

원전 증기발생기 세관 결함 크기 예측을 위한 Bagging 신경회로망에 관한 연구

A Study on Bagging Neural Network for Predicting Defect Size of Steam Generator Tube in Nuclear Power Plant

김경진*, 조남훈*[†]

Kyung-Jin Kim* and Nam-Hoon Jo*[†]

초 록 본 논문에서는 원자력 발전소 증기발생기 세관에 발생할 수 있는 결함의 크기측정에 사용되는 Bagging 신경회로망에 대한 연구를 수행하였다. Bagging은 부트스트랩(bootstrap) 샘플링에 기반을 둔 추정기 앙상블을 생성하는 방법이다. 증기발생기 세관의 결함 크기측정을 위하여 다양한 폭과 깊이를 갖는 4가지 결함패턴의 eddy current testing 신호를 생성하였다. 그 다음, 단일 신경회로망(single neural network; SNN)과 Bagging 신경회로망(Bagging neural network; BNN)을 구성하여 각 결함의 폭과 깊이를 추정하였다. SNN과 BNN 추정성능은 최대오차를 이용해서 측정하였다. 실험결과, 결함 깊이 추정시의 SNN과 BNN 최대오차는 0.117 mm와 0.089 mm 이었다. 또한, 결함 폭 추정 시에는 SNN과 BNN 최대오차는 0.494 mm와 0.306 mm 이었다. 이러한 실험결과는 BNN 추정성능이 SNN 추정성능보다 우수하다는 것을 보여준다.

주요용어: 와전류탐상시험, 원전 증기발생기 세관, Bagging, 가중평균기법, 단일 신경회로망, Bagging 신경회로망

Abstract In this paper, we studied Bagging neural network for predicting defect size of steam generator(SG) tube in nuclear power plant. Bagging is a method for creating an ensemble of estimator based on bootstrap sampling. For predicting defect size of SG tube, we first generated eddy current testing signals for 4 defect patterns of SG tube with various widths and depths. Then, we constructed single neural network(SNN) and Bagging neural network(BNN) to estimate width and depth of each defect. The estimation performance of SNN and BNN were measured by means of peak error. According to our experiment result, average peak error of SNN and BNN for estimating defect depth were 0.117 and 0.089 mm, respectively. Also, in the case of estimating defect width, average peak error of SNN and BNN were 0.494 and 0.306 mm, respectively. This shows that the estimation performance of BNN is superior to that of SNN.

Keywords: Eddy Current Testing(ECT), Steam Generator(SG), Bagging, Weighted Average Method, Single Neural Network(SNN), Bagging Neural Network(BNN)

1. 서론

화석연료의 고갈로 인해 전 세계는 대체에너지에 많은 관심을 가지고 있다. 연료전지, 풍력 발전, 태

양광 발전 등에 많은 국가와 기업들이 투자하고 있으며, 몇몇 기술들은 혁신적인 발전을 이루어 그 나라의 환경에 맞게 사용되고 있다. 하지만 우리나라 환경에 맞게 발전되어 상용화된 기술이 적기 때

문에, 그 대안으로 원자력발전이 대두되고 있는 것이 사실이다. 현재 고리, 월성에 추가적으로 원자력 발전소를 지어 원자력발전의 공급 비율을 높이려 하고 있다. 하지만 방사능 유출 사고와 핵에 대한 부정적인 인식이 강하기 때문에 원자력발전소의 설비는 다른 발전설비에 비해 철저히 관리되어야 한다. 그 중에 원자력발전소의 증기발생기(steam generator; SG) 세관은 고온 고압에 의한 균열(cracking), 관과 관지대 사이의 마멸(wear), 덴팅(denting) 등과 같은 매우 열악한 환경에 노출되어 있다. 원전 SG 세관은 원자로를 거치는 1차 계통수와 2차 계통수 사이에서 열을 전달하고 터빈 발전기를 돌리는 증기를 발생함과 동시에 방사능 차단벽으로서의 기능을 하고 있다. 만약 이 원전 SG 세관에 결함으로 인한 파단사고가 발생한다면, 방사능이 방출되어 부정적 인식이 고착화 될 것이다. 따라서 이러한 사고를 미연에 방지하기 위해 반드시 비파괴검사가 수행되어야 한다.

비파괴검사법 중에 원전설비검사에 사용되는 대표적인 방법으로 와전류탐상시험(eddy current testing; ECT)이 있는데, 이는 도체에 와전류를 유도하여 도체에 흐르는 전류를 관찰함으로써 원전 SG 세관의 이상 유무를 판단하는 방법이다. 그러나 ECT 신호를 발생시키는 요인과 결함의 종류가 다양하기 때문에 검사 결과의 분석이 복잡하고, 또한 많은 경우 경험에 의존하므로 반드시 신뢰성 평가가 수반되어야 한다[1-4]. 이를 위해 여러 학자들이 인공지능 기술을 사용하여 결함신호를 분석하고, 결함의 위치, 종류, 크기 등을 예측하는 기법을 연구 중이다[5,6]. 참고문헌 [5]에서는 수치해석 기법을 사용하여 ECT 신호를 생성한 뒤, 이를 4가지 결함형태로 분류하기 위하여 11가지의 특징을 추출하였다. [7]에서는 새로운 특징 3가지를 추출하여 [5]에서 제시한 신경회로망(neural network; NN)을 이용한 결함패턴 분류기의 분류성능을 더욱 향상시켰으며, [8]에서는 [7]에서 사용한 새로운 특징을 이용하여 크기 예측에 만족할 만한 결과를 얻었다. 본 논문에서는 Bagging 기법을 결함 크기 추정에 적용하여 기존 신경회로망의 추정성능을 향상시킬 수 있음을 보이고자 한다. Bagging 방법은 우선 기존의 학습데이터를 여러 번 임의로 추출하여 새로운 학습데이터 집합을 만든 뒤, 각각의 신경회로망으로 학습을 시킨다. 이렇게 학습된 각각의 신경회로망의 출력을 결합함으로써 최종 결과를 얻는 것

이 Bagging 기법의 기본 아이디어이다.

2. 축대칭 결함 및 특징 추출

본 논문에서는 4가지 종류의 축대칭 결함(원주방향 결함) 형태, 즉 "I"자형 관내벽 결함(I-in type), "I"자형 관외벽 결함(I-out type), "V"자형 관내벽 결함(V-in type), "V"자형 관외벽 결함(V-out type)을 고려한다. Fig. 1은 이해를 돕기 위하여 위의 4가지 결함 중 I-in 결함과 V-out 결함 형태를 나타낸 것이며, 이때의 결함 깊이를 D 로, 폭을 W 로 표시하였다.




Fig. 1 The I-shaped flaw in the inner diameter and the V-shaped flaw in the outer diameter

신경회로망을 이용하여 결함 크기를 추정하기 위해서는 충분한 양의 ECT 결함신호 표본들이 필요하다. 하지만, 많은 양의 결함신호들을 실제 SG 세관으로부터 실험적으로 얻어내는 것은 그리 간단하지 않다. 참고문헌 [5]에서는 유한요소법을 이용하여 수치적으로 생성한 결함신호와 실제 SG 세관으로부터 얻은 결함신호가 거의 일치한다는 연구결과를 발표하였다. 따라서 본 논문에서는 [5]와 동일한 수치해석 프로그램을 사용하여 ECT 결함신호를 생성하였으며, 각각의 결함 형태에 대해서 결함 깊이와 폭을 변화시켜가면서 50개의 결함 신호를 생성하였다. 이때, 결함 깊이는 0.1, 0.2, 0.3, ..., 1.0 mm로 변화시켰으며, 결함 폭은 0.2, 0.4, ..., 1.0 mm로 변화시켰다.

한편, ECT 결함신호로부터 추출하는 특징벡터는 결함 크기를 추정하는데 매우 중요하다. 기존의 연구결과 [5]에서는 ECT 결함신호의 특징 11가지(최대 저항값, 최대 저항값을 갖는 점의 위상, 최대 리액턴스값, 최대 리액턴스값을 갖는 점의 위상, 최대 임피던스값, 최대 임피던스값을 갖는 점의 위상, 결함 신호 시작점의 출발각, 결함 신호 끝점의 도착

각 등등)를 추출하여 결함 크기 추정에 사용하였다. 최근의 연구결과 [7,8]에서는 특징 3가지만을 추출하여 [5]와 거의 유사한 추정성능을 얻을 수 있음을 밝혔다. 따라서 본 논문에서는 [7,8]에서 사용한 3가지 특징을 사용하는데 Fig. 2는 ECT 신호로부터 추출하는 특징벡터를 나타낸다. 여기서, F1, F2, F3는 각각 최대 임피던스값, 최대 임피던스값을 갖는 점의 위상, 최대 임피던스 값을 갖는 점과 최대 임피던스값의 1/2의 값을 갖는 점 사이의 위상각을 나타낸다.

3. 신경회로망의 구조와 일반화 성능

본 논문에서는 결함크기 추정을 위하여 다층퍼셉트론(multi-layer perceptron; MLP) 신경회로망을 사용한다. MLP는 입력층과 출력층 사이에 하나 이상의 은닉층(hidden layer)이 존재하며, 역전파 신경회로망(backpropagation neural network)이라고도 불린다. MLP는 충분히 많은 뉴런을 사용할 경우 임의의 함수를 근사할 수 있는 성질이 알려져 있기 때문에, 함수 근사화, 복잡한 패턴 분류, 예측 이론 등에 자주 사용된다[9]. 참고문헌 [8]에서는 I-in 결함 형태의 깊이와 폭, I-out 결함 형태의 깊이와 폭, V-in 결함 형태의 깊이와 폭, V-out 결함 형태의 깊이와 폭 예측을 위해서 8개의 독립적인 MLP를 사용하였다. 하지만 독립적인 MLP를 사용하기 위해서는 결함 형태를 분류하는 작업이 선행되어야 하며, 두 개의 프로세스를 거치기 때문에 시스템이 복잡해진다. 따라서 본 논문에서는 이 과




Fig. 2 Feature vectors extracted from the ECT signals in the impedance plane to estimate defect size

정을 거치지 않고 결함 크기를 추정하기 위하여 4가지 결함형태의 깊이에 대해 하나의 MLP를 사용하여 결함 깊이를 추정하며, 결함 폭 예측 또한 하나의 MLP를 사용한다. 2개의 MLP를 사용하여 결함크기를 추정하는데 있어 신경회로망의 구조나 시물레이션에 필요한 변수 값은 [8]과 동일하게 설정하였다.

신경회로망의 학습은 일반적으로 평균제곱오차(mean square error; MSE)가 미리 정한 목표오차(error goal)보다 작아질 때까지 계속된다. 여기서 MSE는

$$MSE = \frac{1}{N} \sum_{i=1}^N (t(x_i) - f(x_i))^2 \quad (1)$$

로 정의되는데, x_i 는 i 번째 학습데이터, $t(x_i)$ 는 x_i 에 해당하는 실제 결함크기, $f(x_i)$ 는 신경회로망에 의한 결함크기 추정치, N 은 학습 데이터 개수를 나타낸다. 본 논문에서는 목표오차를 깊이와 폭 추정 모두 0.0002로 선정하였다. 또한, 신경회로망의 추정성능은 최대오차(peak error; PE)를 이용하여 측정하는데, 최대오차는

$$PE = \max_{1 \leq i \leq N} |t(x_i) - f(x_i)| \quad (2)$$

로 정의된다.

4. Bagging

Bagging은 미국의 통계학자 Leo Breiman이 처음으로 제안하였으며 'Bootstrap AGGREGatING'의 약어이다[10]. Bagging은 여러 개의 추정기를 만들어 하나의 결과로 종합하는 방법이기 때문에, 각 추정기들 간에 다양성이 존재해야 한다. 이를 위해 기존 학습데이터의 각 입력요소를 임의로 추출하여 같은 크기의 여러 학습데이터를 만든 후, 각각의 추정기를 학습시킨다. 이 때 각 추정기의 성능은 기존 신경회로망의 성능보다 저조하고 편차가 크지만, 각각의 결과를 종합하면 우수한 성능을 얻을 수 있다. 이러한 Bagging 기법은 잡음에 강하며, 불안정한 학습알고리즘, 즉 학습데이터의 작은 변화에도 예측 성능이 크게 변하는 경우에 매우 효과적이다[11].

4.1. 학습 단계

Bagging 알고리즘은 Table 1과 같은데[12], 이는 학습단계와 분류단계로 나누어진다. 학습단계를 살펴보면 먼저 몇 개의 추정기를 생성할지 결정하여야 하는데, 이 값을 앙상블 크기라고 하며, 본 논문에서는 L 로 표시한다. 학습데이터 집합 Z 가 있다고 할 때, 이 Z 라는 집합의 요소를 임의로 추출하여 같은 크기의 집합 S_1 을 만든다. 같은 방법으로 S_2, S_3, \dots, S_L 까지 L 개의 다양한 학습데이터 집합을 생성하는 것이 부트스트랩 샘플링이며, 간단한 예를 Table 2에 나타내었다. 부트스트랩 샘플링으로 생성한 L 개의 학습데이터를 통해 L 개의 신경회로망을 학습시키는 것이 학습 단계이다.

Table 1 Bagging algorithm

Training phase
1. Initialize the parameters · $D = \emptyset$, the ensemble. · L , the number of classifiers to train. 2. For $k=1, \dots, L$ · Take a bootstrap sample S_k from Z . · Build a classifier D_k using S_k as the training set. · Add the classifier to the current ensemble, $D = D \cup D_k$. 3. Return D .
Aggregating phase
4. Run D_1, \dots, D_L on the input x . 5. The class with the maximum number of votes is chosen as the label for x .

Table 2 An example of bootstrap sampling

Original train data
data-1 : 1, 2, 3, 4, 5, 6, 7, 8, 9, 10
Train data for using bootstrap sampling
data-1 : 10, 3, 7, 5, 9, 8, 5, 1, 9, 5
data-2 : 7, 8, 10, 8, 2, 5, 10, 10, 5, 9
data-3 : 1, 4, 9, 1, 2, 3, 2, 7, 3, 2
⋮
data-L : 10, 3, 5, 3, 7, 10, 8, 7, 2, 1

4.2. 결집 단계

분류 단계에서는 L 개의 신경회로망 출력을 투표, 또는 평균을 취하는 단계로서, 여러 개의 출력에서 1개의 출력을 얻어낸다고 하여 결집(agggregating)이라고 한다. 결집 기법은 단순 평균 방법, 가중치 평균 방법 등 여러 가지가 있는데[13], 본 논문에서는 가중치 평균 방법을 사용한다. 이 방법은 앙상블 크기와 같은 개수의 신경회로망을 사용하며, 신경회로망 출력에 각각의 가중치를 곱한 뒤 그 합을 구하는 방식이다. 즉, $f_i(x)$ 를 i 번째 신경회로망의 출력, $f_{bagging}(x)$ 을 Bagging의 출력이라고 할 때, Bagging 출력은 다음과 같은 식으로 표현된다.

$$f_{bagging}(x) = \sum_{i=1}^L \alpha_i f_i(x) \tag{3}$$

여기서, α_i 는 $\sum_{i=1}^L \alpha_i = 1$ 를 만족하는 상수로서 i 번째 신경회로망에 대한 가중치를 나타낸다. 추정오차를 줄이기 위해서는 $f_{bagging}(x)$ 의 MSE를 최소화하는 α_i 를 선정하여야 하는데, Michael P. Perrone은 [14]에서 다음과 같은 값을 사용할 것을 제안하였다.

$$\alpha_i = \frac{\sum_{j=1}^L C_{ij}^{-1}}{\sum_{k=1}^L \sum_{j=1}^L C_{kj}^{-1}}, \tag{4}$$

$$C_{ij} = E[(t(x) - f_i(x))^T (t(x) - f_j(x))]$$

위의 식에서 L 은 앙상블 크기, $f_i(x)$ 는 i 번째 신경회로망의 출력을 나타내며, $t(x)$ 는 목표함수이다. 이러한 가중치 평균을 사용하기 위해서는 C_{ij} 행렬이 선형독립이어서 역행렬 계산이 가능해야 해야 하며, 그렇지 않은 경우 부트스트랩 샘플링을 다시 수행해야 한다.

Bagging 기법의 예를 들기 위해 다음과 같은 구형과 신호를 근사시켜보자.

$$F(x) = \begin{cases} -1, & 0 \leq x < 1, 2 \leq x < 3 \\ 1, & 1 \leq x < 2, 3 \leq x \leq 4 \end{cases}$$

학습 데이터는 0에서 4까지의 숫자를 0.1 간격으로 나눈 41개이며, 가중치를 계산하기 위해 사용되

는 데이터는 0.03 간격으로 나누어 131개이며, 평가 데이터는 0.01 간격으로 나누어 401개이다. 상상블 크기는 3개로 하였으며, 목표오차는 0.001로 하였다. Fig. 3에서 구형파 신호를 근사한 결과를 나타내었다. 총 3개의 신경회로망이 학습되어 일점쇄선과 같은 결과를 나타내며, 가중치 평균 방법으로 인해 최종적으로 실선과 같은 출력을 갖게 된다. 여기서, 첫 번째 신경회로망의 가중치는 0.7931, 두 번째 가중치는 0.1133, 세 번째는 0.0936 을 사용하였다. 이러한 가중치로 인하여 Bagging 추정기가 두, 세 번째 신경회로망보다 첫 번째 신경회로망의 영향을 많이 받는 것을 알 수 있다.

한편, [14]에서는 평가데이터를 이용하여 상관관계 수 행렬(correlation matrix), C_{ij} 행렬을 계산하였지만, 평가데이터는 추정기 설계에 사용할 수 없는 데이터이기 때문에 이를 이용하여 C_{ij} 행렬을 계산하는 것은 현실성이 없다. 따라서 본 논문에서는 추정기 학습에 사용되는 학습데이터의 일부를 이용하여 C_{ij} 행렬을 계산하고자 한다. 이러한 경우, [14]의 가정을 만족하지 않지만, 모의실험을 통하여 Bagging 추정기의 추정성능이 기존의 신경회로망보다 우수하다는 것을 보이고자 한다.

5. 컴퓨터 모의실험

본 논문에서 제안하는 Bagging 기법의 우수성을 입증하기 위하여 본 절에서는 컴퓨터 모의실험을 수행한다. 본 논문에서는 앞으로 신경회로망 하나를 사용한 추정기를 SNN(single neural network)추정기, Bagging 기법을 사용하는 추정기를 BNN

(Bagging neural network)추정기로 언급한다. 제안된 결합크기 추정기의 추정성능을 측정하기 위해서는 학습데이터와 평가데이터를 선정하여야 한다. 2장에서 기술한 데이터 중에서 결합 깊이가 0.1, 0.2, 0.4, 0.5, 0.7, 0.8, 0.9, 1.0 mm인 데이터 160개는 SNN추정기와 BNN추정기 설계에 사용되는 학습데이터로 선정하였다. 나머지 데이터 40개, 즉 결합 깊이가 0.3, 0.6 mm인 데이터는 SNN추정기와 BNN추정기의 추정성능을 평가하는데 사용되는 평가데이터로 선정하였다. 한편, BNN추정기에서는 (4)에서의 가중치를 계산하기 위해서 학습데이터의 일부분을 사용해야 되는데, 본 논문에서는 0.2, 0.5, 0.8, 1.0 mm인 데이터 80개를 BNN추정기의 가중치 계산을 위해서 사용하였다. 따라서 BNN추정기에서는 각각의 신경회로망 학습에 결합깊이가 0.1, 0.4, 0.7, 0.9 mm 인 데이터 80개만을 사용한다.

BNN추정기 설계 시 상상블 크기는 30으로 정하였다. 또한, SNN추정기와 BNN추정기 학습 시 국소적 최소점으로 수렴할 수도 있으며, 이에 따라 추정성능에 편차가 존재할 수도 있다. 따라서 다양한 초기조건에 대해서 여러 번의 컴퓨터 모의실험이 필요한데, 본 논문에서는 초기조건을 무작위로 발생시키면서 20번의 모의실험을 수행하였다. 또한, 은닉층 내의 뉴런의 개수(NEU)에 의해서 추정성능이 많은 영향을 받기 때문에 여러 가지 NEU에 대한 모의실험이 필요하다. 이를 위해서 NEU가 4, 7, 10, 15, 20인 경우의 모의실험을 수행하여 다양한 구조에서의 성능을 비교하고자 한다.

5.1. 결합 깊이 추정

SNN추정기와 BNN추정기의 추정성능을 평가하기 위해서 우선 NEU가 10인 경우를 알아보았다. 모의실험은 20번을 수행하였는데, Fig. 4는 첫 번째 모의실험의 추정오차를 나타낸다. 그림에서 x축은 평가데이터 식별번호를 나타내며 y축은 추정오차를 나타낸다. SNN추정기를 살펴보면, 대부분의 추정오차가 0.05 이하이지만, 30~32번 데이터에서는 오차가 0.2 정도 발생했음을 볼 수 있다. BNN추정기의 경우, 30~32번 데이터에서 오차가 0.08 정도인데, 이는 SNN추정기와 비교할 때 추정오차가 60% 가량 감소한 것을 알 수 있다. 이는 Bagging 기법이 여러 개의 다양한 신경회로망의 결과를 적절히 조합하여 평균화 기법을 통해 좋지 않은 결과를 상




Fig. 3 Approximation of square wave signal using Bagging

왜시켰기 때문이라고 해석된다. Fig. 4로부터 SNN 추정기의 PE는 0.210이며, BNN추정기의 PE는 0.085임을 계산할 수 있다. 이와 같은 방식으로 20 번의 모의실험에 대한 PE를 모두 계산할 수 있으며, 이를 Fig. 5에 표시하였다.

Fig. 5로부터 NEU가 10인 경우, 20번의 모의실험 중 SNN추정기의 PE 최대값, 최소값, 평균값은 0.255, 0.072, 0.132임을 알 수 있다. 또한, BNN추정기의 PE 최대값, 최소값, 평균값은 0.145, 0.043, 0.087임을 알 수 있다. 이 결과로부터 BNN추정기가 SNN추정기보다 상당히 우수한 추정성능을 나타냄을 알 수 있다. 즉 BNN추정기 PE 평균은 SNN추정기 PE 평균보다 훨씬 작다는 것을 알 수 있으며, 특히 SNN추정기의 최고성능(PE 최소값)과도 별 차이가 나지 않는다는 것을 알 수 있다. 또한, BNN추정기 PE 최저성능(PE 최대값)도 SNN추정기 PE 최저성능보다 월등히 우수하며, 특히 SNN추정기 PE 평균과도 거의 비슷하다는 것을 알 수 있다. NEU의 변화에 따른 PE 성능의 변화를

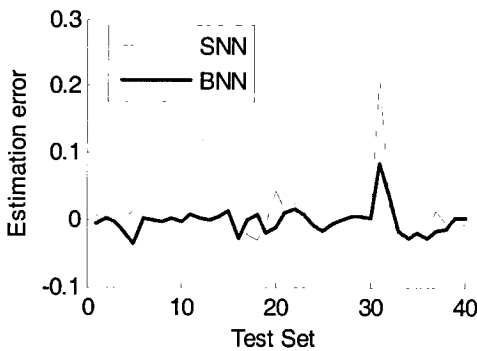


Fig. 4 Defect depth estimation error when NEU is 10

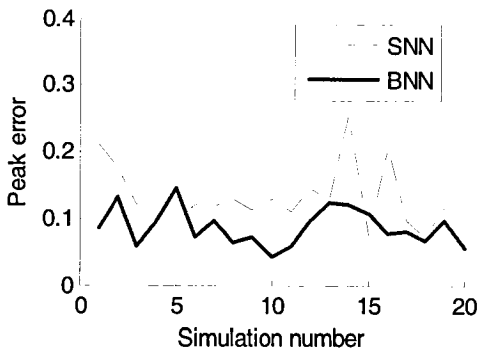


Fig. 5 Peak error of defect depth estimation for 20 different simulations when NEU is 10




Fig. 6 Peak error of defect depth estimation for 5 different NEUs

알아보기 위하여 NEU가 10인 경우와 비슷한 방법으로 NEU가 4, 7, 15, 20인 경우에 대해서 SNN추정기와 BNN추정기의 PE최대값, 최소값, 평균을 계산하였으며, 이를 Fig. 6에 표시하였다.

Fig. 6으로부터 NEU가 4, 7, 10, 15, 20인 경우 모두 BNN추정기의 PE 평균값이 SNN추정기의 PE 평균값보다 작다는 것을 알 수 있다. 또한, 5 가지 모두 BNN추정기의 PE 최소값이 SNN추정기의 PE 최소값과 비슷하거나 작다는 것을 알 수 있다. 따라서 거의 모든 경우에 대해서 BNN추정기의 성능이 SNN추정기 성능보다 우수함을 확인할 수 있다. 마지막으로, 각각의 NEU에 대한 PE 평균값을 5가지 NEU에 대해서 평균한 값을 구해보면 SNN과 BNN이 각각 0.117 mm, 0.089 mm임을 알 수 있다.

5.2. 결함 폭 추정

이번 절에서는 결함형태의 폭에 대한 SNN추정기와 BNN추정기의 성능을 비교하였다. 추정성능을 평가하기 위해 20번의 모의실험을 수행하는데, Fig. 7은 첫 번째 모의실험의 추정오차를 나타낸다. SNN추정기를 살펴보면, 대부분의 추정오차가 0.2 이하이지만, 30~32번 데이터에서는 오차가 0.7 정도로 크게 발생했다. BNN추정기에서도 SNN과 마찬가지로 대체로 오차가 0.2 이하이지만, 오차가 가장 크게 발생한 32번 데이터에서도 0.2 정도로 SNN추정기보다 오차가 크게 감소하였다. Fig. 7로부터 SNN추정기의 PE는 0.683이며, BNN추정기의 PE는 0.193임을 계산할 수 있다. 이와 같은 방식으로 20번의 모의실험에 대한 PE를 모두 계산할 수 있으며, 이를 Fig. 8에 표시하였다.

Fig. 8로부터 NEU가 10인 경우, 20번의 모의실험 중 SNN추정기의 PE 최대값, 최소값, 평균값은 0.820, 0.143, 0.456임을 알 수 있다. 또한, BNN추정기의 PE 최대값, 최소값, 평균값은 0.885, 0.126, 0.244임을 알 수 있다. BNN추정기의 PE 최대값이




Fig. 7 Defect width estimation error when NEU is 10




Fig. 8 Peak error of defect width estimation for 20 different simulations when NEU is 10




Fig. 9 Peak error of defect width estimation for 5 different NEUs

SNN추정기의 PE 최대값보다 크지만, 11번째 실험에 국한된 것이며, 평균적으로 살펴보면 BNN추정기가 SNN추정기보다 상당히 우수한 추정성능을 나타냄을 알 수 있다. BNN추정기의 PE 최소값이 SNN추정기의 PE 최소값보다 더 작으며, 평균은 두 배 정도 차이가 나는 것을 알 수 있다. NEU의 변화에 따른 PE 성능의 변화를 알아보기 위하여 NEU가 10인 경우와 비슷한 방법으로 NEU가 4, 7, 15, 20인 경우에 대해서 SNN추정기와 BNN추정기의 PE 최대값, 최소값, 평균을 계산하였으며, 이를 Fig. 9에 표시하였다.

Fig. 9로부터 NEU가 4, 7, 10, 15, 20인 경우 모두 BNN추정기의 PE 평균값이 SNN추정기의 PE 평균값보다 작다는 것을 알 수 있다. 또한, NEU가 7인 경우를 제외하면, BNN추정기의 PE 최소값이 SNN추정기의 PE 최소값과 비슷하거나 작다는 것을 알 수 있다. 따라서 대부분의 경우에 대해서 BNN추정기의 성능이 SNN추정기 성능보다 우수함을 확인할 수 있었다. 마지막으로, 각각의 NEU에 대한 PE 평균값을 5가지 NEU에 대해서 평균한 값을 구해보면 SNN과 BNN이 각각 0.494 mm, 0.306 mm 임을 알 수 있다.

지금까지의 실험결과를 정리하기 위하여 퍼센트 상대오차(percentage relative error; PRE)를 PE 평균을 이용하여 아래와 같이 정의한다.

$$PRE = \frac{PE_{SNN} - PE_{BNN}}{PE_{SNN}} \times 100 \quad (5)$$

즉, PE_{SNN} 과 PE_{BNN} 은

$$PE_{SNN} = \frac{1}{N} \sum_{i=1}^N PE_{SNN}(i)$$

$$PE_{BNN} = \frac{1}{N} \sum_{i=1}^N PE_{BNN}(i)$$

로 정의되는데, $PE_{SNN}(i)$ 와 $PE_{BNN}(i)$ 는 i 번째 실험에서 얻은 SNN추정기 PE와 BNN추정기 PE를 나타낸다. 예를 들어 NEU가 10일 때 결함 깊이 추정값의 경우 PE_{SNN} 은 0.132이고 PE_{BNN} 은 0.087이며,

$$PRE = \frac{0.132 - 0.087}{0.132} \times 100 = 34.27\% \text{이다.}$$

이와 같은 방식으로 NEU=4, 7, 10, 15, 20으로 변화시키면서 깊이와 폭에 대한 PRE를 계산할 수 있는데 이를 Table 3에 정리하였다.

Table 3 Comparison of percentage relative error of SNN estimator and BNN estimator

NEU	4	7	10	15	20	mean
depth PRE	14.08	24.50	34.27	21.95	25.54	24.07
width PRE	10.41	7.53	46.42	55.48	43.78	32.72

Table 3으로부터 깊이 추정 의 경우 평균적으로 24.07% 성능이 향상되는 것을 확인할 수 있으며, 폭 추정 의 경우에는 32.72%로 깊이 추정보다 더 큰 성능개선을 얻을 수 있었다. 특히 결함 폭을 추정할 때 NEU를 15로 정하는 경우, 상대오차를 최고 55.48%까지 개선시킬 수 있음을 표로부터 알 수 있다.

6. 결 론

본 논문에서는 원자력발전소 증기발생기 세관의 와전류탐상검사 결함크기 예측에 사용되는 신경회로망 추정성능을 향상시키기 위한 Bagging기법을 제시하였다. Bagging기법은 부트스트랩 샘플링을 이용하여 다양한 신경회로망 추정기를 생성하고, 각 추정기의 출력을 적절히 종합하는 방법이다. 이때 각 추정기의 성능은 기존의 추정기 성능보다 저조하지만, 각각의 결과를 종합하면 우수한 성능을 얻을 수 있는 특징이 있다. 모의실험 결과, 모든 경우에 대해서 BNN추정기가 SNN추정기보다 추정성능이 우수하였다. 특히, 깊이 추정과 폭 추정에서 각각 24.07%와 32.72% 성능이 향상되는 것을 확인할 수 있었다. 이는 Bagging기법이 앙상블 내에 속한 다양한 신경회로망의 결과를 적절히 조합하여 평균화 기법을 통해 좋지 않은 결과를 상쇄시켰기 때문이라고 해석된다.

감사의 글

이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업입(No. 2009-0089686)

참고문헌

[1] E. E. Kriezis, T. D. Tsiboukis, S. M. Panas and 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 Transactions on Magnetics, Vol. 36, No. 5, pp. 3131-3133 (2000)
- [3] K. Miya, "Recent advancement of electromagnetic nondestructive inspection technology in Japan," IEEE Transactions on Magnetics, Vol. 38, No. 2, pp. 321-326 (2002)
- [4] 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 Transactions on Magnetics, Vol. 42, No. 4, pp. 1079-1082 (2006)
- [5] S. J. Song and Y. K. Shin, "Eddy current flaw characterization in tubes by neural networks and finite element modeling," NDT & E International, Vol. 33, pp. 233-243 (2000)
- [6] H. Haoyu and T. Takagi, "Inverse analyses for natural and multicracks using signals from a differential transmit-receive ECT probe," IEEE Transactions on Magnetics, Vol. 38, No. 2, Part 1, pp. 1009-1012 (2002)
- [7] 조남훈, 이항범, 한기원, 송성진, "신경회로망을 이용한 원전SG 세관 결함패턴 분류성능 향상기법", 전기학회논문지, Vol. 56, No. 7, pp. 1224-1230, (2007)
- [8] 한기원, 조남훈, 이항범, "신경회로망을 이용한 원전SG 세관 결함크기 예측", 비파괴검사학회지, Vol. 27, No. 5, pp. 383-392, (2007)
- [9] M. T. Hagan, H. B. Demuth and M. H. Beale, Neural Network Design, PWS Pub. Co (1995)
- [10] L. Breiman, "Bagging predictors," Machine Learning, 24, pp. 123-140 (1996)
- [11] D. Opitz and R. Maclin, "Popular ensemble methods: an empirical study," Journal of Artificial Intelligence Research, pp. 169-198, November (1999)
- [12] L. I. Kuncheva, Combining Pattern Classifiers:

- Methods and Algorithms, John Wiley & Sons. Inc (2004)
- [13] N. M. Wanas and M. S. Kamel, "Decision fusion in neural network ensembles," Proceedings of the International Joint Conference on Neural Network, Washington DC, Vol. 4, pp. 2952-2957 (2001)
- [14] M. P. Perrone and L. N. Cooper, "When networks disagree: Ensemble methods for hybrid neural networks," Neural Networks for Speech and Image Processing by R. J. Mammone, Ed., Chapman-Hall (1993)