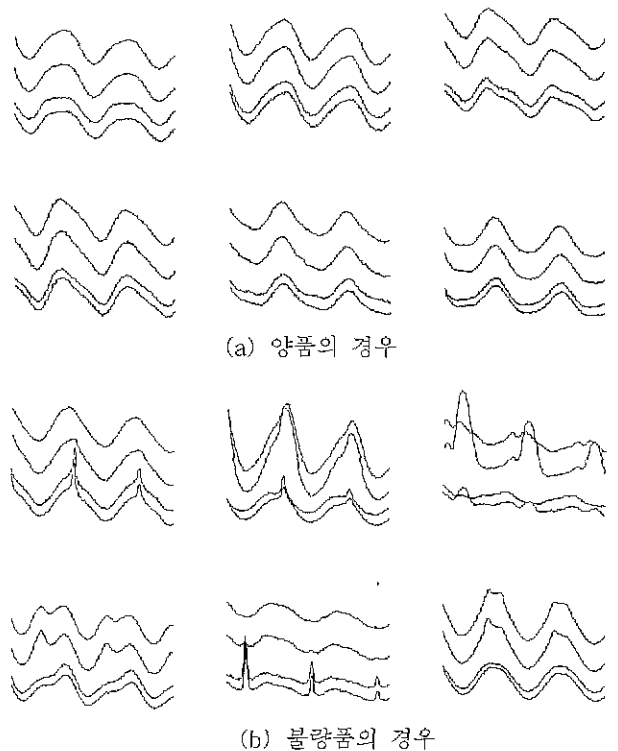


그림 6. 온도분포 데이터.

Fig. 6. Thermal distribution data.

따라서 본 논문에서는 이 같은 센서간 차이를 특징량으로 선정하였다. 물리적으로도 센서간 온도차는 온도의 반경방향 변화율을 나타내므로 중요하다. 임의의 순간, 즉 j 번째 샘플링 시의 i 번째 특징량 $x(i, j)$ 은 $(i+1)$ 번째 센서 데이터 $y(i+1, j)$ 와 i 번째 센서 데이터 $y(i, j)$ 의 차이로 정의되며 그에 따라 특징량 벡터 $x(j)$ 는 아래처럼 센서 데이터간의 선형적인 관계로 표현된다.

$$x(j) = \begin{pmatrix} x(1, j) \\ \vdots \\ x(M-1, j) \end{pmatrix} = \begin{bmatrix} -1 & 1 & 0 & 0 \\ \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & -1 & 1 \end{bmatrix} \begin{pmatrix} y(1, j) \\ \vdots \\ y(M, j) \end{pmatrix} \quad (2)$$

센서 데이터간의 편차를 표현하는 방법으로서 특징량 공간을 그림 7과 같이 구성하였다. 즉 그림은 3차원 특징량의 2차원 단면으로 해석할 수 있으며 가로축과 세로축은 좌측 그림부터 각각 $[x(1, j), x(2, j)]$, $[x(1, j), x(3, j)]$, $[x(2, j), x(3, j)]$ 이다. 따라서 그림 7(a)는 한 합격 술에서 특징량의 통계 분포를 보여주는데 클러스터링화 되어있고, 반면에 그림 7(b)는 한 불합격 술에서 특징량의 분포를 보여주며 몇 개의 점들이 클러스터링 밖으로 놓여 있음을 알 수 있다.

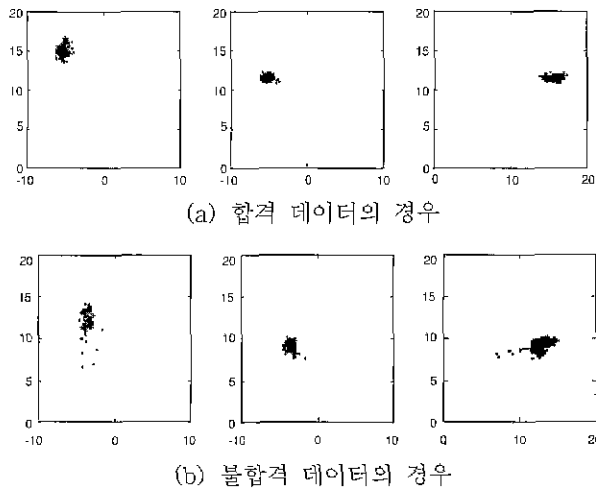


그림 7. 특징량에 의한 센서 데이터의 분포도.
Fig. 7. Distribution of sensor data denoted by characteristic feature.

3. 판독 알고리즘

본 논문에서는 타원형 decision boundary 함수 방식에 의한 패턴인식 방법을 사용하였다. 타원형 방식은 그림 8과 같이 불량과 합격의 사건에 대한 통계분포를 각각 균일분포와 정규분포로 보고 maximum likelihood 방법을 판독 알고리즘으로 적용했을 때 결정 경계선이 타원이 된다는 사실에 기초하고 있다.(Appendix참조). 확률분포함수를 직접 구하지 않고 decision boundary 함수를 구하는 방식은 학습 데이터의 수가 적을 때 유용하고 불량과 합격의 사건을 균일 분포로 보는 것은 과거에도 시도된 바 있다[4]. 데이터의 수가 많고 hard한 분류기

를 설계할 때는 신경망이나 퍼지모델을 사용하여 여러 개의 타원을 조합하여 사용하는 방법이 있으나[7,8,9], 본 연구의 경우와 같이 데이터의 수가 적을 때는 'Curse of Dimensionality'에 의하여 설정해야 할 변수의 개수가 적도록 하는 방법이 일반적으로 성능이 우수하다[6].




그림 8. 타원 함수와 Decision Boundary.
Fig. 8. Ellipsoidal function and decision boundary.

타원형 패턴인식 방법은 다음과 같다. 타원함수의 위치와 모양을 결정짓는 변수벡터와 변수행렬로 각각 $m = (m_1, \dots, m_{n-1})$ 과 $Q = \text{diag}(\sigma_1^2, \dots, \sigma_{n-1}^2)$ 를 사용하면

$$\begin{aligned} \text{If } x(j) \in S, \text{ then } d(j) &= d_0 \\ \text{Otherwise, } d(j) &= d_1 \end{aligned} \quad (3)$$

여기서 $S = \{x | (x-m)Q^{-1}(x-m) \leq 1\}$ 로 주어지고 $d(j)$ 는 j 번째 지점에서의 지역 판정치를 나타내고, d_0 와 d_1 은 각각 합격과 불량으로 지역 판정함을 나타낸다.

시스템 변수를 $\theta = [m_1, \dots, m_{n-1}, \sigma_1^2, \dots, \sigma_{n-1}^2]$ 로 정의하고 k 번째 술에 대한 판정을 $D(k; \theta)$ 라 하면 그 결정을 위한 결과는 다음과 같이 나타난다.

$$\begin{aligned} \text{If } \prod_{j=1}^n d(j) = d_0^n \text{ then } D(k; \theta) &\neq 0 \\ \text{Otherwise } D(k; \theta) &= 1 \end{aligned} \quad (4)$$

시스템 변수들의 최적화는 다음과 같은 비용 함수를 정의하고 이 함수를 최소화 시키는 변수를 구함으로써 얻을 수 있다. 따라서 튜닝된 시스템 변수는 K 개의 학습 데이터들의 함수가 된다. 최소화 과정은 유전자 알고리즘을 사용하였다.

$$R(\theta) = \frac{Vol(\theta)}{\lambda} + \sum_{k=1}^K C(D(k; \theta) | W(k)) \quad (5)$$

$$\text{where, } C(D(k; \theta) | W(k)) = \begin{cases} 1, & \text{if } D(k; \theta) = 1 \text{ and } W(k, \theta) = 0 \\ 10, & \text{if } D(k; \theta) = 0 \text{ and } W(k, \theta) = 1 \\ 0, & \text{Otherwise} \end{cases}$$

여기서, Vol 은 체적, λ 는 penalty 함수의 가중치를 나타

내므로 비용함수는 penalty 함수와 decision boundary 함수에 대한 체적의 조합으로 구성된다고 볼 수 있다.

Penalty 함수는 판정의 정확성을 높여주기 위해 사용하였고 decision 함수의 체적은 일반성을 개선시키는 목적으로 사용된다. 일반적으로 패턴인식 문제가 합격의 경우와 불량률의 경우로 나뉘어질 경우 불량률의 사건에 대한 데이터를 구하기는 쉽지 않다. 구할 수 있는 불량률 데이터의 수가 특징량의 차원 수에 비하여 적을 경우 비용함수에 penalty 함수만 고려할 때에는 탐색 과정에서 여러 가지가 해가 나올 수 있게 된다. 이 경우 체적이 제일 적은 것을 택함으로써 decision boundary의 함수가 outlier 샘플들에 덜 민감하게 하고 추가 비용의 가능성을 적게 하여 일반화 성능을 향상시킬 수 있다.

이 같은 추가 비용의 가능성이란 다음과 같다. 즉 대상 솔이 양품으로 판정되기 위해서는 슬의 1회전 동안 측정된 80개의 시계열 벡터 x 가 모두 타원 내부에 있어야 하나, 불량 판정은 80개의 데이터 벡터 중 하나만 타원 외부로 벗어나면 충분하다. 그러므로 Penalty 함수만을 최소화 할 경우 불량 솔의 데이터 80개 중에서 거리가 제일 먼 것 한 개 이상만 타원밖에 놓이게 하면 불량처리라 충분하므로 그림 9와 같이 동점의 경우가 최적화 과정에서 발생할 수 있게 된다. 이 영역은 충분한 데이터 확보가 이루어지지 않고 decision boundary 함수들 간의 비교가 주어진 데이터만으로는 판정 불가능한 구간이라고 볼 수 있다.




그림 9. 적은 학습 데이터수로 유전자 알고리즘 적용 시 동점이 나올 수 있는 경우.

Fig. 9. The case that has equivalent value, when applying genetic algorithm with small number of data set.

학습 샘플이 훨씬 많아졌을 경우는 이 같은 구간으로 인하여 판정 비용의 차이가 발생한다. 많은 샘플의 경우 합격을 불량으로 처리하는 것이 불량을 합격으로 처리하는 것보다 비용 소요가 적으므로 이 구간을 불량 처리 구간으로 설정함으로써 추가 비용의 가능성을 줄일 수 있다. 이를 위하여 타원의 체적을 비용 함수에 고려하였다.

2 유전자 알고리즘

유전자 알고리즘(genetic algorithm)은 자연계에 존재하는 생물 진화의 적자생존 법칙을 모사화한 확률적 탐색 방법이다. 이 탐색 방법은 복제(reproduction), 교차(crossover), 돌연변이(mutation)와 같은 과정을 통

하여 해집단(population)을 적절히 섭동시켜 가면서 적합도가 높은 해를 다음과 같은 과정으로 구해나간다.

a) 초기화 및 부호화 : 최적화하고자 하는 변수들을 나열한 문자열을 구성하되 복수 개를 구성함으로써 해집단을 구성한다. 각 문자열에 대하여는 생물의 유전 정보인 염색체(chromosome)처럼 부호화한다. 여기서는 2진 부호화를 사용한다.

b) 평가 : 해집단 내의 각 개체 (2진부호열)을 디코딩하여 적합도를 계산함으로써 각 부호열 간의 성능 비교가 가능하도록 한다.

c) 복제 : 해집단 내의 각 개체에 대하여 복제 확률을 지정하되 적합도가 높은 개체에 대하여는 높은 확률을 배정하여 자손세대의 각 개체들을 확률적 방법으로 선택한다.

d) 교배 : 해집단 내의 복수개의 개체들 중에서 확률적으로 쌍을 지어 유전자 정보를 서로 교차 시킴으로써 새로운 개체들을 생성한다.

e) 돌연변이 : 각 개체 내의 2진 부호들을 자연계의 돌연변이 원리처럼 일정한 확률적 통제하에서 변화시킨다. 2진 부호열에서는 1은 0으로 또 0은 1로 부호를 바꾸는 것을 의미한다.

사용된 유전자 알고리즘을 프로그램으로 나타내면 다음과 같다[5].

그림 10에서 $P(t)$ 는 시간 t 에서의 해집단을 나타내고, $a_1(t), a_2(t), \dots, a_L(t)$ 는 시간 t 에서의 L 개의 개체(2진 부호열) 들이다.

3 실험 및 고찰

인식 오차와 체적을 모두 최소화 하기 위한 decision boundary 함수로서 hyper ellipsoid 함수와 hyperbox 함수 2경우를 모두 사용하고 그 결과를 비교 시험하였다.

Hyperbox 함수는 합격과 불합격의 확률밀도함수가 모두 균일 분포 함수일 경우 maximum likelihood에 의

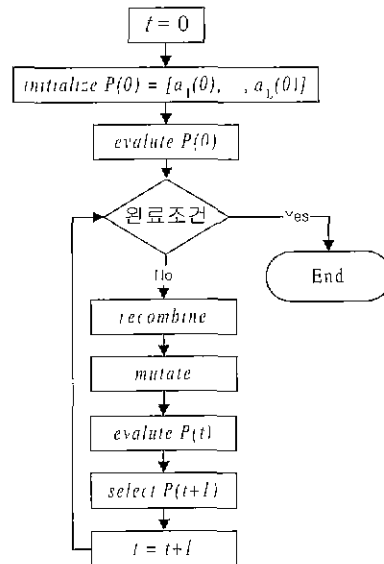


그림 10. 유전자 알고리즘의 흐름도.
Fig. 10. Flowchart of the genetic algorithm.

한 decision 함수가 hyperbox 함수로 되는 것에 근거하고 있다. (Appendix 참조) 실험에 사용된 센서의 수는 4개이므로 $M=4$ 이고, $N=2000$ 으로 놓았으며, 유전자 알고리즘에 필요한 변수들은 표 1과 같이 설정하였다.

표 1. 유전자 알고리즘을 위한 변수.

Table 1. Parameters for genetic algorithm.

변수	설정치
Mutation probability	0.15
Crossover probability	0.70
Population size	40
Maximum generation	200
Fitness	$\frac{1}{1+R(\theta)}$

본 연구를 위해 10개의 불량 솔과 60개의 양품의 솔을 합하여 모두 70개의 솔을 대상으로 데이터를 측정하였다. 이중 임의로 선정된 30개의 합격솔 데이터와 5개의 불량 솔 데이터는 유전자 알고리즘을 위한 학습 (supervised learning) 데이터로 사용하였고, 나머지는 모두 알고리즘 검증용을 위한 테스트 데이터로 사용하였다.

센서의 개수가 4인 경우 결정해야 할 시스템 변수는 모두 6개가 되고 타원 함수를 사용하였을 때 학습된 변수는 $m=(-6.0, 13.5, 8.5)^T$ 과 $Q=diag(5.0^2, 7.0^2, 7.5^2)$ 로 구해졌다. 구해진 변수에 대한 학습 및 인식 실험 결과가 표 2에 나타나 있다. 표에서 보는 바와 같이 hyper ellipsoid 함수를 사용하였을 경우는 학습 과정에서 합격과 불량인 패턴이 모두 학습되었고 테스트 과정에서는 단 1개만의 양품 솔의 데이터가 불량 솔의 패턴으로 오인식 되고 있음을 보여준다. 결론적으로 적은 학습 데이터 ($K=35$)만으로도 양호한 테스트 성능을 보여주고 있음을 알 수 있다

표 2. 실험 결과.

Table 2. Experimental result.

Classifier	함수종류	Hyper ellipsoid	Hyper cube
학습 데이터	W=1, D=0	0	0
	W=0, D=1	0	1
	인식률	100%	97%
체적		1.100	792
테스트 데이터	W=1, D=0	0	0
	W=0, D=1	1	2
	인식률	97%	94%

Hyperbox 함수를 사용한 경우는 학습시 1개의 양품 솔의 데이터가 학습에 오류를 일으키며 인식 시에도 2개의 양품 솔의 데이터가 불량으로 판정이 났다. Hyper ellipsoid 함수의 경우와 유사한 결과를 보여주나 다소 학습 및 인식 성능이 떨어짐을 보여준다.

그림 11은 유전자 알고리즘의 진화과정을 보여주는 그림으로서 가로축은 세대들, 수직축은 적합도 값을 나타낸다. 실선으로 표시한 것은 세대 당 최대적합도이고 점선으로 표시한 것은 한 세대의 평균적합도이다.




그림 11. 적합도 값의 변화 과정.

Fig. 11. Transient response of the value of fitness.

VI. 결론

본 논문을 통하여 간편하고 효율적인 유도 가열 압력 솔의 비파괴 불량 검사 방법을 제안하였다. 다이캐스팅 접합된 솔을 외부 가열기로 가열하고 적외선 온도센서를 이용해 온도분포를 측정후 통계적 패턴인식 방법을 사용함으로써 솔 내부의 기포의 생성 여부를 비파괴 방식으로 잘 검출할 수 있음을 보여주었다.

먼저 단순히 측정된 온도의 시간에 따른 데이터가 아니라 센서 데이터간 온도차를 특징량으로 선정함으로써 여러 가지 불확실성들로 야기되는 문제점들을 최소화 할 수 있었다. 또한 판독 알고리즘에서는 타원형 decision boundary 함수를 적용하되 변수들의 최적화에 decision 함수의 체적을 함께 고려함으로써 일반화된 특성을 높였다. 본 연구의 결과 제안된 알고리즘이 적은 수의 표본 데이터를 가지고도 높은 인식률을 갖는 통계적 패턴 인식 방법임을 입증할 수 있었다.

참고문헌

- [1] IH압력밥솥에 관한 보고서, LG전자 조리기기OBU 설계실, 1997.
- [2] A. W. Van Herwaarden, D. C. Van Duyn and B. W. Van Oudheusden, "Integrated thermopile sensor," *Sensor and Actuators*, A21-A23, pp. 621-630, 1989.
- [3] K. S. Lee et al., "Applications of the thermopile infrared sensor to the home appliances," *Proc. of 1998 Appliance Manufacturer Conference & Expo.*, pp. 21-32, Nashville, Tenn., October 12-14, 1998.
- [4] P. Smyth and J. Mellstrom, "Failure monitoring in dynamic systems. model construction with-

out fault training data,” *Telecommunications and Data Acquisition Progress Report*, vol 112, pp. 37-49, Jet Propulsion Laboratory, Pasadena, CA, Feb 15th, 1993.

- [5] T. Back and Hans-Paul Schwefel, “An overview of evolutionary algorithms for parameter optimization,” *Evolutionary Computation* 1 (1), pp. 1-23, 1993.
- [6] Duda and Hart. *Pattern Recognition and Machine Intelligence*, Prentice Hall, 1972.
- [7] R. Schalkoff, *Pattern Recognition*, John Wiley & Sons, Inc. 1992.
- [8] J. C. Bezdek and S. K. Pal, *Fuzzy Models For Pattern Recognition*, IEEE Press, 1992.
- [9] S. Abe and R. Thawonmas, “A fuzzy classifier with ellipsoidal regions,” *IEEE Trans. Fuzzy System*, vol. 5, pp. 358-368, Mar. 1997.
- [10] L. P. Karasev, E. D. Mezintsev, and K. V. Khilkov, “Using defect simulators in developing methods of acoustic emission inspection combined with strength tests of vessels.” *Technical diagnostics and nondestructive testing*, vol. 3, pp. 33. 1991.
- [11] P. Perner, “A knowledge-based image-inspection system for automatic defect recognition, classification, and process diagnosis,” *Machine vision and applications*, vol. 7, pp. 135. 1994.
- [12] V. N. Potapov, N. G. Belyi, V. S. Grom, “Increasing the contrast of defect images in radiation inspection of welded joints”, *Technical diagnostics and nondestructive testing*, vol. 1, pp. 74, 1989.

부록

A.1 균일 분포의 경우

$L = M-1$ 일 때 L 차원에서 j 번째 지점에서의 합격과 불합격 사건의 ω_0, ω_1 의 확률밀도함수가 균일 분포를 갖으면서 i.i.d (independent and identically distributed) 하다고 가정하면, 각 사건별 조건부 확률밀도함수는

$$p(\mathbf{x}(j) | \omega_0(j)) = p(\mathbf{x} | \omega_0) = \begin{cases} \frac{1}{S_0} & \text{for } \mathbf{x} \in [a_{1,1}, a_{1,2}] \times \dots \times [a_{L,1}, a_{L,2}] \\ 0 & \text{otherwise} \end{cases} \quad (A.1)$$

$$p(\mathbf{x}(j) | \omega_1(j)) = p(\mathbf{x} | \omega_1) = \begin{cases} \frac{1}{S_1} & \text{for } \mathbf{x} \in [b_{1,1}, b_{1,2}] \times \dots \times [b_{L,1}, b_{L,2}] \\ 0 & \text{otherwise} \end{cases} \quad (A.2)$$

여기서 S_0, S_1 은 각각

$$S_0 = \int p(\mathbf{x} | w_0) dx = (a_{1,2} - a_{1,1})(a_{2,2} - a_{2,1}) \dots (a_{L,2} - a_{L,1}) \quad (A.3)$$

$$S_1 = \int p(\mathbf{x} | w_1) dx = (b_{1,2} - b_{1,1})(b_{2,2} - b_{2,1}) \dots (b_{L,2} - b_{L,1})$$

식 (A.3)으로 주어지며, 미지의 변수들은 $a_{1,1}, a_{1,2}, \dots, a_{L,1}, a_{L,2}, b_{1,1}, b_{1,2}, \dots, b_{L,1}, b_{L,2}$ 로 총 $4(M-1)$ 개가 된다.

Decision boundary는 확률밀도가 같다는 조건으로부터 $p(\mathbf{x}|w_0) = p(\mathbf{x}|w_1)$ 이라고 놓으면 hyperbox 함수가 되고 미지의 변수들은 $\theta = (b_{1,1}, b_{1,2}, \dots, b_{L,1}, b_{L,2})$ 이며, 패턴구별은 다음과 같이 주어진 샘플 \mathbf{x} 가 이 boundary의 내부에 있는지 외부에 있는지를 조사함으로써 가능하다.

$$\begin{aligned} \text{If } \mathbf{x}(j) \in S, \text{ then } d(j) &= d_0 \\ \text{Otherwise, } d(j) &= d_1 \end{aligned} \quad (A.4)$$

where, $S = \{ \mathbf{x} | b_{1,1} \leq x_1 \leq b_{1,2}, \dots, b_{L,1} \leq x_L \leq b_{L,2} \}$

A.2 정규 분포의 경우

균일 분포에서와 유사하게 L 차원에서 j 번째 지점에서의 ω_0, ω_1 의 확률밀도함수가 정규분포를 갖으면서 i.i.d. 하다고 가정하면, 각 사건별 조건부 확률밀도 함수는 식 (A.4) 및 (A.5)와 같이 주어진다.

$$p(\mathbf{x}(j) | \omega_0(j)) = p(\mathbf{x} | \omega_0) = (2\pi)^{-L} |\Sigma|^{-\frac{1}{2}} \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{m})' \Sigma^{-1} (\mathbf{x} - \mathbf{m}) \right] \quad (A.5)$$

$$p(\mathbf{x}(j) | \omega_1(j)) = p(\mathbf{x} | \omega_1) = \begin{cases} \frac{1}{S_1} & \text{for } \mathbf{x} \in [b_{1,1}, b_{1,2}] \times \dots \times [b_{L,1}, b_{L,2}] \\ 0 & \text{otherwise} \end{cases} \quad (A.6)$$

여기서, $S_1 = \int p(\mathbf{x} | w_1) dx = (b_{1,2} - b_{1,1})(b_{2,2} - b_{2,1}) \dots (b_{L,2} - b_{L,1})$ 이며, decision boundary는 확률밀도가 같다는 조건으로부터 $p(\mathbf{x}|w_0) = p(\mathbf{x}|w_1)$ 라고 놓으면 다음과 같은 hyper ellipsoid 함수가 되고,

$$\begin{aligned} (\mathbf{x} - \mathbf{m})' Q^{-1} (\mathbf{x} - \mathbf{m}) &= 1 \\ \text{where, } Q^{-1} &= \Sigma^{-1} / (2 \log S_1 - L \log(2\pi) - \log |\Sigma|) \end{aligned} \quad (A.7)$$

패턴구별은 다음과 같이 주어진 샘플 \mathbf{x} 가 이 boundary의 내부에 있는지 외부에 있는지를 조사함으로써 가능하다.

$$\begin{aligned} \text{If } \mathbf{x}(j) \in S \text{ then } d(j) &= d_0 \\ \text{Otherwise } d(j) &= d_1 \end{aligned} \quad (A.8)$$

where $S = \{ \mathbf{x} / (\mathbf{x} - \mathbf{m})' Q^{-1} (\mathbf{x} - \mathbf{m}) \leq 1 \}$

여기서


$$\mathbf{m} = (m_1, \dots, m_L), Q^{-1} = \text{diag} \left(\frac{1}{\sigma_1^2}, \dots, \frac{1}{\sigma_L^2} \right) \text{이다.}$$



오 기 태

1960년 8월 3일생. 1983년 연세대학교 기계공학과 졸업. 1985년 KAIST 생산공학과 (공학석사). 1995 Case Western Reserve Univ. 시스템공학과 (공학박사) 1985년~현재 LG전자

Home Appliance 연구소 책임연구원. 관심분야는 Detection, Data Mining, 통계적 정보이론, Markovian Jump System 제어.



이 순 걸

1961년 2월 10일생. 1983년 서울대학교 기계공학과(공학사). 1985년 KAIST 생산공학과(공학석사). 1993년 Univ. of Michigan 기계공학과 (공학박사). 1994년~1996년 KIST

휴먼로봇센터 선임연구원. 1996년~현재 경희대학교 기계산업시스템공학부 교수. 관심분야는 로봇틱스 및 제어, 생체역학, Java를 이용한 원격제어, 메카트로닉스.