

인공신경회로망을 이용한 원공결함을 갖는 유한 폭 판재의 음향방출 음원특성과 파괴거동에 관한 연구

이장규*, 우창기[†]

(논문접수일 2008. 10. 24, 심사완료일 2009. 2. 4)

Acoustic Emission Source Characterization and Fracture Behavior of
Finite-width Plate with a Circular Hole Defect using Artificial Neural Network

Zhang-Kyu Rhee*, Chang-Ki Woo[†]

Abstract

The objective of this study is to evaluate an acoustic emission (AE) source characterization and fracture behavior of the SM45C steel by using back-propagation neural network (BPN). In previous research Ref. [8] about k-nearest neighbor classifier (k-NNC) continuity, we used K-means clustering method as an unsupervised learning method for obtaining multi-variate AE main data sets, such as AE counts, energy, amplitude, risetime, duration and counts to peak. Similarly, we applied k-NNC and BPN as a supervised learning method for obtaining multi-variate AE working data sets. According to the error of convergence for determinant criterion Wilk's λ , heuristic criteria D&B(Rij) and Tou values are discussed. As a result, in k-NNC before fracture signal is detected or when fracture signal is detected, showed that produce some empty classes in BPN. And we confirmed that could save trouble in AE signal processing if suitable error of convergence or acceptable encoding error give to BPN.

Key Words : Acoustic Emission(음향방출), k-Nearest Neighbor Classifier(k-최근접 이웃 분류기), Back-Propagation Neural Network (역전파 신경망), Error of Convergence(수렴오차), Heuristic Criterion(귀납적 기준), Empty Class(빈 클래스)

1. 서 론

원자력 산업이나 항공우주 산업 등 안전성이 요구되는 산업분야에서 재료의 파괴에 관한 연구는 깊은 관심사이며,

이처럼 구조물의 안전성을 검사하기 위해 등장한 새로운 비파괴시험 및 검사기술이 바로 음향방출법(AE, acoustic emission)이다. 현재 AE는 재료 내부에 국부적으로 형성되었던 변형에너지가 급격히 방출될 때 발생하는 응력탄성파

* 인천대학교 기계공학과

+ 교신저자, 인천대학교 기계공학과 (woerwck@incheon.ac.kr)
주소: 402-749 인천시 남구 도화동 177

로 이와 같은 물리적 현상 자체를 포함하여, 이를 이용한 시험방법까지도 포함하는 넓은 의미로 쓰이고 있다.

AE법은 그 연륜이 비교적 짧은 비파괴시험 및 평가기술임에도 불구하고 재료 내부의 미시적 변형이나 파괴거동의 규명에서부터 대형 압력용기나 구조물의 수압시험 및 보증시험, 그리고 가동 중에 있는 원자력 발전설비나 운항 중인 항공기에서의 연속감시체계에 이르기까지 매우 다양한 응용사례를 보이고 있다⁽¹⁾. 이것은 AE의 발생과정이 극히 미세한 비가역적인 변형에 기인하기 때문이며, 초음파탐상이나 방사선투과 등의 방법과는 달리 파시험체를 인위적인 환경하에 두지 않아도 되기 때문이다.

AE 기술을 보다 실제적인 시험검사에 적용함에 있어서 가장 큰 문제점은 현재까지 개발된 기술로는 AE의 발생원이 되는 여러 가지 현상이 재료 내에서 동시에 일어날 경우 이들을 서로 분명하게 구별할 수 없다는 점이다. 그럼에도 불구하고 AE 시험이 재료의 특성평가에서부터 대형 구조물의 진단에 이르기까지 무한한 잠재력을 지닌 것은 비교적 장치가 간단하고 압전센서를 쓸 경우 10^{-13}m 의 미소변위나 수 MPa의 압력까지도 측정할 수 있는 극히 높은 감도를 갖기 때문이다. 따라서 원리상으로는 원자의 이동이나 전위의 움직임도 포착 가능하기 때문에 소재나 구조에서 결함이 판촉되기 훨씬 이전부터 AE신호가 포착되며, 이는 저주기 피로시험 등을 통하여 입증된 바 있다. 또한 AE로 구조물의 질적 저하, 균열의 발생 및 성장, 고체의 소성변형 등 동적인 변화를 포착할 수 있고, 존재하던 결함이 외력에 의해 성장하거나 이동하는 경우 효과적으로 음원과 발생빈도를 알 수 있기 때문에 AE는 이러한 미소변형을 탐지하는데 매우 유효한 수단이 된다⁽²⁻⁴⁾.

본 연구와 관련하여 1998년 Huang 등⁽⁵⁾은 하중-변위 곡선으로부터 AE 활성도(AE activity)가 선형탄성구역의 초기부분에서 매우 조용하며, 변형이 발생하기 바로 전 두 번째 단계에서 최고치에 도달함을 보고하였고, 2003년 Singh 등⁽⁶⁾은 인공적으로 중앙원공결합을 도입한 연강시험편에 단순인장시험으로부터 얻은 하중-변위 곡선과 AE 파라미터의 상관성을 분석하여 크랙의 시작을 아는 것뿐만 아니라 그러한 결함의 존재를 예측하는 것이 구조요소의 파괴예방에 중요한 역할을 할 수 있음을 입증하였다. 또한 2008년 Woo 등⁽⁷⁾은 인공적으로 중앙원공결합을 도입한 SM45C 인장시험편의 하중-변위 곡선으로부터 강재에 대한 가속수명시험의 가능성을 입증하였다.

본 연구에서는 동일한 단일시험편의 인장시험에서 2개의 AE 측정시스템을 활용하여 동시에 획득한 AE 신호를 상용코

드로 후처리하고, 인공신경회로망을 이용한 신호분류를 통하여 인장변형에 따른 재료의 기계적 성질과 그 상관관계에 대한 AE 신호분류가 참고문헌 [8]에서의 결과보다 수월하게 수렴하는지를 파악하여, 그 타당성을 확인함으로써 AE 신호분석에 대한 노력을 최소화하는 방향을 제시하고자 한다.

2. 실험 재료 및 방법

2.1 실험재료 및 시험편

본 연구에서 사용한 시험편은 POSCO에서 생산한 두께 6mm의 기계구조용 강인 SM45C로 KS B 0801 「금속재료 인장시험편」⁽⁹⁾의 5호 시험편 규격을 적용하였으며, 시험편의 화학적 성분과 기계적 성질은 각각 Tables 1, 2와 같다.

2.2 실험방법

인공결합이 없는 시험편과 관통원공결합의 크기를 1.0, 2.5, 5.0, 7.5 및 10.0mm로 부여한 시험편에 Autograph 25-TG(Shimadzu, Japan) 만능재료시험기를 사용하여 5mm/min의 속도로 정속 인장시험을 하였다.

인장시험 중에 발생하는 AE 원신호(AE raw signals)는 Spartan 2000(PAC, USA)의 DAQ 모듈과 DiSP(PAC, USA)의 TRA 모듈을 이용하여 단일시험편에 대하여 모두 동일한 조건으로 10MSPS 샘플링 간격으로 동시에 획득하였다. 이 경우 1220A(대역필터 100~300kHz, 게인 40dB) 전치증폭기와 R15(공진주파수 150kHz) 공진역 센서를 시험편 양면에 각각 2개씩 사용하였다. 그리고 만능재료시험기의 아날로그 출력단자로부터 읽어 들인 하증값이 Spartan 2000에서의 계측 데이터와 함께 저장되도록 별도의 데이터커넥터^(11,12)를 만들어 사용하였다.

또한 고진공 그리스를 사용하여 시험편에 각각의 센서를 압착한 후, 샤프심 압절법으로 캘리브레이션(calibration)을

Table 1 Chemical composition of SM45C(wt.%)

C	Si	Mn	P	S
0.439	0.2	0.69	0.018	0.007

Table 2 Mechanical properties of SM45C⁽¹⁰⁾

Yield strength (MPa)	Tensile strength (MPa)	Elongation (%)
343	569	20

실시하여 센서의 압착여부를 확인하고, 이렇게 해서 검출된 AE 신호를 주증폭기에서 2차 증폭하여 디지털 데이터로 저장한 후 신호분석을 하였다.

3. 선행연구⁽⁷⁾의 실험결과

Fig. 1은 선행연구에 대한 실험결과를 인용한 그림이다. 선행연구에서는 인공결합이 없는 시험편(Fig. 1(a))에 견주어서 이미 시험편 자체에 원공결합이 있기 때문에 구간 I은 1차 피크가 존재하는 초기 탄성영역과 초기 소성영역으로,

구간 II는 대체로 2차 피크가 존재하는 소성영역으로, 구간 III은 시험편이 파단되는 영역으로 구분하였다. 그럼에서 원공결합의 크기가 증가할수록 하중을 분담하는 부재의 단면적이 작아져 파단이 빨리 일어나며, 그때 부재에 작용하는 하중 또한 작기 때문에 AE 카운트값도 점차 감소하는 경향이 있음을 알 수 있다. 하지만 인공결합이 없는 경우와 달리 원공결합이 존재하는 경우, AE 카운트가 소성영역을 지난 후에도 지속적으로 빈번하게 발생하고 있는데, 이미 원공결합에서 파생된 크랙이 계속해서 부재에 영향을 미치기 때문인 것으로 판단된다. 더불어 시험편이 파단될 때 발생하는

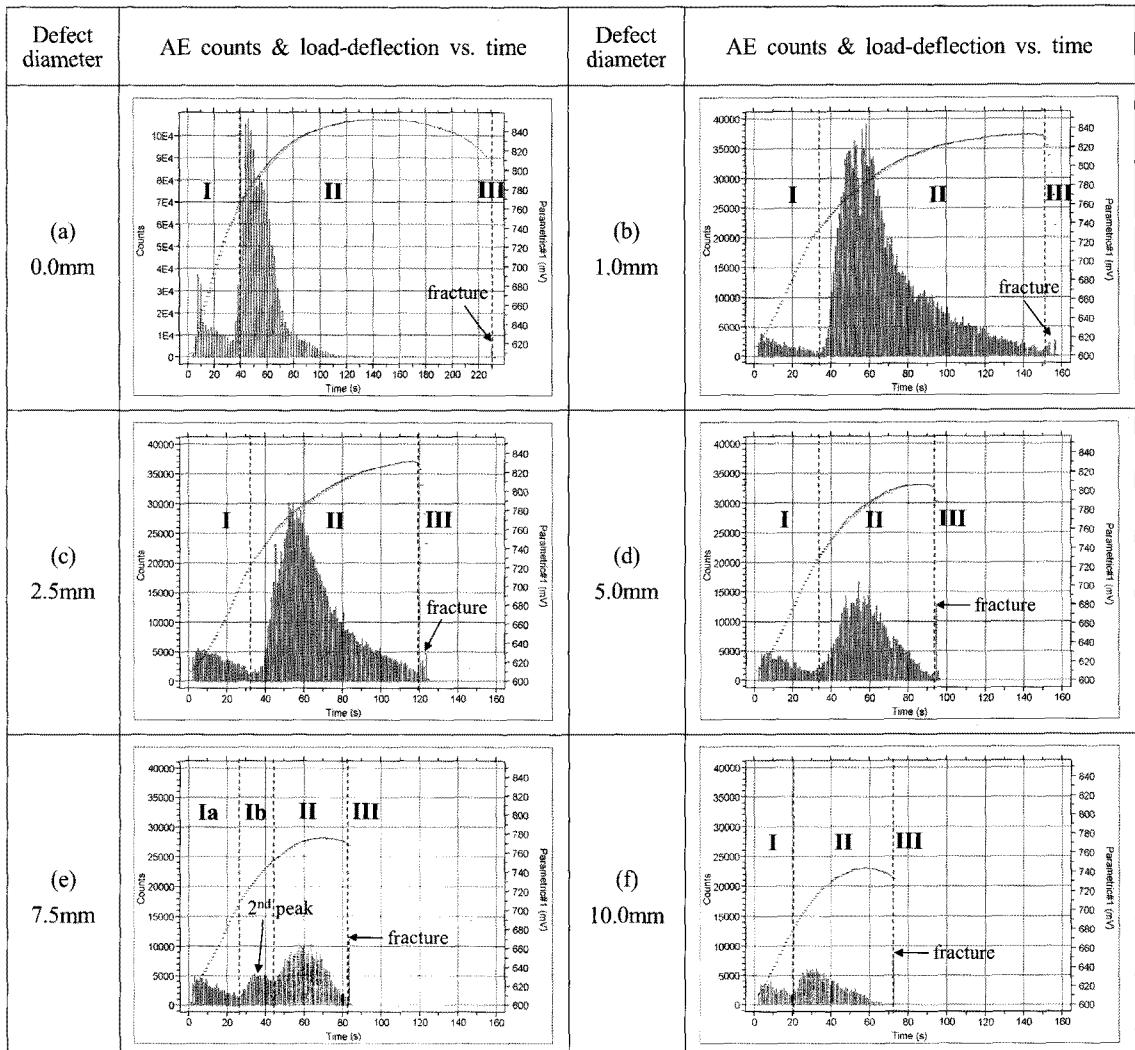


Fig. 1 Results of AE signals detected on tensile test at 5mm/min⁽⁷⁾

AE 카운트 수도 원공결합이 클수록 상대적으로 더 높은 값을 보임을 알 수 있다. 한편 원공결합이 7.5mm인 경우에는 타 조건과 다른 경향을 보이고 있으며, 정확한 파괴기구의 규명을 위해 추가연구가 필요하다.

4. 기계학습과 인공신경회로망의 구성

인공신경회로망에서의 학습은 패턴의 부류에 따라 가중치(weights)를 적당한 값으로 지정하여 패턴이 입력으로 주어질 때 지정된 노드가 일정한 출력값을 내도록 하는 것으로 학습방법에 따라 지도학습(supervised learning)과 비지도학습(unsupervised learning)으로 구분한다.

여기서 적용한 다층 퍼셉트론(multi-layer perceptron)의 일종인 역전파 신경망(BPN, back-propagation neural network)은 다층 퍼셉트론에 관련된 가중치 및 임계값에 관한 해를 반복적으로 구하는 일반적인 방법으로 작은 학습률이 사용되는 경우에 안정적인 최속 강하법에 속하지만, 수렴이 느린 단점을 가지고 있다. BPN은 입력층(input layer)과 출력층(output layer) 사이에 은닉층(hidden layer)이 존재하며, 각 층간은 가중치에 의하여 연결되고, 이 가중치의 설정에 의하여 안정된 출력을 형성하게 된다⁽¹³⁾.

앞서 언급한 것처럼 역전파 알고리즘은 다층이고, 전진형(feedforward) 신경망에서 사용되는 학습 알고리즘이며, 지도학습이다. 따라서, 학습을 하기 위해서는 입력데이터와 원하는 출력데이터가 있어야 한다. 학습의 개념은 우선 입력이 신경망의 가중치와 곱하고 더하는 과정을 몇 번 반복하면 입력의 결과값인 출력이 나오는데, 이때의 출력은 학습데이터에서 주어진 원하는 출력과 다르게 된다. 결국, 신경망에서는 (입력의 결과값 - 원하는 출력값) 만큼의 오차가 발생하며, 오차에 비례하여 출력층의 가중치를 갱신하고, 그 다음 은닉층의 가중치를 갱신한다. 이 때 신경망의 처리는 입력층→은닉층→출력층의 방향으로 진행되며, 가중치의 학습방법은 출력층→입력층으로 진행된다.

선행연구⁽⁷⁾의 유효 및 타당성 검증과 재료의 파괴거동에 따른 AE 음원특성을 보다 상세히 알아보기 위해, 사전에 비지도학습의 일종인 Cluster Seeking 알고리즘을 적용하여 기계학습에서 무작위로 제시하는 군집의 수(11~14개)를 찾아냈으며, 이를 바탕으로 먼저 비지도학습의 일종인 K-means 알고리즘을 적용하여 15개 클래스까지 군집의 수를 계산하였다. 그리고 다시 지도학습의 일종인 k-최근접 이웃 분류기(k-NNC, k-nearest neighbor classifier)를 적용하여 각 조건에 대하여 15개 클래스까지 계산함으로써 그 타당성을 보

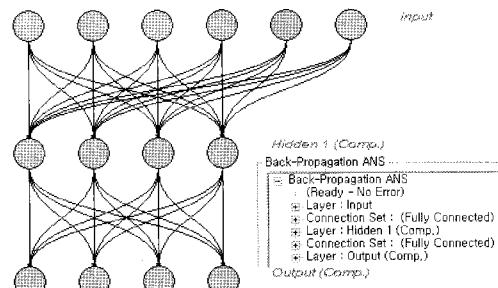


Fig. 2 Example of composed BPN dialog

였다⁽⁸⁾. 여기서 k-NNC가 가지는 가장 큰 장점은 전체 학습 예제에서 일반화된 목적함수를 도출해내는 다른 기계학습 방법과 달리 새로운 예제에 대한 탐색공간이 새로이 설정되고, 학습 예제를 그대로 사용함으로써 학습 예제가 가지고 있는 정보를 손실없이 사용할 수 있다는 것이다. 하지만 입력되는 새 데이터의 분류를 위해서는 모든 학습 데이터들과의 유사도(similarity) 계산이 필요하기 때문에 상대적으로 비용이 크다는 단점이 있다.

따라서, 궁극적으로 입력패턴과 출력의 형태가 주어지고 이에 따라 가중치가 조정되는 BPN 지도학습을 통하여 다층 퍼셉트론(입력층, 은닉층 및 출력층)에 관련된 가중치 및 임계값에 관한 해를 반복적으로 구함으로써, 결과적으로 군집의 수를 줄이며 보다 안정된 출력(수렴오차의 최소화)을 형성하도록 하였다.

Fig. 2는 AE 전용해석도구인 NOESIS⁽¹⁴⁾에서 구성한 BPN의 예이며, 신호처리에 사용한 설정값(parameters)은 다음과 같다.

- Global Learning Rate 0.5897
- Maximum Encoding 1000
- Acceptable Encoding Error ≤ 0.005
- Number of Hidden Layer 1
- Input dimension 6
- Output dimension 2~N(until converged)

5. 패턴인식 학습결과 및 해석

Fig. 3은 클래스의 수에 대한 k-NNC와 BPN의 수렴오차의 결과로 (a)~(f) 모두 클래스의 수가 증가함에 따라 수렴오차도 증가하는 경향을 보이고 있다.

여기서, k-NNC는 모든 학습 데이터들을 특징벡터로 표현하여 단순히 저장하는 것으로 학습이 완료되며, 새로운 데

이터를 분류할 때는 유클리드 거리(Euclidean distance)를 이용하여 새 데이터와 유사한 데이터 k개를 추출하고, 추출된 데이터들로부터 새로운 데이터의 정보를 얻어낸다. 따라서, k-NNC는 입력패턴이 주어졌을 때 유사도 함수에 기반하여 미리 저장되어 있는 표준패턴들의 집합에서 입력패턴과 가장 유사한 k개의 표준패턴을 선택하며, 선택된 k개의 표준패턴들의 클래스를 확인하여 가장 많이 선택된 표준패턴의 클래스를 입력패턴의 클래스로 결정하게 된다.

전술한 바와 같이 K-mean에서 15개의 클래스까지 군집

의 수를 계산한 후, 단순히 이를 바탕으로 k-NNC를 적용하였으며, 그 결과 대체적으로 15개의 클래스 안에서 시험편의 거시적인 파단신호를 분류할 수 있었다. 또한, 거시적인 파단신호가 분류된 시점에서의 수렴오차는 약 3.50% 이내인 것으로 나타났다.

마찬가지로 K-mean에서 계산한 클래스를 기준으로 하여 구성한 BPN을 적용하였다. 그 결과 대체적으로 k-NNC에서 시험편의 거시적인 파단신호를 분류하기 전에 빈 클래스(empty class)를 선별하거나 수렴오차가 급격하게 증가하여

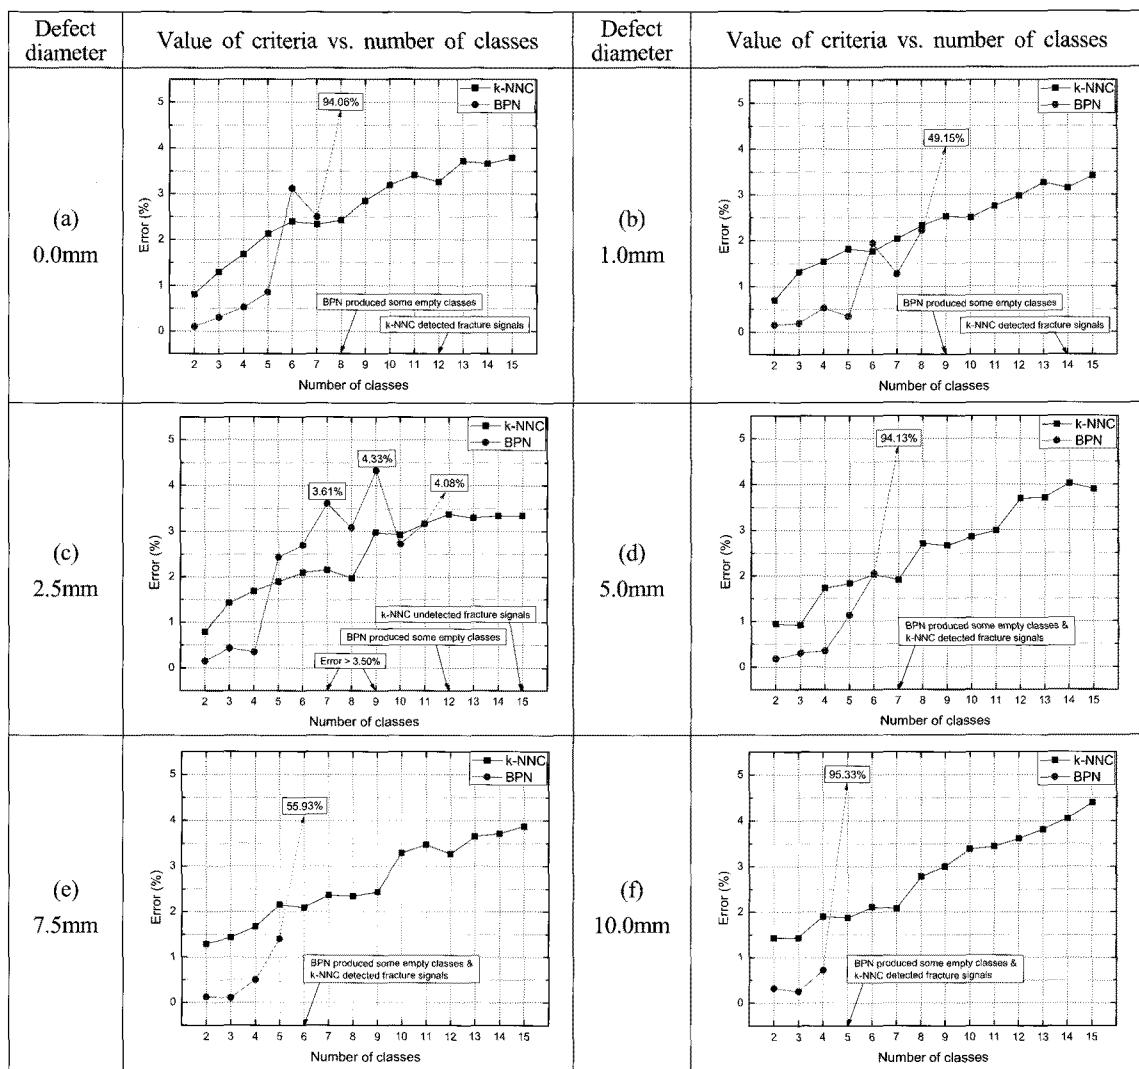


Fig. 3 Calculated error of convergence to k-NNC and BPN

안정적인 해를 구하지 못하는 것으로 나타났다. 따라서 k-NNC에서 거시적인 판단신호가 분류된 시점에서의 수렴 오차인 $3.50\% + \alpha$ (최대 $<4.0\%$)를 기준으로 하여, 그 결과를 Fig. 4의 판단기준(Wilk's λ , D&B(Rij) 및 Tou)에 적용할 수 있을 것으로 사료된다.

Fig. 4는 Cluster Seeking에서 제시한 군집의 수와 Fig. 3의 수렴오차를 기반으로 작성한 클래스 수에 대한 k-NNC 및 BPN의 판단기준이다. 여기서, 결정적 기준(determinant criterion)인 Wilk's λ 값은 단순히 적절한 클래스의 수를 찾

기 위한 참고지표로만 활용하였다.

먼저 k-NNC의 경우, 귀납적 기준(heuristic criteria)인 D&B(Rij) 및 Tou의 값이 전반적으로 상반된 경향의 일정한 값에 수렴하는 것으로 나타났다. 따라서 k-NNC에서 D&B(Rij)와 Tou 값은 Wilk's $\lambda < 0.01$ 을 만족하는 경우에 대하여 D&B(Rij)는 최소, Tou는 최대인 값을 갖는 클래스를 최적의 군집수로 선택하였다. 그 결과, 인공결함이 없는 시험편의 경우에는 7 또는 12개, 관통원공결합이 1.0, 2.5, 5.0, 7.5 및 10.0mm인 시험편의 경우에는 각각 6, 6, 7, 6

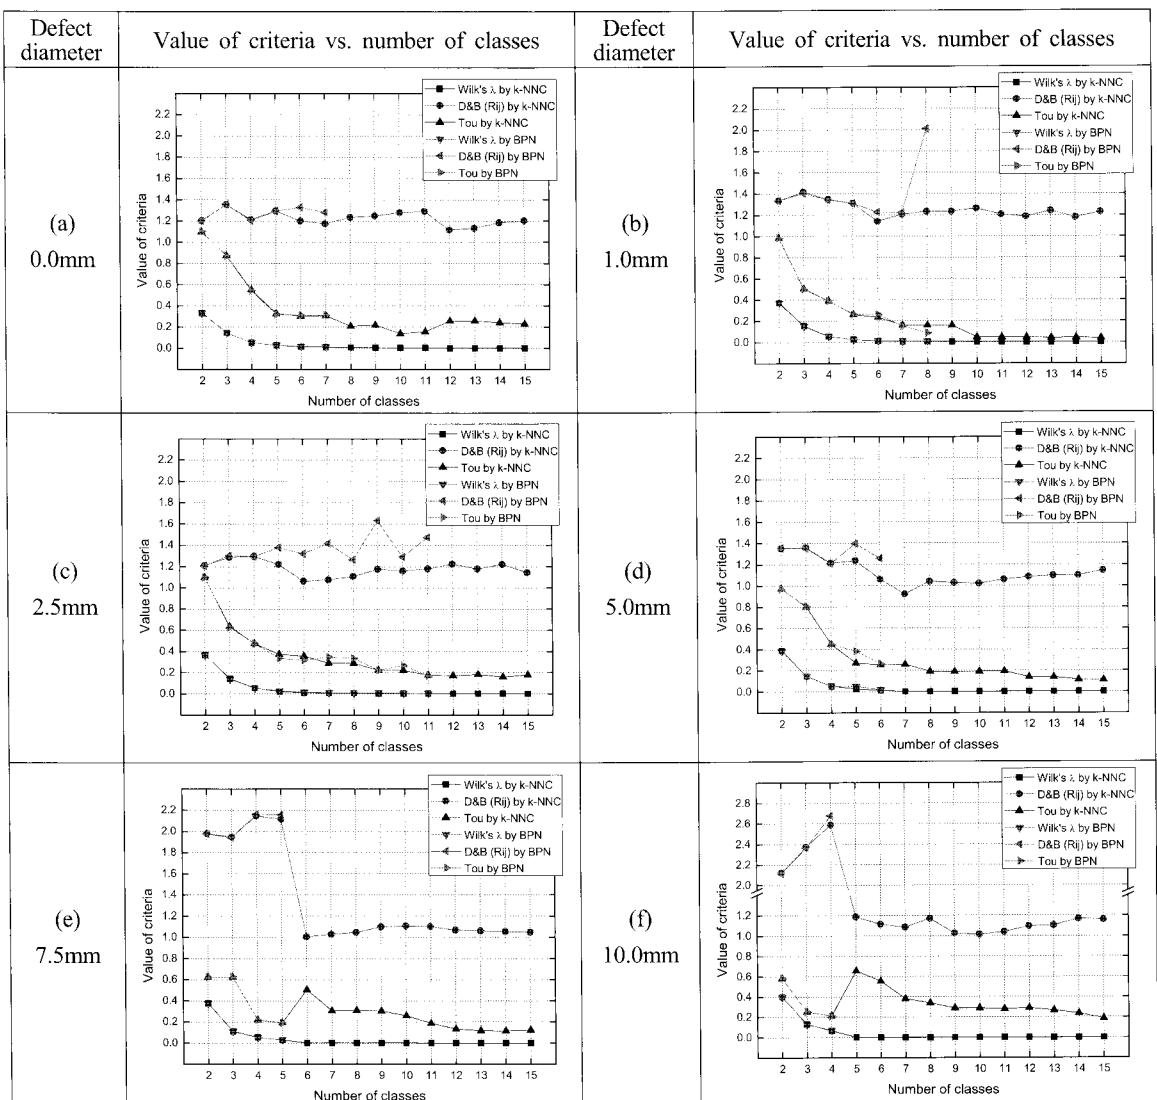


Fig. 4 Comparison of criteria k-NNC and BPN

및 5개의 클래스로 결정되어 Cluster Seeking에서 제시한 군집의 수를 1/2 가까이 줄였다.

그리고 BPN의 경우, 마찬가지로 인공결함이 없는 시험편의 경우에는 7개, 관통원공결함이 1.0, 2.5, 5.0, 7.5 및 10.0mm인 시험편의 경우에는 각각 8, 6 또는 8, 6, 5 및 4개의 클래스로 결정할 수 있다.

이상의 경우에서 결함의 크기가 증가함에 따라 시험편이 파단될 때까지의 시간이 줄어들 것으로 제시된 클래스의 수 또한 줄어들 것으로 예측되며, 그림에서 이를 확인할 수 있다. 특히 k-NNC의 경우, 관통원공결함이 7.5 및 10.0mm인 경우에는 D&B(Rij) 값의 기울기에 급격한 변화를 보이는 것으로 보아 시험편 내부에서 발생하는 AE 음원에서 현격한 변화가 있음을 짐작할 수 있는데, 이는 BPN에서 바로 그 시점이 시험편의 거시적인 파단현상에 기인함을 Fig. 3에서 입증하였다.

6. 결 론

본 연구에서는 선행연구의 유효 및 타당성 검증과 재료의 파괴거동에 따른 AE 음원특성에 대하여 보다 상세히 알아보기 위해 먼저 K-means 알고리즘을 사용하였고, 그 군집결과로 제시되는 조건별 각 클래스에 대하여 군집의 수를 줄이기 위해 k-NNC과 BPN에 적용하였다.

- (1) k-NNC의 경우, 수렴오차를 기반으로 한 결과의 타당성을 검증하기 위해 결정적 기준인 Wilk's $\lambda < 0.01$ 을 만족하는 경우에 대하여 귀납적 기준인 D&B(Rij)는 최소, Tou는 최대인 값을 가지는 해당 클래스를 군집의 수로 선택함으로써 Cluster Seeking에서 제시한 군집의 수를 1/2 가까이 줄일 수 있었다.
- (2) 또한 수렴오차를 $3.50\% + \alpha$ (최대 $< 4.0\%$)로 하여 BPN을 적용한 후, 그 수렴오차를 비교·확인함으로써 AE 신호처리 시 군집의 수를 줄임과 동시에 시험편의 거시적 파단현상에 대해서도 입증하였다.
- (3) 본 연구에서는 k-NNC보다 BPN의 우월성을 알 수 있으며, 이를 토대로 AE 신호 후처리 시 여타의 수치적 알고리즘을 적용한다면 AE 음원 분석에 대한 시공간적인 노력을 경감할 수 있을 것으로 기대된다.

후 기

이 논문은 2007년도 인천대학교 자체연구비 지원에 의해 연구되었음.

참 고 문 헌

- (1) Miller, R. K. and McIntire, P., 1987, *Nondestructive Testing Handbook (2nd ed.)*, Vol. 5, *Acoustic Emission Testing*, ASNT, USA.
- (2) Tensi, H. M., 2004, "The Kaiser-effect and its Scientific Background," *Journal of Acoustic Emission*, Vol. 22, pp. s1~s16.
- (3) Yoshimura, T. and Kano, S., 1987, "A Method of Rapidly Estimating the Fatigue Limits by Acoustic Emission," *Journal of Acoustic Emission*, Vol. 6, No. 3, pp. 145~149.
- (4) Mukhopadhyay, C. K., Jayakumar, T., Raj, B., and Ray, K. K., 2000, "Acoustic Emission—Stress Intensity Factor Relations for Tensile Deformation of Notched Specimens of AISI Type 304 Stainless Steel," *Materials Science and Engineering*, A293, pp. 137~145.
- (5) Huang, M., Jiang, L., Liaw, P. K., Brooks, C. R., Seeley, R., and Klarstrom, D. L., 1998, "Using Acoustic Emission in Fatigue and Fracture Materials Research," *Journal of Metals*, Vol. 50, No. 11.
- (6) Singh, S. K., Srinivasan, K., and Chakraborty, D., 2003, "Acoustic Emission Studies on Metallic Specimen under Tensile Loading," *Materials and Design*, 24, pp. 471~481.
- (7) Woo, C. K. and Rhee, Z. K., 2008, "Case Study on the Load-Deflection and Acoustic Emission Analysis of SM45C Coupons with a Circular Hole Defect under Tensile Loading," *Transactions of the Korean Society of Machine Tool Engineers*, Vol. 17, No. 1, pp. 50~58.
- (8) Rhee, Z. K., Woo, C. K., and Oh, J. S., 2008, "Acoustic Emission Source Characterization and Fracture Behavior of Finite-Width Plate with a Circular Hole Defect using k-Nearest Neighbor Classifier," *KSMTE Spring Conference 2008*, pp. 459~464.
- (9) Korean Standards Association, 2002, *Test pieces for tensile test for metallics materials*, KS B 0801.
- (10) MatWeb, n.d. viewed 1 May 2006, <<http://www.matweb.com/search/DataSheet.aspx?MatGUID=5682e01583604573ab367e6b1e7f09bf&cckck=1>>.

- (11) Rhee, Z. K. and Woo, C. K., 2005, "Experimental Studies on Joinability of SWS 490A High Tension Steel using Acoustic Emission Signals," *Transactions of the Korean Society of Machine Tool Engineers*, Vol. 14, No. 3, pp. 87~85.
- (12) Rhee, Z. K., 2007, "A Study on the Wavelet Transform of Acoustic Emission Signals Generated from Fusion-Welded Butt Joints in Steel during Tensile Test and its Applications," *Transactions of the Korean Society of Machine Tool Engineers*, Vol. 16, No. 1, pp. 26~32.
- (13) Mitchell, T. M., 1997, *Machine Learning*, WCB/McGraw-Hill, USA.
- (14) Envirocoustics, 2001, *Noesis v3.1 Professional Edition, Reference Manual Rev. 3*, Envirocoustics S.A., Athens, Greece.