

주성분 분석과 이차 판별 분석 기법을 이용한 항공기 복합재료에서의 자동 결함 검출 및 분류

Automatic Defect Detection and Classification Using PCA and QDA in Aircraft Composite Materials

김 영 범 · 신 덕 하 · 황 승 준 · 백 중 환*

한국항공대학교 정보통신공학과

Young-Bum Kim · Duk-Ha Shin · Seung-Jun Hwang · Joong-Hwan Baek*

Information & Telecommunication Engineering, Korea Aerospace University, Gyeonggi-do, 412-791, Korea

[요 약]

본 논문에서는 항공기 복합재료 내부의 결함을 자동으로 검출하고 분류하는 초음파 검사 방식을 제안한다. 결함 검출을 위해서 초음파의 국부 최대값을 이용해 피크(peak) 값을 추출해낸다. 피크의 거리정보를 이용해 히스토그램화 하며 시편의 표면과 바닥의 백월 에코(back-wall echo)를 결정한다. 이를 통해 C-scan 영상을 생성한다. 검출된 피크의 평균과 분산을 이용해 임계값을 정하고 그 값으로 결함여부를 판단한다. 결함의 종류를 구분하기 위해서는 주성분 분석(PCA; principal component analysis)와 이차 판별 분석(QDA; quadratic discriminant analysis)을 수행하였다. PCA를 통한 512개의 차원은 주성분으로 변환 시 30개의 주성분에 99% 이상의 분산이 포함되었다. 주성분 개수를 한정시킴으로써 차원 축소를 통해 계산량을 크게 줄였고 오분류를 최소화하였다. 이차 판별 분석을 적용해 결정경계(decision boundary)의 방정식을 얻었고 이를 통해 결함을 분류할 수 있음을 실험을 통해 보였다.

[Abstract]

In this paper, we propose a ultra sound inspection technique for automatic defect detection and classification in aircraft composite materials. Using local maximum values of ultra sound wave, we choose peak values for defect detection. Distance data among peak values are used to construct histogram and to determine surface and back-wall echo from the floor of composite materials. C-scan image is then composed through this method. A threshold value is determined by average and variance of the peak values, and defects are detected by the values. PCA(principal component analysis) and QDA(quadratic discriminant analysis) are carried out to classify the types of defects. In PCA, 512 dimensional data are converted into 30 PCs(Principal Components), which is 99% of total variances. Computational cost and misclassification rate are reduced by limiting the number of PCs. A decision boundary equation is obtained by QDA, and defects are classified by the equation. Experimental result shows that our proposed method is able to detect and classify the defects automatically.

Key word : Defect detection, classification, PCA, QDA, Aircraft composite material.

<http://dx.doi.org/10.12673/jant.2014.18.4.304>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 28 July 2014; Revised 21 August 2014

Accepted (Publication) 20 August 2014(30 August 2014)

*Corresponding Author, Joong-Hwan Baek

Tel: +82-10-3308-0125

E-mail: jhbaek@kau.ac.kr

1. 서론

항공기 제작용 복합재료는 각 소재의 장점을 살려 혼합 사용하므로 개별적 구성의 소재보다 월등한 기계적, 기능적 특성을 갖는다. 복합재료로 구성된 비행기 동체나 날개의 제작 시 발생하는 결함의 검출을 위해 개별 소재의 검사와는 차별되는 비파괴 검사기법(NDT; non-destructive test) 또는 비파괴 평가기법(NDE; non-destructive evaluation)이 필요하다. 단일 재료의 금속구조 항공기와 달리 복합재료 항공기는 외관상 아무 이상 없어도, 내부적으로 미세충간 분리 및 균열 같은 BVID(barely visible impact damage)가 생길 수 있다. 운항 중 결함커지거나, 결함부위의 하중이 커지면 구조물의 갑작스런 파국적 고장(catastrophic failure)을 초래할 수 있어, 반드시 이들 손상부위의 위치를 비행 전 감지해 구조물수리교범(SRM; structural repair manual)에 따른 수리절차를 통해 결함을 원상 복귀한 상태로 운행해야 한다. 복합재료는 시험 데이터의 상대적인 부족, 적층각 및 순서에 따른 다양한 기계적 공정과 및 수리기법 등으로 인해 보다 향상된 NDT/NDI/NDE 등의 기술이 필요하다. 항공기 복합재료 구조물의 내부 품질 검사 중 가장 효율적인 검사기술은 초음파 이용 비파괴 검사기술이다. 이는 함유물이나 공간 등의 경계면에서 반사 또는 산란되는 초음파의 특성을 이용해 결함의 유무 및 크기를 판단하는 기술이다 [1],[2].

결함이란 이물질이 시편 내부에 포함됐거나, 갈라짐이나 벌어짐 등을 의미하는데 초음파가 조사될 경우 반사, 퍼짐 등의 파형변화가 생긴다. 이를 응용해 실제현장에서 통용되는 방법은 결함에 의해 파형이 변화된 부분이라 생각되는 시간영역에 대해서만 에너지를 취해 영상으로 변환하는 방법인 게이티드 피크(Gated Peak)방법이다. 이를 통해 C-scan 영상을 얻는다. 이 방법은 검사자의 경험적 파형분석능력이 중요하게 작용하기 때문에 오퍼레이터가 높고 시간이 많이 소요된다. 또한 결함의 형태나 재료의 종류에 따라 판정 기준이 달라지므로 결함의 종류구분이 매우 중요하다. A-scan 영상만으로는 결함의 종류를 구분할 수 없으므로 결함의 파형분석이 필수적이다.

이를 개선하기 위해 본 논문은 자동으로 결함 검출 및 분류를 위한 시스템을 구성하였다. 자동 결함 검출의 시작은 영상을 생성하는 단계다. Gated Peak 방식을 그대로 따르면서 자동 C-scan 영상 생성 방법으로 국부 최대값을 이용하였다. 이를 통해 주된 피크(peak)들을 검출하고 이들의 거리정보를 이용해 히스토그램을 생성한다. 생성된 히스토그램을 통해 표면 반사에 의한 피크와 백월에코를 찾아 결정한다. 얻어진 표면 반사와 백월에코 데이터를 이용해 게이트를 자동으로 정의하고 C-scan 영상을 생성한다.

이 후 결함의 검출을 위해 얻어진 파형의 표면 반사에 의한 피크에 따라 모든 파형을 정렬한다. 정렬된 파형은 피크를 이미 검출한 상태이므로, 피크의 평균과 분산을 이용해 임계값을 정하고 결함의 여부를 결정한다. A-scan 파형의 차원은 매우 커서 주성분분석을 통해 512개의 파원을 주성분으로 변환했

고 이중 30개의 주성분에 99%의 총분산이 포함되도록 하였다. 차원의 축소를 통해 계산량이 크게 줄었다. 주성분분석을 거친 벡터는 이차편별분석을 통한 비선형적(non-linear) 분류로써 결함분류의 정확성을 높일 수 있었다.

본 논문의 2장에서는 A-scan 파형의 구조와 형태를 알아본다. 3장에서는 C-scan 영상생성 및 다른 방법들과 그에 해당하는 문제점을 살펴보고 자동으로 C-scan 영상을 생성하는 방법을 제안한다. 4장에서는 생성된 정보를 이용해 A-scan 파형을 이용해 결함의 검출방법을 제시하고, 자동 결함 검출 알고리즘의 효율성을 확인하였다. 5장에서는 검출된 결함의 종류를 구분하는 방법에 대해 제안한다.

II. A-scan 파형의 구조 및 영상생성

2-1 A-scan 파형의 구조

초음파 검사의 장점은 시험체가 두꺼워도 검사가 가능하며 불연속의 위치와 깊이를 정확히 알 수 있다. 검출되는 A-scan 파형은 시편에 초음파를 조사시켜 시간에 따라 반사되는 신호의 세기를 측정된 데이터이다. 미상의 물질이 시편 내부에 존재하거나 이상이 발견되면 반사되는 에너지를 이용해 결함여부를 판단할 수 있다.

2-2 결함의 A-scan 파형

초음파는 매질에 따라 투과 속도가 다르기 때문에 새로운 매질을 만나면 반사가 생긴다. 처음 생기는 피크치(first peak)는 시편의 표면을 맨처음 초음파가 투과 시 생기는 반사에너지이며 백월에코(back-wall echo)는 바닥면을 초음파가 반사할 때 생기는 에너지이다. 대부분의 결함(defect)은 first peak와 백월 에코 사이에 존재하며, 결함이 없는 시편의 A-scan 데이터는 first peak와 백월에코에서만 주요한 성분으로 존재하며 기타 미세한 값의 변화는 고려치 않는다. 시편사이에 동판을 넣은 후 동판의 팽창과 수축을 이용해 시편사이의 공간을 만들었으며, 백월에코의 유무로는 결함을 판단할 수 없다. 결함이 포함된 파형은 결함의 종류에 따라 복잡하고 다양한 변화를 나타낸다. 결함의 종류는 박리(delamination), 비접착(disbonds), 삼입(inclusion), 다기공(porosity), 부식(Corrosion), 충격(Impact Damage)으로 구분된다.

2-3 실험환경

데이터의 픽셀 별 샘플수는 512 이며, 3:2의 종횡비(aspect ratio)를 가지고 있다. 또한 탐촉자(probe)는 5Mhz를 주로 사용였고 픽셀간 간격은 0.02인치이며 0° 수직 탐상 검사를 적용하였다.

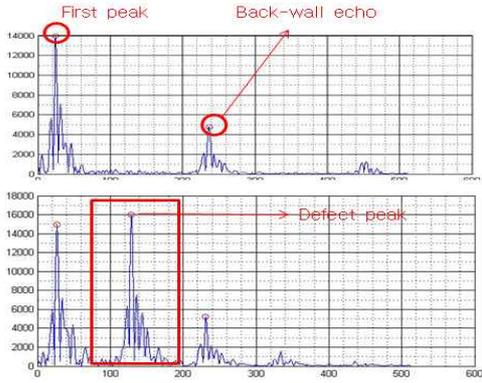


그림 1. 결함 없는 영역(상)과 결함 영역(하)의 A-scan 파형
 Fig. 1. A-scan of non-defected area(top) and defected area(bottom).

초음파와 스캐닝으로 얻어진 Voxel 파일을 Matlab 파일 형식으로 변환하였다. 그림 1은 결함이 없는 영역과 결함이 있는 영역의 A-scan 파형을 보인다. x-축은 초음파의 진행시간을 나타내며 y-축은 반사파의 진폭을 나타낸다[3].

III. A-scan 파형의 구조 및 영상생성

3-1 기존방법

1) 게이티드 피크(Gated Peak)

게이티드 피크방법은 일반적으로 필드에서 사용되는 수동적인 방법이다. 게이티드 피크 방법의 요점은 결함이라 의심되는 부분에 게이트라는 필터를 설정하여 필터를 통과한 에너지만 취하여 영상을 생성하는 방법이다. A-scan은 시험기기에 수신된 RF파형을 정류해 절대값만 취해 파형을 형성하고, 이때 시간 축을 기준하여 임의의 게이트를 설정해 일정 레벨을 넘어서 피크의 level을 설정하는 방식이다. 그림 2는 게이티드 피크의 방식을 나타내고 있다.

일반적으로 게이트는 표면 반사 이후부터 정의하게 되며 잘 정의된 게이트를 통과한 에너지에 의해 생성된 영상의 예는 그림5(a)와 같다. 디지털 신호 시스템은 0, 1의 복원에 충실하면 되므로 원신호의 복원이 목적인 아날로그 시스템과는 차이점이 많다. 따라서 정합필터를 사용해 최대의 SNR을 갖도록 신호를 왜곡시켜서 0, 1을 구분하기 용이하게 만든다. 결과적으로 전송구간에서 발생하는 잡음을 수신단에서 최소화할 수 있다. 이 특성을 이용해 검사자는 미리 결함을 가진 파형의 형태를 예측해 템플릿(template) 파형을 설계하고 이를 이용해 영상을 생성한다.

2) 정합필터 방법(Matched filter method)

신호 $x_i(t)$ 가 스캔 라인의 i번째 위치일 때 $x_i(t)$ 는 식(1)과 같이 정의 된다.

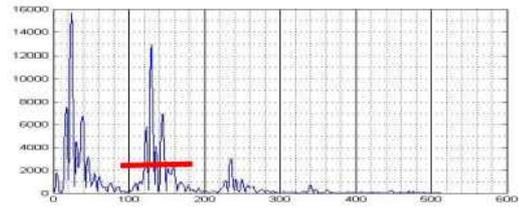


그림 2. 게이티드 피크 방법
 Fig. 2. A method of gated peak.

$$x_i(t) = h_i(t) * r_i(t) + n_i(t) = s_i(t) + n_i(t) \quad (1)$$

h_i 는 시스템 혹은 재료의 효과를 포함한 입력펄스이며 r_i 는 임펄스 응답함수, n_i 는 잡음이다. 필터를 통과한 신호 s_i 는 초음파의 산란이나 다른 환경요인에 의해 왜곡된 신호가 된다.

정합필터의 템플릿은 $s_i^m = h_i^m * r_i^n$ 의 역으로 계산될 수 있다. 이상적인 결과는 $s_i^m = s_i$ 이지만 이는 자연과 같은 여러 가지 문제들에 의해 영향 받는다. i번째 위치의 신호 x_i 의 상관도는 식(2)와 같다.

$$\begin{aligned} \beta_m &= \sum_t s_i^m(t) x_i(t) = \sum_t s_i^m s_i(t) + \sum_t s_i^m(t) n_i(t) \\ &= \partial_m + \partial_n \end{aligned} \quad (2)$$

$\partial_m = 1$ 은 이상적인 경우로 최고의 성능을 나타낼 수 있고 ∂_m 이 1보다 작은 경우 좋은 성능을 나타낸다. β_m 의 분포가 왼쪽으로 이동시 성능저하를 의미한다.

3) 공간 상관도 방법(Spatial correlation method)

인접한 신호는 정합필터에 비해 더 비슷한 형태를 갖는다. $N \times M$ 크기의 영상과 각 픽셀 별 T 개의 샘플 데이터가 존재하기 때문에 A-scan 데이터의 크기는 $N \times M \times T$ 크기가 된다. 따라서 $x = x_{i,j}(t)$ 라 하며 $i = 1 \dots N, j = 1 \dots M$, 그리고 $t = 0 \dots T - 1$ 의 범위를 가진다. 식(3)은 A-scan 파형간의 상관계수를 나타낸다.

$$\rho = \frac{\sum_{t=t_i}^{t_f} (x_{i,j}(t-\tau) - m_{i,j})(x_{i+\delta,j+\delta}(t) - m_{i+\delta,j+\delta})}{\sqrt{\sum_{t=t_i}^{t_f} (x_{i,j}(t-\tau) - m_{i,j})^2} \sqrt{\sum_{t=t_i}^{t_f} (x_{i+\delta,j+\delta}(t) - m_{i+\delta,j+\delta})^2}} \quad (3)$$

크기에 따른 의존성을 제거하기 위해 ρ 는 -1과 1 사이의 값으로 정규화(normalize)를 수행했다. m은 평균값이며 τ 는 두 신호 사이의 이동을 나타내고, δ 는 공간적인 이동 매개변수(parameter)이다. t_i 와 t_f 는 시작점과 끝점을 나타낸다.

3-2 제안한 방법

기존 방식에서 정합필터 방식은 설계자가 직접 결함 파형을 예측하여 필터를 설계하므로 전문성이 요구되며, 공간 상관도 방법은 임펄스 잡음(impulse noise)에 매우 민감하게 작용한다. 본 논문에서는 표면 반사와 백월에코를 검출하기 위해 각 파형의 최대값으로 정렬하는 전역정렬법(global alignment)을 수행한다. 전역정렬법은 시편의 표면에서 피크의 값이 최대값이 된다고 가정하고 파형을 표면 반사를 기준으로 정렬하는 기법이다. 이후 각 파형별로 국부 최대값을 이용해 주된 피크를 결정한다. 피크의 결정 시 피크의 값이 해당하는 층의 임계치에 따른다. 임계치는 식(4)와 같이 결정된다.

$$\text{임계치 (threshold)} = \mu - 2\sigma \quad (4)$$

가우시안 분포는 $\mu \pm 2\sigma$ 내에 95% 이상의 파형이 존재하므로 대부분의 결함을 포함하지 않는 파형들이 임계치 안에 포함된다. 그림 3에서 $\mu \pm k\sigma$ 보다 값이 크면 빨간색으로 표시하고 값이 작으면 파란색으로 표시했다. 웨이트값인 k 는 초기에 2로 설정했으며 범위를 벗어나는 값들은 특이값으로 간주한다. 그림 4는 국부 최대값과 정해진 임계치를 이용해 검출된 피크들을 나타낸다.

이 피크를 이용해 거리 히스토그램을 생성한다. 사용된 데이터는 검사시 탐촉자와 시편간의 거리를 일정하게 유지시키며 검사하기 때문에 파형의 이동은 매우 적은 편이다. 그러므로 가장 많이 검출되는 위치는 표면이라 할 수 있으며, 이를 이용해 히스토그램에서 가장 많은 위치의 값을 표면 반사로 여긴다. 백월에코는 결함의 존재 여부에 따라 값이 달라지고 위치의 이동이 일어날 수 있어 표면 반사 보다는 작은 피크값을 갖는다.

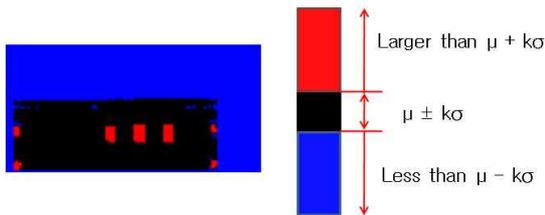


그림 3. 임계치 기반 영역 분할
Fig. 3. Region segmentation based on threshold.

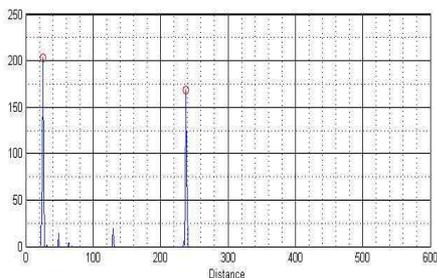


그림 4. 거리 히스토그램 결과
Fig. 4. A result of distance histogram.

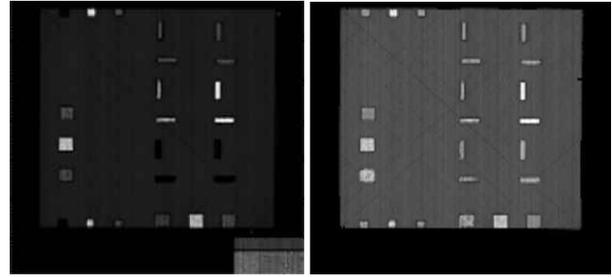


그림 5. Gated Peak 영상(좌)과 자동생성 영상(우)
Fig. 5. Gated peak(left) and automatic formed image(right).

그림 5에서 보듯이 제안한 방법으로 자동 생성된 영상에서 결함의 모양과 크기가 잘 나타났으며 손실된 영역을 최소화 할 수 있었고, 결함 영역의 대비가 확실한 영상을 얻었다 [4].

자동 영상 생성 알고리즘 과정

1. 모든 파형을 최대값에 정렬(전역정렬법 수행)
2. 각 파형의 국부 최대값을 이용해 피크 검출
3. 피크의 값이 $\mu - 2\sigma$ 보다 작으면 제거
4. 검출된 피크의 거리를 히스토그램화
5. 가장 많은 크기를 가지는 두 피크의 위치를 표면 반사와 백월에코로 간주
6. 표면 반사와 백월에코 사이에 게이트 설정 영상확득

IV. 결함의 검출과 분류

4-1 국부최대값을 이용한 영상 생성과 결함검출

그림 4에서 생성한 거리 히스토그램과 피크 검출을 이용해 결함을 검출한다. 결함을 검출할 때는 피크가 해당 샘플의 $\mu \pm 2\sigma$ 에 속하지 않을 시 결함으로 판단하였다. 그림 6에서 이를 확인할 수 있으며, 표 1은 결함의 설계된 크기와 검출된 크기를 나타낸다. σ 값을 변화시켜 사용자가 임의로 임계치를 변화시켜 결함구분의 정확도를 조절할 수 있다. 또한 임계치 변화에 따른 결함모양의 내부외부의 에너지를 이용해 결함의 구분을 용이하게 할 수 있다.

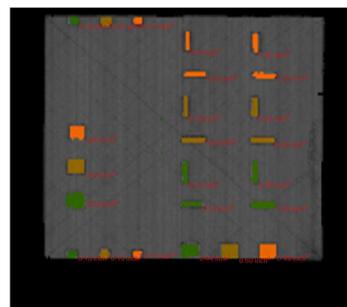


그림 6. 자동결함검출 결과
Fig. 6. A result of automatic defect detection.

표 1. 실제 결함 크기와 자동으로 검출된 결함의 크기 비교

Table 1. Comparison between actual defect sizes and automatic detected defect sizes.

순서	크기		순서	크기	
	실제	결과		실제	결과
1	0.49	0.40	13	0.25	0.20
2	0.49	0.50	14	0.25	0.25
3	0.49	0.59	15	0.25	0.24
4	0.49	0.44	16	0.25	0.24
5	0.49	0.50	17	0.25	0.26
6	0.49	0.49	18	0.25	0.36
7	0.25	0.15	19	0.16	0.14
8	0.25	0.22	20	0.16	0.21
9	0.25	0.16	21	0.16	0.12
10	0.25	0.23	22	0.16	0.13
11	0.25	0.23	23	0.16	0.15
12	0.25	0.22	24	0.16	0.11

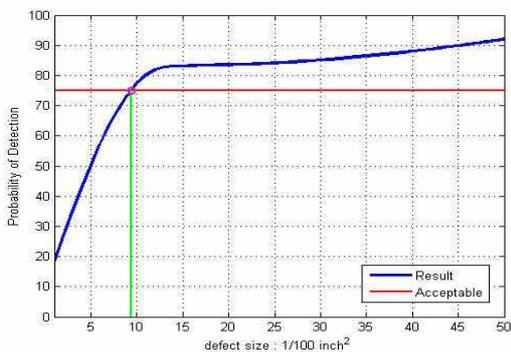


그림 7. 결함 크기에 따른 결함 검출 확률

Fig. 7. Detection probability depend on defect size.

그림 7은 결함 크기에 따른 결함 검출 확률을 나타낸다. 실제 필드에서 사용시 0.38 inch × 0.38 inch 이상부터 결함으로 판단하고, 75%이상의 면적이 검출되면 결함을 찾은 것으로 정의한다. 본 논문의 자동 결함 검출 방식을 따를 때는 0.09 inch² 즉 0.3 inch × 0.3 inch 이상부터 검출확률이 75%이상으로 나타났다. 이를 통해 자동 결함 검출 알고리즘의 효율성을 확인하였다.

4-2 파형분류를 통한 결함 분류

1) 주성분 분석(PCA:Principal Component Analysis)

다변량 통계 분석 방법인 주성분 분석은 데이터의 차원을 축소하거나, 고차원의 데이터로부터 데이터의 구조를 나타낸다. 이는 데이터를 한 개의 축에 사상시켰을 때 그 분산이 최대가 되는 축부터 순서대로 차례로 놓이도록 새로운 좌표계로 선형 변환한다. 이렇게 변환된 벡터들을 주성분 (PC: Principal component)라 한다. 이러한 주성분에서 분산이 작은 주성분들을 제거한다. 이 과정을 통해 데이터의 차원은 축소되고, 데이터에 포함되어 있던 잡음이 제거된다.

입력 벡터 x 를 N 차원 이라 하면,

$$\bar{x}_i = \frac{1}{M} \sum_{i=1}^M x_i, \quad \Phi_i = x_i - \bar{x}_i \tag{5}$$

식(5)와 같이 벡터의 평균을 계산하여 입력 벡터와의 차를 구한다.

$A = \Phi_1, \Phi_2, \Phi_3, \dots, \Phi_M$ 과 같이 $N \times M$ 크기의 행렬 A 를 구한다.

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = AA^T \tag{6}$$

행렬 A 을 이용해 식(6)의 공분산 행렬 C 를 구한다. 생성된 공분산 행렬 C 로부터 고유값 ($C: \lambda_1 > \lambda_2 > \lambda_3 \dots > \lambda_N$)과 고유벡터 ($C: u_1, u_2, u_3, \dots, u_N$)를 연산한다.

C 는 대칭 행렬이고, $u_1, u_2, u_3, \dots, u_N$ 는 기저를 구성한다. 따라서 식(7)과 같이 $x_i - \bar{x}_i$ 는 고유벡터들의 선형 조합으로 다시 쓸 수 있다.

$$x_i - \bar{x}_i = b_1 u_1 + b_2 u_2 + \dots + b_N u_N = \sum_{i=1}^N b_i u_i \tag{7}$$

식(7)의 선형조합을 값이 큰 고유 값에 대응 되는 K 개의 벡터를 식(8)과 같이 선택한다.

$$x_i - \bar{x}_i = \sum_{i=1}^K b_i u_i, \text{ where } K \ll N \tag{8}$$

이를 통하여 $x_i - \bar{x}_i$ 의 기저벡터 $u_1, u_2, u_3, \dots, u_N$ 은 벡터 $b_1, b_2, b_3, \dots, b_N$ 으로 표현된다.

따라서, N 차원에서 K 차원($N > K$)으로의 선형변환은 식(9)로 나타낼 수 있다 [6].

$$\begin{pmatrix} b_1 \\ b_2 \\ \dots \\ b_k \end{pmatrix} = \begin{pmatrix} u_1^T \\ u_2^T \\ \dots \\ u_k^T \end{pmatrix} (x - \bar{x}) = U^T (x - \bar{x}) \tag{9}$$

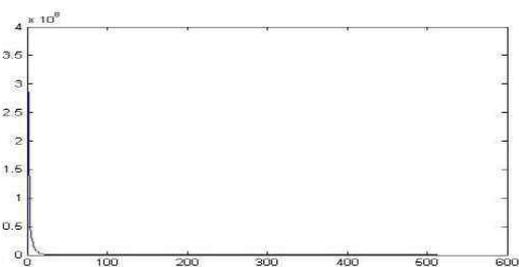


그림 8. 주성분들의 분산

Fig. 8. Variance of principal components.

그림 8은 A-scan 데이터에 대한 주성분분석을 수행한 후 각 주성분들의 분산을 나타낸다. 처음 30번째 까지 거의 모든 정보가 포함되어 있음을 확인할 수 있으며 이를 통해 512차원의 데이터를 30차원의 데이터로 대폭 축소할 수 있었다 [5],[6].

2) 이차 판별 분석(QDA:Quadratic Discriminant Analysis)

분류목적의 판별분석에서는 범주들을 가장 잘 구별 짓는 변수들의 선형 또는 비선형의 하나 또는 다수의 함수를 도출하여 이를 기반으로 분류규칙을 제시한다. 이러한 판별함수는 피셔(Fisher)방법이나 의사결정이론으로부터 유도되는데, 의사결정이론에서는 주로 다 변량 정규분포를 사용한다. 이때 정규분포의 분산-공분산행렬이 범주별로 다르다고 가정하면 이차식의 판별함수가 유도되므로 이 경우를 이차판별분석(QDA: Quadratic Discriminant Analysis)라 한다. 이차판별함수는 정규 분포의 공분산 행렬의 종류에 따라 여러 가지 행렬로 나타낼 수 있다.

데이터가 다변량인 경우, 가우시안 확률밀도함수의 일반식은 식 (10)과 같다.

$$f_i(x) = \frac{1}{(2\pi)^{M/2} |\Sigma_i|^{\frac{1}{2}}} \exp\left[-\frac{1}{2}(X - \mu_i)^T \Sigma_i^{-1} (X - \mu_i)\right] \quad (10)$$

식(10)으로부터 판별 함수는 식(11) 과 같이 유도된다.

$$g_i(x) = P(w_i | X) = \frac{P(X | w_i)P(w_i)}{P(X)} = \frac{1}{(2\pi)^{M/2} |\Sigma_i|^{\frac{1}{2}}} \exp\left[-\frac{1}{2}(X - \mu_i)^T \Sigma_i^{-1} (X - \mu_i)\right] P(w_i) \frac{1}{P(X)} \quad (11)$$

식(11)에서 상수항을 제거하고 자연로그를 취하면, 식(12)와 같이 나타낼 수 있다.

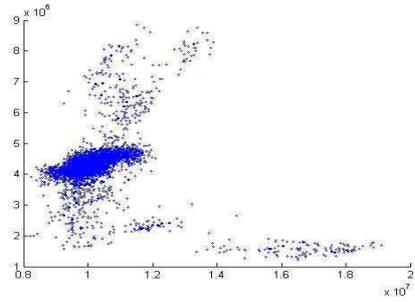
$$g_i(x) = -\frac{1}{2}(X - \mu_i)^T \Sigma_i^{-1} (X - \mu_i) - \frac{1}{2} \log(|\Sigma_i|) + \log(P(w_i)) \quad (12)$$

“베이즈의 이차 판별함수식” 이라 불리는 식(12)에 공분산 행렬을 적용하면 이차형식으로 구성된 식(13)을 얻을 수 있다 [6].

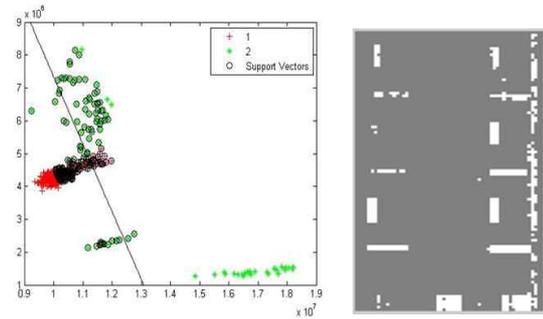
$$g_i(X) = X^T W_i X + w_i^T X + w_{i0} \quad (13)$$

$$\begin{cases} W_i = -\frac{1}{2} \Sigma_i^{-1} \\ w_i = \Sigma_i^{-1} \mu_i \\ w_{i0} = \frac{1}{2} \mu_i^T \Sigma_i^{-1} \mu_i - \frac{1}{2} \log(|\Sigma_i|) + \log(P(w_i)) \end{cases}$$

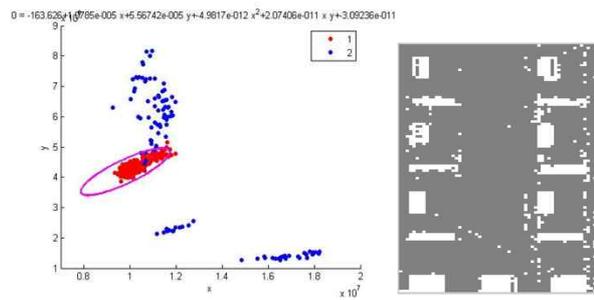
이렇게 얻어진 식을 이용해 실제 데이터에 결함의 종류에 따라 이차판별식을 생성하였다 [7]. 그림 9(a)는 테스트 데이터이다. x축은 에너지, y축은 MOG(Magnitude of gradient)를 의미하며 각각 주성분 분석을 통해 분산이 가장 큰 2 개의 주성분을 나타낸다. 그림 9(b)는 1차원의 선형분리 초평면을 나타낸다. 판정영역이 선형이므로 오분류 데이터가 많다. 그림 9(c)의 결정경계(decision boundary)는 2차 함수형태의 비선형적(non-linear)인 타원(hyper-ellipse or hyper-paraboloid)으로 나타내진다. 붉은색은 잡음이 없는 영역이며, 파란색은 결함영역을 의미한다. 그림 9(b)와 비교시 오분류되는 값이 적어짐을 알 수 있다.



(a) 실험 데이터 (test data)



(b) 1차원의 선형분리 초평면 (Hyperplane of linear separable pattern)



(c) 2차원의 비선형 분리 초평면 (Hyperplane of nonlinear separable pattern)

그림 9. (a) 실험 데이터, (b) 학습된 선형 (c) 비선형 분리초평면 적용 데이터와 그 결과

Fig. 9. (a) Test data, (b) linear, and (c) non-linear separable pattern using discriminant function and its results.

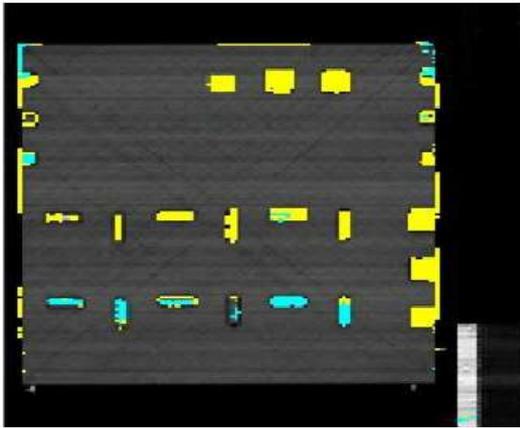


그림 10. 주성분 분석과 이차 판별 분석을 통한 결함 분류
 Fig.10. Defect classification using PCA and QDA.

그림 9(b)의 우측 영상은 1차원의 선형분리 초평면을 적용한 결과를 나타낸다. 결정경계가 선형이므로 미검출된(missed detection) 결함 및 오분류 데이터가 많다. 반면 그림 9(c)의 우측 영상은 약간의 오분류(positive false)가 있지만 더 정확하게 분류해냈으며 학습을 더 많이 할 경우 오분류는 극복 가능하다.

그림 10은 이물질(inclusion)과 갈라짐(delamination), 두 종류의 결함이 포함된 시편 테스트 데이터에 이차원 비선형 분리 초평면을 적용한 분류영상을 나타낸다. 그림 10에서 노란색은 이물질을 나타내며 파란색은 갈라짐을 나타낸다. 실험결과 실제 시편 제작 시 설계했던 것과 거의 흡사한 결과가 나타났다.

V. 결 론

본 논문에서는 항공기 복합재료의 초음파 비파괴 검사를 위해 A-scan 데이터를 이용한 자동결함 검출 및 분류 시스템을 제안했다. C-scan 영상 생성시 사용되는 기존의 방법을 개선한 자동 C-scan 생성 알고리즘은 거리 히스토그램으로 표면 반사와 백월 에코를 찾아내 그 내부에 게이트를 자동으로 정의하였다. 검출을 위해서는 파형을 이용해 표면 반사면반사와 백월 에코 사이의 피크들을 찾아내 결함을 인식하는 방법을 사용하였으며, 결함을 분류하기 위해서는 주성분분석과 이차 판별 분석을 이용하였다. 파형의 512개 샘플은 차원이 매우 크므로 주성분 분석을 통해 30차원으로 축소가 가능했다. 주성분 분석을 통해 추출된 특징들을 이용해 이차 판별분석을 적용하였다. 결함은 이물질과 갈라짐을 이용하였고 실험결과 실제 설계와 비

슷한 결과를 얻었다. 제안한 시스템은 시간 및 인력측면에서 효율성을 갖으며 결함의 크기측정 역시 만족할만한 결과를 얻었다. 자동결함분류를 통해 제한된 환경에서 우수한 특성을 보였다.

감사의 글

본 연구는 경기도의 경기도지역협력연구센터사업 2014-B01, "실감융합 방송서비스를 위한 3D영상 공간추출 기술 및 이동 멀티미디어 방송수신 성능 향상 기술"과 한국항공대학교 2011년 교비과제 "비전기반 무인항공기 자동 항행에 관한 연구" 지원에 의함.

참고문헌

- [1] K. Diamanti, C. Soutis, "Structural health monitoring techniques for aircraft composite structures," in *progress in Aerospace Science*, Amsterdam: Netherlands, Vol. 46, Issues 8, pp. 342~352, 2010.
- [2] G. Moon, "A study on the discrimination of materials corrosion states using the acoustic signal data," *The Journal of Korea Navigation Institute*, Vol. 9, No. 2, pp. 131-139, 2005.
- [3] Y. Cao, H. Zhu, and P. Yang, "Ultrasonic time of flight diffraction defect recognition based on edge detection," in *Biomedical Engineering and Computer Science(ICBECS)*. Wuhan: China, pp 1-4, 2010.
- [4] K. S. Ho, S. G. Pierce, M. H. Li, and G. Hayward, M. T. H. Sultan, "Improved C-scan imaging using a Bayesian approach," in *Ultrasonics Symposium(IUS)*, 2010 IEEE, San Diego: CA, pp 1813-1816, 2010.
- [5] A. Khan, and H. Farooq, "Principal component analysis-linear discriminant analysis feature extractor for pattern recognition," *International Journal of Computer Science Issues(IJCSI)*, Vol. 8, Issue 6, No 2, pp. 267-270, 2011.
- [6] H. Y. Han, *Pattern Recognition Introduction*, Seoul, Korea: HANBIT Media Inc. 2009.
- [7] C. Williams, *Classification Using Linear Discriminant Analysis and Quadratic Discriminant Analysis*, Colorado State University: CO, 2009.



김 영 범(Young-Bum Kim)

1997년 2월 : 한국항공대학교 항공통신정보공학과(공학사)
2001년 8월 : 한국항공대학교 정보통신공학과(공학석사)
2010년 2월 : 한국항공대학교 정보통신공학과(박사수료)
※ 관심분야 : 패턴인식, 영상처리, 멀티미디어



신 덕 하(Douck-Ha Shin)

2009년 2월 : 한국항공대학교 항공통신정보공학과(공학사)
2011년 2월 : 한국항공대학교 정보통신공학과(공학석사)
2011년 ~ : 삼성전자 연구원
※ 관심분야 : 영상처리, 패턴인식, 멀티미디어



황 승 준 (Seung-Jun Hwang)

2012년 2월 : 한국항공대학교 항공통신정보공학과(공학사)
2014년 2월 : 한국항공대학교 정보통신공학과(공학석사)
2014년 ~ 현재 : 한국항공대학교 정보통신공학과(박사과정)
※ 관심분야 : 영상처리, 멀티미디어, 3D Vision



백 중 환(Joong-Hwan Baek)

1981년 2월 : 한국항공대학교 항공통신정보공학과 (공학사)
1987년 7월 : 오클라호마주립대학원 전기 및 컴퓨터공학(공학석사)
1991년 7월 : 오클라호마주립대학교 전기 및 컴퓨터공학(공학박사)
1992년~ 현재 : 한국항공대학교 항공전자 및 정보통신공학부 교수
※ 관심분야 : 영상처리, 패턴인식, 영상압축, 멀티미디어