

# Bagging 방법을 이용한 원전SG 세관 결합패턴 분류성능 향상기법

논문

58-12-37

## Classification Performance Improvement of Steam Generator Tube Defects in Nuclear Power Plant Using Bagging Method

이준표\* · 조남훈†  
(Jun-Po Lee · Nam-Hoon Jo)

**Abstract** - For defect characterization in steam generator tubes in nuclear power plant, artificial neural network has been extensively used to classify defect types. In this paper, we study the effectiveness of Bagging for improving the performance of neural network for the classification of tube defects. Bagging is a method that combines outputs of many neural networks that were trained separately with different training data set. By varying the number of neurons in the hidden layer, we carry out computer simulations in order to compare the classification performance of bagging neural network and single neural network. From the experiments, we found that the performance of bagging neural network is superior to the average performance of single neural network in most cases.

**Key Words** : Eddy Current Testing (ECT), Steam Generator (SG), Neural Network, Bagging

### 1. 서론

원자력발전소를 안정적으로 운영하기 위해서는 발전소 내의 많은 기기들의 안정성에 대한 감시가 필요하다. 특히, 압력경계를 이루는 부품들의 건전성 확보 및 지속적인 감시는 필수적이다. 이러한 장비들 중 원전 증기발생기(SG: Steam Generator) 세관은 1차 측과 2차 측의 압력 경계를 이루는 기기이다. 만약 열화에 의해 세관에 결함이 발생하여 성장할 경우 방사성 물질이 포함되어 있는 1차 측의 냉각수가 누설되는 사고로 이어진다. 따라서 SG 세관은 원전의 안전성과 경제성에 매우 큰 영향을 미치는 핵심 기기 중의 하나이다. 국내에는 총 20기의 원자력 발전소가 있으며, 여기에 증기 발생기는 총 50기가 설치되어있는데, 이 중 절반 이상이 10년 이상 운전된 상태이다. 또한 정부는 발전량기준 원전 의존도를 기존의 36%에서 55%까지 높인다는 목표를 가지고 10기의 원전을 추가로 건립할 계획을 수립하였다. 이와 같은 증기발생기의 수요증가와 함께 기존 설비의 노후화가 계속 진행되는데, 이는 증기 발생기 세관의 결함 발생 가능성이 점증되고 있음을 의미한다. 이러한 상황으로 인한 원전의 건전성 상실에 대한 사회적 우려가 매우 심각한 문제로 대두되고 있다. 그런 이유로 사회적 우려를 해소하고 원전을 안전하게 운영·관리하기 위해서는 원전설비검사기술의 확보가 중요하다.

SG 세관 검사는 비파괴 검사(Non-Destructive Testing : NDT)의 한 종류인 와전류 탐상 시험(eddy current testing:

ECT)을 주로 사용한다. ECT는 도전성 물체를 파괴하지 않고 센서코일의 임피던스 변화 및 유기기전력의 변화를 관찰하여 피검사체의 결함이나 물질특성의 변화를 탐지해 내는 검사방법이다. ECT는 비접촉 방식으로 고속자동화가 가능하고 취득한 신호의 저장성이 우수하며 다른 비파괴 검사법에 비하여 상대적으로 비용이 저렴한 장점을 가지고 있다. 이런 장점으로 ECT는 증기발생기 전열관에 대한 검사에 가장 널리 사용되고 있다. 그러나 신호를 발생시키는 요인과의 결함의 종류가 다양하여 검사 결과의 분석이 복잡하고 많은 경우 경험에 의존하므로, 검사 결과에 대한 신뢰성 평가를 병행해야 한다[1-3]. 또한, 신뢰성을 높이기 위하여 신경회로망 기법 등 최첨단 인공지능 기술을 적용하여 결함신호를 분석하여 결함의 위치, 종류, 크기 등을 정밀하게 분류하는 기법에 대한 연구가 꾸준히 진행되어 왔다[4-9]. 하지만, 신호에 섞여있는 잡음, 판지지대에 의한 신호왜곡, 투자율 변화 및 검사 프로브의 흔들림에 의한 신호 왜곡 등이 존재하기 때문에, 고도의 정확성을 갖는 결함탐지 기법을 개발하는 것은 그리 간단하지 않다.

참고문헌 [9]에서는 4가지 결합형태(I-In, I-Out, V-In, V-out 결합신호)로부터 얻을 수 있는 ETC신호를 이용한 결함분류기법을 연구하였다. 이 연구에서는 잡음이 존재하지 않는 순수한 ECT 신호를 사용할 경우 100%의 결함 분류 성능을 얻을 수 있었다. 하지만, 백색 잡음이 더해진 ECT 신호를 이용하면 분류성능이 84%까지 악화되었다. 본 논문에서는 앙상블 방법 (Ensemble method)의 한 종류인 Bagging 기법을 사용하여 분류성능을 개선하고자 한다. 앙상블 분류기는 여러 개의 분류기를 서로 다른 학습집합으로 학습시키고, 그 결과들을 종합하는 기법이다. 특히, 각각의 분류기가 서로 통계적으로 무관(statistically uncorrelated)하다면,  $L$ 개의 분류기를 사용하는 앙상블 기법은 예측오차를  $L$ 배만큼 감소시킬 수 있다는 것이 알려져 있다[10]. 본 논문

\* 정 회 원 : 숭실대 공대 전기공학부 석사과정

† 교신저자, 정회원 : 숭실대 공대 전기공학부 부교수 · 공박

E-mail : professor.jo@gmail.com

접수일자 : 2009년 10월 20일

최종완료 : 2009년 11월 25일

에서는 증기 발생기 세관의 결함패턴을 분류하는데 Bagging 기법을 사용할 경우, 기존의 방법처럼 신경회로망을 한개만 사용할 때보다 분류성능을 향상시킬 수 있음을 보이고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 본 논문에서 고려하는 4가지 축대칭 결함의 형태를 소개하고, 결함형태 분류를 위해서 필요한 특징벡터의 추출에 대해서 기술한다. 3장에서는 결함형태분류를 위해 사용될 신경회로망의 구조와 학습방법을 설명한다. 4장에서는 앙상블 기법의 대표적인 방법인 Bagging 기법의 기본 개념 및 신경회로망에의 적용 방법을 기술한다. 5장에서는 모의실험을 통하여 신경회로망을 한 개 사용할 때의 분류성능과 Bagging을 적용한 신경회로망의 분류성능을 비교한다. 마지막으로 6장에서는 본 논문의 결론을 제시한다.

## 2. 축대칭 결함 및 특징 추출

### 2.1 축대칭 결함

본 논문에서는 그림 1과 같은 4가지 결함형태, 즉 I형 관내벽 결함(I-In type), I형 관외벽 결함(I-Out type), V형 관내벽 결함(V-In type), V형 관외벽 결함(V-Out type)을 고려한다. 분류기를 이용하여 결함형태를 분류하기 위해서는 예측 알고리즘을 학습시키는데 충분한 양의 ECT 결함 신호 표본들이 필요하다. 이러한 결함신호는 실제 SG세관으로부터 실험적으로 얻을 수도 있으나, 현실적으로 신경회로망을 학습시키기에 필요한 양의 많은 데이터를 취득하는 것은 쉽지 않다. 또한, 전자기 수치해석으로 생성된 신호와 실제 실험으로 취득한 신호는 거의 일치한다는 연구결과가 참고문헌 [6]에서 밝혀졌다. 따라서, 본 논문에서는 I형 결함 100개와 V형 결함 100개의 ECT 신호를 전자기 수치해석 프로그램을 이용하여 생성하였다. 결함의 종류는 형상에 따라 2가지(I/V-type), 위치에 따라 2가지 (In/Out) 총 4가지로 구분하였다. 그리고 각 범주에 속한 결함의 크기(폭과 깊이)를 다양하게 변화시키면서 I형 결함에 대해서 100개, V형 결함에 대해서 100개의 결함신호를 생성하였다. 여기서, 결함의 깊이는 0.1, 0.2, ~ , 0.9, 1.0mm의 값을 사용하였고, 결함의 폭은 0.2, 0.4, 0.6, 0.8, 1.0mm의 값을 사용하였다.




그림 1 4가지 축대칭 결함 형태  
Fig. 1 Four axisymmetric defect types

### 2.2 특징 추출

결함 형태 분류를 위해서는 효과적인 특징추출 (feature extraction)이 매우 중요하다. 참고문헌 [6]에서는 ECT 결함 신호의 특징 11가지 (최대 저항 값, 최대 저항 값을 갖는 점의 위상, 최대 리액턴스 값, 최대 리액턴스 값을 갖는 점의 위상, 최대 임피던스 값, 최대 임피던스 값을 갖는 점의 위상, 결함 신호의 시작점의 출발각, 결함 신호 끝점의 도착각

등등)를 추출하였다. 이런 특징벡터를 사용하여 분류기를 학습시킬 경우, 대부분의 결함에 대해서는 우수한 분류 성능을 나타내지만, I-In 결함 분류에서는 저조한 분류 성공률을 나타내었다. 이러한 문제를 해결하기 위하여 참고문헌 [9]에서는 새로운 특징 3가지를 제안하였는데, 이는 그림 2와 같이 최대 임피던스 값, 최대 임피던스 값을 갖는 점의 위상, 최대 임피던스 값을 갖는 점과 최대 임피던스 값의 1/2의 값을 갖는 점 사이의 위상각으로 구성된다.




그림 2 4가지 결함형태를 분류하기 위하여 임피던스 평면의 ECT 신호로부터 추출된 특징.

Fig. 2 Features extracted from the ECT signals in the impedance plane in order to classify four defect types.

참고문헌 [9]에서는 이러한 세 가지 특징을 사용하여 결함패턴을 분류할 경우 기존의 연구결과 [6]보다 우수한 결과를 얻을 수 있음을 보였다. 따라서, [9]의 특징벡터가 [6]의 특징벡터보다 우수함을 알 수 있으며, 본 논문에서는 참고문헌 [9]에서 제안한 특징벡터를 이용한다. 참고로, 결함깊이가 1.0mm, 폭이 1.0mm인 I-In 결함, I-Out 결함, V-In 결함, V-Out 결함의 특징벡터는 다음과 같이 계산된다.

|     |        |        |         |
|-----|--------|--------|---------|
| II: | [62.54 | 103.96 | 27.41]. |
| IO: | [45.80 | 85.64  | 29.24]  |
| VI: | [35.47 | 105.44 | 20.43]  |
| VO: | [17.70 | 76.67  | 23.92]  |

## 3. 신경회로망

신경회로망은 그 종류가 여러 가지인데, 본 논문에서는 일반화 성능이 우수한 것으로 알려져 있는 다층퍼셉트론 (Multi-layer Perceptron; MLP)을 사용한다. MLP는 입력층과 출력층 사이에 하나 이상의 은닉층(hidden layer)이 존재하는 퍼셉트론으로 그림 3은 한 개의 은닉층을 갖는 MLP의 구조를 나타낸다. MLP는 충분히 많은 은닉 뉴런을 사용할 경우 임의의 함수를 근사할 수 있는 성질이 알려져 있기 때문에, 함수 근사화, 복잡한 패턴 분류, 예측이론 등에 자주 사용된다 [11]. 본 논문에서는 I-In, I-Out, V-In, V-out의 결함분류를 위해 각각 독립적인 MLP를 사용하는데, 모든 MLP는 하나의 은닉층을 갖으며, 입력층의 뉴런은 3개, 출력

뉴런은 1개로 구성하였다. MLP의 학습에는 학습속도가 매우 빠른 것으로 알려져 있는 결합경사(conjugate gradient) 알고리즘을 사용한다 [11]. 여기서, 결합 경사 알고리즘의 최대 반복횟수는 3000번, 수렴 여부를 판정하는 목표오차는 0.002로 설정하였다. 또한, 결합 경사 알고리즘에는 구간 선정(Interval Location)과 구간 축소(Interval Reduction)가 사용되는데, 구간 선정을 위한 최대 반복횟수는 100, 구간 축소를 위한 최대 반복횟수는 1000, 구간 축소의 수렴여부 판정에 사용되는 목표오차는  $10^{-6}$ , 선탐색(line search)의 스텝 크기(Step Size)는 0.01, 황금분할(Golden Search) 검색에 사용되는  $\tau=0.618$ 로 설정하였다.




그림 3 한 개의 은닉층을 갖는 다층 퍼셉트론 구조  
Fig. 3 The structure of multi-layer perceptron (MLP) with one hidden layer

#### 4. Bagging 기법

Bagging은 앙상블 기법의 대표적 방법으로, 그 기본 구조를 그림 4에서 볼 수 있다. 앙상블에 속한 각각의 신경회로망 (Network 1, Network 2, ..., Network N)은 각각의 학습집합을 이용하여 학습되며, 각각의 신경회로망의 출력을 종합하여 앙상블의 최종출력을 생성한다. 이때, 앙상블에 속한 신경회로망의 개수를 앙상블 크기 (ensemble size)라고 한다. 참고문헌 [10]에 의하면, 각각의 분류기가 서로 통계적으로 무관(statistically uncorrelated)할 경우, N개의 분류기를 사용하는 앙상블 기법은 예측오차를 N배만큼 감소시킬 수 있다고 한다.

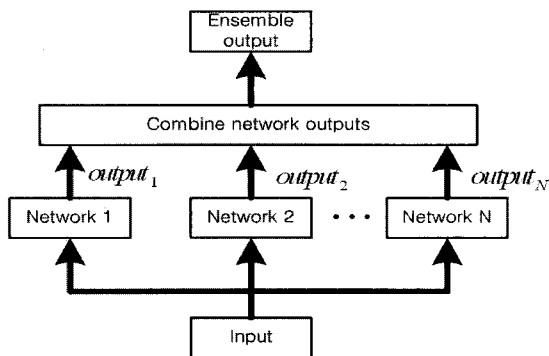


그림 4 신경회로망의 앙상블 분류기  
Fig. 4 A classifier ensemble of neural networks

Bagging은 ‘Bootstrap AGGregatING’의 약자로 각각의 신경회로망의 학습집합을 Bootstrap 방법을 사용하여 원래의 학습데이터로부터 추출하는 방법이다[12,13]. 여기서, Bootstrap 방법이란 원래의 학습집합 (표본의 개수는 N개)에서 무작위로 표본을 N개 복원 추출하여 각각의 신경회로망의 학습집합을 생성하는 것이다. 이 과정에서 어떤 표본은 최종 학습집합에서 여러 번 반복될 수도 있고, 어떤 표본은 한번도 포함되지 않을 수도 있다. 그림 5는 bootstrap방법에 의한 학습집합 생성의 한 가지 예를 나타내는데, bootstrap으로 생성된 첫 번째 학습집합의 경우, 표본 2, 3, 7은 두 번씩 포함되어 있지만, 표본 1, 5, 6은 전혀 포함되지 않는다는 것을 알 수 있다. Bagging 기법은 학습데이터를 무작위로 복원추출하기 때문에 앙상블을 구성하는 각각의 분류기 성능은 하나의 신경회로망의 성능보다는 저조하다. 하지만 각각의 신경회로망의 결과를 종합한 앙상블의 분류성능은 하나의 신경회로망을 사용한 분류성능보다 대체로 우수하다는 것이 알려져 있다[12].

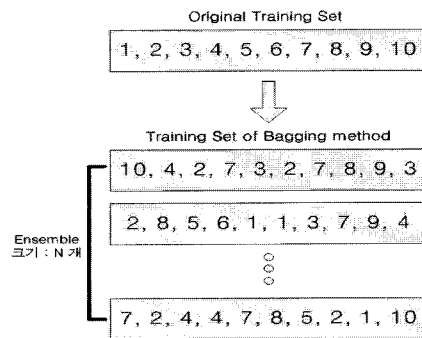


그림 5 Bootstrap 방법에 의한 학습 집합 생성 예  
Fig. 5 An example of training set generation by bootstrap method

Bagging 알고리즘은 크게 학습단계와 분류단계로 나눌 수 있다. 학습단계에서는 우선 Bagging 에서 사용할 앙상블 크기를 설정하고 앙상블 내의 분류기를 초기화한다. 그 다음, 원래의 학습 데이터로부터 bootstrap 방법을 사용하여 학습데이터들을 추출한 후 앙상블 내의 각각의 분류기를 학습시킨다. 분류단계에서는 각각의 분류기들의 결과를 정해진 결집방법(aggregating method)을 사용하여 앙상블의 최종 출력을 결정한다. 본 논문에서는 다수표결(majority vote) 방식을 사용하는데, 이는 앙상블 내의 분류기중 다수가 결정한 패턴을 최종 패턴으로 정하는 방법이다 [14].

#### 5. 컴퓨터 모의실험

본 절에서는 Bagging 기법을 적용한 신경회로망의 분류 성능과 하나의 신경회로망을 사용한 분류기의 분류성능을 비교한다. 앞으로, Bagging 기법을 적용한 신경회로망 분류기를 BNN(Bagging Neural Network), 하나의 신경회로망을 사용한 분류기를 SNN(Single Neural Network)으로 표기하도록 한다. BNN과 SNN의 분류성능을 평가하기 위해서는 분류기를 학습시키는데 사용하는 학습데이터와 학습된 분류기의 일반화 성능을 계산하는데 사용하는 평가데이터를 선




그림 6 4% 백색 잡음이 추가된 평가데이터에 대한 I-In 결함 분류성능 비교  
 Fig. 6 I-In defect type classification performance for the test set corrupted by 4% white noise




그림 8 4% 백색 잡음이 추가된 평가데이터에 대한 V-In 결함 분류성능 비교  
 Fig. 8 V-In defect type classification performance for the test set corrupted by 4% white noise




그림 7 4% 백색 잡음이 추가된 평가데이터에 대한 I-Out 결함 분류성능 비교  
 Fig. 7 I-Out defect type classification performance for the test set corrupted by 4% white noise




그림 9 4% 백색 잡음이 추가된 평가데이터에 대한 V-Out 결함 분류성능 비교  
 Fig. 9 V-Out defect type classification performance for the test set corrupted by 4% white noise

정하여야 한다. 본 논문에서는 깊이가 0.1mm, 0.3mm, 0.5mm, 0.7mm, 0.9mm인 데이터 100개를 학습데이터로 선정하였고, 깊이가 0.2mm, 0.4mm, 0.6mm, 0.8mm, 1.0mm인 데이터에 4%, 10%의 백색잡음이 추가된 데이터를 평가데이터로 선정하였다. 또한, 신경회로망은 유일한 해(unique solution)로 수렴하는 것이 보장되지 않기 때문에 서로 다른 초기조건을 이용한 모의실험을 20번 반복해서 그 결과를 분석하였다. 여기서 초기조건은 -0.5에서 0.5 사이의 값을 무작위로 발생시켜서 사용하였다. 한편, Bagging 기법을 사용하기 위해서는 앙상블에 속한 신경회로망의 개수를 결정하여야 하는데, 본 연구에서는 앙상블 크기를 20개로 결정하여 결과를 분석하였다. 또한, 앙상블에 속한 신경회로망의 초기조건도 -0.5에서 0.5사이의 값을 무작위로 발생시켜서 사용하였다. 마지막으로, 신경회로망은 은닉층내의 뉴런의 개수에 따라 성능차이가 많이 나기 때문에, 본 논문에서는 이를 3개, 5개, 10개, 15개, 20개의 경우에 대해서 분석해 보았다.

5.1 4%의 노이즈가 더해진 데이터의 결함 형태 분류

먼저 I-In 형태 결함 분류를 위한 분류기를 고려해 보자. 이를 위해서는 I-In의 결함 패턴의 목표값(target)을 1, I-In 이외의 결함(즉, I-Out, V-In, V-Out 형태 결함) 패턴의 목

표값을 0으로 설정하여 신경회로망을 학습시킨다. 이렇게 학습된 신경회로망을 이용하여 결함형태 분류시에는 출력값이 0.5 이상인 패턴은 I-In 형태 결함으로, 0.5 미만인 패턴은 I-In 이외의 결함으로 분류하였다. 또한, Bagging 기법을 적용한 결함패턴 분류는 다수 표결을 이용하였다. 즉, 앙상블을 구성하는 신경회로망의 50% 이상이 I-In 형태 결함으로 판정한 경우에는 Bagging 기법도 I-In 형태로 판정하고, 그렇지 않은 경우는 I-In 이외의 결함으로 판정하였다. 한편, 일반화성능을 측정하기 위해서, SNN의 경우에는 각 신경회로망의 최고, 최저, 평균 분류성공률을 사용하였고, Bagging 방법의 경우에는 앙상블 크기가 20개인 경우를 고려하였다.

그림 6, 7, 8, 9는 4% 노이즈가 더해진 평가 데이터에 대한 I-In결함, I-Out결함, V-In결함, V-Out결함 패턴 분류성공률을 각각 나타낸다. 여기서, x축은 신경회로망의 은닉층내의 뉴런의 개수를 나타내며, y축은 분류성공률을 나타낸다. 또한, 'SNN 최고'는 서로 다른 20개의 초기조건으로 학습한 20개의 신경회로망 중 분류성공률이 가장 높은 신경회로망의 분류 성능을 의미하고, 'SNN 최저'는 20개의 신경회로망 중 분류성공률이 가장 낮은 신경회로망의 분류 성능을 의미하며, 'SNN 평균'은 20개의 신경회로망의 분류성능

을 평균한 값이다. 또한, Bagging은 앙상블 크기가 20개인 BNN의 분류성공률을 의미한다. SNN의 경우, 최고성능과 최저성능의 차이가 상당부분 존재하는 것을 그림 6, 7, 8, 9로부터 알 수 있으며, 특히 V-Out 결함을 분류할 때, 은닉층의 뉴런의 개수가 3개인 경우에는 최저성능이 75%까지 떨어질 수 있다는 것을 그림 9로부터 알 수 있다. 이에 대해서, BNN의 경우, I-In 결함, I-Out 결함, V-Out 결함에 대한 분류성공률은 은닉뉴런의 개수에 상관없이 100%임을 그림 6, 7, 9로부터 알 수 있다. 한편, V-In 결함에 대해서는 분류성공률이 100%에는 미치지 못하지만, SNN 평균보다는 높은 성능을 나타내는 것을 확인할 수 있다. 표 1은 은닉층 뉴런의 개수가 5개일 때의 V-In 결함 분류에 대한 혼동행렬(confusion matrix)이다. 표에서 T로 표시한 것은 실제결함(true)이고 O로 표시한 것은 분류기의 출력(output)을 의미하며, VI는 V-In 결함, non-VI는 V-In 이외의 결함을 의미한다. 예를 들어, 2행 3열의 숫자 13이 의미하는 것은 실제로는 V-In 이외의 결함인데, 분류기가 V-In 결함이라고 판정하는 것을 나타낸다. 표 1로부터, V-In 결함 분류기의 성능 차이는 V-In 이외의 결함을 V-In 이외의 결함으로 정확히 분류하는 능력에 따라 달라진다는 것을 알 수 있다. 정리해 보면, 4% 노이즈가 섞인 경우에는 3가지 결함(I-In, I-Out, V-Out)에 대해서는 BNN의 성능이 SNN의 최고성능과 같음을 알 수 있다. 또한, V-In 결함에 대해서는 BNN의 성능이 SNN의 최고성능보다는 약간 낮지만 평균성능보다는 우수하다는 것을 확인할 수 있다.

표 1 4% 백색 잡음이 추가된 평가데이터에 대한 V-In 결함 분류에 대한 혼동 행렬 (은닉층 뉴런의 개수는 5개)

Table 1 Confusion matrix of V-In defect type classification for the test set corrupted by 4% white noise (The number of hidden layer neurons is five.)

| T\O    | SNN 최고 |        | SNN 최저 |        | BNN |        |
|--------|--------|--------|--------|--------|-----|--------|
|        | VI     | non-VI | VI     | non-VI | VI  | non-VI |
| VI     | 24     | 1      | 24     | 1      | 24  | 1      |
| non-VI | 2      | 73     | 13     | 62     | 3   | 72     |
| 합계     | 26     | 74     | 37     | 63     | 27  | 73     |

5.2 10%의 노이즈가 더해진 데이터의 결함 형태 분류

10%의 노이즈가 더해진 평가데이터에 대한 SNN과 BNN의 결함패턴 분류성공률을 그림 10, 11, 12, 13에 나타내었다. 우선, I-Out, V-Out 결함의 경우, 은닉뉴런의 개수에 관계없이 BNN성능이 SNN 평균성능보다 우수하거나 같다는 것을 그림 11, 13으로부터 알 수 있다. 또한, I-In 결함에 대해서는 대부분의 경우(즉, 은닉뉴런의 개수가 3개, 5개, 10개, 15개일 때) BNN의 성능이 SNN의 평균성능보다 우수하다는 것을 그림 10으로부터 알 수 있다. 한편, V-In 결함에 대해서는 은닉뉴런의 개수가 10개, 20개일 때는 BNN의 성능이 SNN의 평균성능보다 우수하다는 것을 그림 12로부터 알 수 있다. 하지만, 은닉뉴런의 개수가 3개, 5개, 15개일 때는 BNN의 성능이 SNN의 평균성능보다 약간 저조하다는 것을 알 수 있었다. 그림에도 불구하고, 대부분의 경우 BNN

성능이 SNN 평균성능보다 우수하다는 것을 그림 10, 11, 12, 13으로부터 확인할 수 있다.




그림 10 10% 백색 잡음이 추가된 평가데이터에 대한 I-In 결함 분류성능 비교

Fig. 10 I-In defect type classification performance for the test set corrupted by 10% white noise




그림 11 10% 백색 잡음이 추가된 평가데이터에 대한 I-Out 결함 분류성능 비교

Fig. 11 I-Out defect type classification performance for the test set corrupted by 10% white noise




그림 12 10% 백색 잡음이 추가된 평가데이터에 대한 V-In 결함 분류성능 비교

Fig. 12 V-In defect type classification performance for the test set corrupted by 10% white noise




그림 13 10% 백색 잡음이 추가된 평가데이터에 대한 V-Out 결함 분류성능 비교

Fig. 13 V-Out defect type classification performance for the test set corrupted by 10% white noise

### 6. 결 론

본 논문에서는 원자력 발전소 증기발생기 세관의 결함 형태를 분류하는데 주로 사용되는 신경회로망의 분류성능을 향상시킬 수 있는 기법을 연구하였다. 분류성능을 향상시키기 위하여 Bagging 기법을 신경회로망 형상분류기에 적용하였으며, 모의실험을 수행하여 기존의 신경회로망과의 분류성능을 비교하였다. 모의실험은 총 40가지, 즉 4가지 결함형태 (I-In, I-Out, V-In, V-Out), 5가지 은닉뉴런의 개수(3개, 5개, 10개, 15개, 20개), 2가지 잡음 강도(4%, 10%)에 대해서 수행되었다. 컴퓨터 모의실험에서 확인된 40가지 경우 중 36가지 경우에서 Bagging 방법의 성능이 신경회로망의 평균성능보다 우수하거나 같다는 것을 확인할 수 있었다. 따라서, 본 연구에서 제안한 Bagging 방법을 사용할 경우 원자력 발전소 세관의 결함 형태에 대한 안정적인 분류 방법으로 활용될 수 있을 것으로 기대된다.

### 참 고 문 헌

- [1] E.E. Kriezis, T.D. Tsiboukis, S.M. Panas, J.A. Tegopoulos, "Eddy currents: Theory and applications," *Proceedings of the IEEE*, vol. 80, no. 10, pp. 1559-1589, 1992.
- [2] H.B. Lee, and D.H. Kim, "Impedance calculation for a plate with crack in eddy current NDT using 3D indirect BIEM," *IEEE Trans. Magnetics*, vol. 36, no. 5, pp. 3131-3133, 2000.
- [3] M. Rebican, Z. Chen, N. Yusa, L. Janousek, and K. Miya, "Shape reconstruction of multiple cracks from ECT signals by means of a Stochastic method," *IEEE Trans. Magnetics*, vol. 42, no. 4, pp. 1079-1082, 2006.
- [4] H. Fukutomi, T. Takagi, J. Tani, M. Hashimoto, J. Shimone, and Y. Harada, "Numerical evaluation of ECT impedance signal due to minute cracks," *IEEE Trans. Magnetics*, vol. 33, no. 2, part 2, pp. 2123-2126, 1997.
- [5] C. Gangzhu, A. Yamaguchi, and K. Miya, "A novel signal processing technique for eddy-current testing of steam generator tubes," *IEEE Trans. Magnetics*, vol. 34, no. 3, pp. 642-648, 1998.

- [6] S.J. Song and Y.K. Shin, "Eddy current flow characterization in tubes by neural networks and finite element modeling," *NDT & E International*, vol. 33, pp. 233-243, 2000.
- [7] H. Haoyu, and T. Takagi, "Inverse analyses for natural and multicracks using signals from a differential transmit-receive ECT probe," *IEEE Trans. Magnetics*, vol. 38, no. 2, part 1, pp. 1009-1012, 2002.
- [8] M. Rebican, N. Yusa, Z. Chen, K. Miya, T. Uchimoto, and T. Takagi, "Reconstruction of multiple cracks in an ECT round-robin test," *International Journal of Applied Electromagnetics and Mechanics*, vol. 19, no. 1-4, pp. 399-404, 2004.
- [9] N.H. Jo and H.B. Lee, "A novel feature extraction for eddy current testing of steam generator tubes," *NDT & E International*, vol. 42, pp. 658-663, 2009.
- [10] M.P. Perrone, and L.N. Cooper, "When networks disagree: Ensemble methods for hybrid networks," *artificial neural networks for speech and vision*, 1993
- [11] S. Haykin, *Neural Networks*, New Jersey: Prentice-Hall, 1999.
- [12] L. Breiman, "Bagging predictors," *Machine Learning*, vol. 24, no. 2, pp. 123-140, 1996
- [13] D. Opitz and R. Maclin, "Popular ensemble methods : an empirical study," *Journal of Artificial Intelligence Research*, vol. 11, pp. 169-198, 1999.
- [14] L.I. Kuncheva, *Combining Pattern Classifiers*, John Wiley & Sons Inc, 2004.

## 저 자 소 개



### 이 준 표 (李俊杓)

2009년 숭실대 공대 전기제어시스템 공학부 졸업. 2009년~현재, 숭실대 공대 전기공학부 석사과정. 연구분야는 패턴인식, 풍력터빈 제어시스템 설계.

Tel : 02-824-0640

E-mail : silfrid@nate.com



### 조 남 훈 (趙南熏)

1992년 서울대 공대 전기공학과 졸업. 2000년 서울대 대학원 전기공학부 졸업 (공학). 2001년~2002년 삼성전자 DVS사업부 책임연구원. 2002년~현재 숭실대학교 전기공학부 부교수. 2006년~현재 대한전기학회 영문논문지 편집위원, 2004년~현재 제어자동화시스템공학회 국문논문지 편집위원. 연구 분야는 패턴인식 및 비파괴 검사에의 응용, 풍력터빈 제어시스템, 제어 시스템 및 시스템 생물학에의 응용.

Tel : 02-820-0643

E-mail : professor.jo@gmail.com, nhjo@ssu.ac.kr

Homepage : http://ee.ssu.ac.kr/~nhjo