

다중겹 교차검증 기법을 이용한 증기세관 결함크기 예측을 위한 신경회로망 성능 향상

(Improvement of Neural Network Performance for Estimating Defect Size of Steam Generator Tube using Multifold Cross-Validation)

김남진* · 지수정 · 조남훈**

(Namjin Kim · Sujung Jee · Nam-Hoon Jo)

Abstract

In this paper, we study on how to determine the number of hidden layer neurons in neural network for predicting defect size of steam generator tube. It was reported in the literature that the number of hidden layer neurons can be efficiently determined with the help of cross-validation. Although the cross-validation provides decent estimation performance in most cases, the performance depends on the selection of validation set and rather poor performance may be led to in some cases. In order to avoid such a problem, we propose to use multifold cross-validation. Through the simulation study, it is shown that the estimation performance of defect width (defect depth, respectively) attains 94% (99.4%, respectively) of the best performance achievable among the considered neuron numbers.

Key Words : Steam Generator Tube, Eddy Current Testing, Neural Network, Multifold Cross-Validation

1. 서 론

2002년 4월 울진 4호기의 증기발생기(Steam Generator: SG) 세관 파단사고와 같은 사고를 미연에 방지하기 위해서는 비파괴검사 신뢰도를 개선하기 위

* 주저자 : 송실대학교 전기공학부 석사과정
** 교신저자 : 송실대학교 전기공학부 부교수
* Main author : Soongsil University, Dept. Electrical Engineering
** Corresponding author : Soongsil University, Dept. Electrical Engineering Professor
Tel : 02-820-0643, Fax : 02-817-7961
E-mail : nhjo@ssu.ac.kr
접수일자 : 2012년 8월 20일
1차심사 : 2012년 8월 23일
심사완료 : 2012년 9월 13일

한 연구가 매우 중요하다. 원자력발전소에서의 사고는 방사능이라는 문제와 연결되기 때문에 기술적인 문제, 정치적인 문제, 사회적인 문제 모든 면에서 반드시 예방하여야만 하는 문제이다. 원전설비검사에 사용되는 대표적인 비파괴검사법으로 와전류탐상시험(Eddy Current Testing: ECT)방법이 있는데[1-3], 와전류탐상시험의 주요 목적은 결함 세관과 무결함 세관을 구별하고, 결함 세관에 대해서 결함의 크기를 추정하는 것이다[4-6]. 하지만 신호에 섞여 있는 잡음, 관지대에 의한 신호왜곡, 투자율 변화 및 검사 프루브의 흔들림에 의한 신호 왜곡 등이 존재하기 때문에, 고도의 정확성을 갖는 결함탐지기법을 개발하는 것은 그리 간단하지 않다.

신경회로망을 이용하여 SG세관 결함 패턴을 분류하고 크기를 추정하는 대표적인 연구가 참고문헌 [6-8]에서 수행되었다. 이 연구에서는 대표적인 신경회로망인 다층퍼셉트론(Multi-Layer Perceptron: MLP)을 이용하였는데, 다층퍼셉트론에는 여러 개의 뉴런으로 구성된 은닉층(hidden layer)이 존재한다. 이러한 은닉층 내의 뉴런의 개수는 패턴분류 성능 및 예측성능에 상당한 영향을 미치는 것으로 알려져 있다[9]. 기존의 연구 결과 [8]에서는 SG세관 결함크기를 추정할 때, 우수한 추정성능을 얻을 수 있는 뉴런의 개수를 결정하기 위하여 교차검증을 이용할 것을 제안하였다. 실험결과 대부분의 경우에서 우수한 결함크기 추정성능을 얻을 수 있음을 보고하였다. 하지만 교차검증을 적용하기 위해서는 검증데이터를 결정해야 하는데, 결함 크기 추정성능은 검증데이터의 선정에 상당부분 영향을 받게 된다. 특히 검증데이터의 선정이 잘못될 경우에는 추정성능이 최고성능 대비 67.4%까지 떨어질 수도 있는 단점이 있었다.

본 논문에서는 [8]의 단점을 해결하기 위하여 다중겹 교차검증(multifold cross-validation)을 사용할 것을 제안한다. 교차검증 사용시 추정성능이 종종 낮아지는 이유는 학습데이터의 일부분만을 검증데이터로 사용하기 때문으로 추측된다. 따라서 학습데이터의 모든 데이터를 골고루 검증데이터로 사용할 수 있는 다중겹 교차검증기법을 사용한다면 [8]의 단점을 해결할 수 있을 것으로 기대된다. 본 논문에서는 이를 검증하기 위하여 다중겹 교차검증에 의한 결함 크기 추정성능과 교차검증에 의한 결함 크기 추정성능을 비교 분석하였다.

2. 축대칭 결함 및 특징추출

본 연구에서는 [5-8]에서 고려한 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. 그림 1은 I형 관내벽 결함과 V형 관외벽 결함을 보여주고 있으며, w 는 결함 폭, d 는 결함 깊이를 나타낸다.

신경회로망을 이용하여 크기를 추정하기 위해서는, 신경망을 학습시키기 위한 충분한 량의 ECT 결함신호 표본들이 필요하다. 이러한 결함신호는 실제 SG 세관으로부터 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 [5]에서 밝혀졌다. 따라서 본 논문에서는 전자기 수치해석으로 생성된 ECT 신호를 이용하는데, 결함의 깊이는 0.1mm, 0.2mm, ~, 0.9mm, 1.0mm이고, 폭은 0.2mm, 0.4mm, 0.6mm, 0.8mm, 1.0mm인 I형 결함 표본 100개와 V형 결함 표본 100개를 고려하였다. 이러한 결함 표본에 대해서 와전류탐상 주파수를 2가지 (100kHz/400kHz)로 변화시켜 가면서 I형 결함 ECT신호 200개와 V형 결함 ECT신호 200개를 참고문헌 [6-8]과 동일한 수치해석 프로그램을 이용하여 생성하였다. 이와 같이 생성된 데이터 중에서 깊이가 0.1mm, 0.3mm, 0.5mm, 0.7mm, 0.9mm인 데이터 100개는 신경회로망 학습에 사용하고, 나머지 100개는 학습된 신경회로망의 추정성능을 평가하는데 사용하였다(전자를 학습데이터, 후자를 평가데이터라고 한다[9]). 한편 결함의 크기를 예측하기 위해서는 결함의 특징을 적절히 기술할 수 있는 특징벡터의 추출이 필요하다. 본 논문에서는 [6]에서 제안하고 [7-8]에서 사용된 6개의 특징을 추출하여 신경회로망의 입력으로 사용하였다.




그림 1. I형 관내벽 결함과 V형 관외벽 결함
Fig. 1. The I-shaped flaw in the outer diameter (I-Out type) and the V-shaped flaw in the outer diameter(V-Out type)

3. 신경회로망 및 결합깊이 추정 성능

본 논문에서는 결합크기 예측을 위하여 다층퍼셉트론(MLP) 신경회로망[9]을 사용하는데, I-In, V-In, I-Out, V-Out 결합크기 추정을 위해서 4개의 독립적인 MLP를 사용한다. 그림 2는 두 개의 은닉층(hidden layer)으로 구성된 다층퍼셉트론의 구조를 나타낸다. 그림에서 $w_{1,1}^1, \dots, w_{s^1, r}^1, \dots$ 와 같이 w 로 표시된 파라미터를 weight라고 하고, b_1, b_2, \dots 과 같이 b 로 표시된 파라미터를 bias라고 하는데, 이러한 파라미터를 적절하게 동조시키는 과정을 MLP 학습이라고 한다.

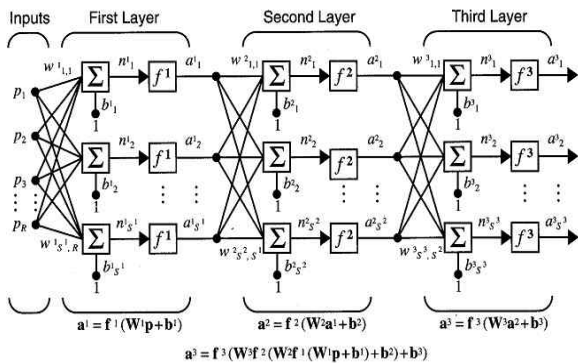


그림 2. 2개의 은닉층으로 구성된 다층퍼셉트론
Fig. 2. Multi-layer Perceptron with two hidden layers

본 논문에서는 하나의 은닉층(hidden layer)을 갖는 MLP를 사용하였으며, 은닉층의 뉴런의 활성화함수는 log sigmoid 함수를 사용하였다. MLP 학습은 학습데이터의 평균제곱오차(MSE: Mean Square Error)가 미리 정한 목표오차(Error goal)보다 작아질 때까지 계속된다. 여기서 MSE는

$$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2 \quad (1)$$

로 정의되는데, x_i 는 실제 결합크기, \hat{x}_i 는 신경회로망에 의한 결합크기 추정치, N 은 실험 데이터 개수를 나타낸다.

신경회로망의 결합 크기 추정 성능에 영향을 미치

는 요소는 여러 가지가 있지만, 그 중에서도 은닉층 뉴런의 개수(앞으로 n 으로 표시) 결정은 매우 중요하다. 참고문헌 [8]에서는 6가지 경우($n=2^2, 2^3, 2^4, 2^5, 2^6, 2^7$)에 대해서 평가데이터에 대한 추정오차를 MSE로 계산하였다. 그 결과, I-Out 결합 폭 추정 성능이 가장 우수한 것은 $n=32$ 이었지만, V-In 결합 폭 추정의 경우에는 $n=8$ 이었다. 또한 n 이 너무 작으면 I-Out 결합의 폭 추정 성능이 매우 좋지 않았고($n=4$), 반대로 n 이 너무 크면 V-In 결합의 폭 추정 성능이 매우 저조하였다($n=128$)는 것을 보고하였다. 따라서 우수한 추정 성능을 얻기 위해서는 n 을 임의로 결정하기보다는 평가데이터에 대한 추정오차(e_{test} 로 표시)를 가능한 최소화하도록 결정하여야 한다. 하지만 n 을 결정할 때 학습데이터만을 사용하고 평가데이터는 사용할 수 없기 때문에, 이는 그리 간단한 문제가 아니다. 다시 말해서 e_{test} 를 알 수 없는 상태에서 e_{test} 를 최소로 하는 n 을 결정하는 체계적인 연구가 필요하다.

4. 교차검증을 이용한 은닉층 뉴런의 개수 결정 및 문제점

신경회로망의 추정 성능에 지대한 영향을 미치는 은닉층 뉴런의 개수(n)를 결정하는 연구가 [8]에서 수행되었다. 추정오차를 최소로 하는 n 을 구하는 일반적인 방법은 현재까지 존재하지 않으며, 현실적으로 가능한 방법은 몇 가지 뉴런의 개수를 미리 결정해 놓고, 이 중에서 최고의 성능을 얻을 수 있는 n 을 구하는 것이다. 참고문헌 [8]에서는 은닉층 뉴런의 개수로 $n=2^2, 2^3, 2^4, 2^5, 2^6, 2^7$ 와 같은 값을 고려하였으며, 이 중에서 평가데이터에 대한 추정오차를 가능한 작게 만드는 n 을 구하기 위해 교차검증을 사용할 것을 제안하였다. 교차검증 기법은 학습데이터를 다시 추정데이터(estimation data)와 검증데이터(validation data)로 나누어서, 추정데이터는 뉴런의 개수를 결정하기 위한 신경망 임시 학습에 사용하고 검증데이터는 임시 학습된 신경망의 일반화 성능을 평가하는데 사용하는 것이다. 바꾸어 말하면 추정 데이터로 학습된 여러 가지 신경회로망들 중에서 검

증데이터에 대한 추정오차 MSE가 최소가 되는 뉴런의 개수를 선택하자는 것이다. 참고문헌 [8]에서는 5가지 방식(D1, D3, D5, D7, D9)에 따라 검증데이터를 선택하였는데, 그에 따라 달라질 수 있는 추정성능을 계산하였다. 여기서 D1은 학습데이터 중 깊이가 0.1mm인 데이터를 검증데이터로 정하고 나머지를 추정데이터로 정하는 방법이고, D3은 깊이가 0.3mm인 데이터를 검증데이터로 정하고 나머지를 추정데이터로 정하는 방법이며, D5, D7, D9도 마찬가지로 5가지 방식의 교차검증에 대한 결함 폭 추정성능을 표 1에서 볼 수 있다.

표 1. 교차검증을 이용한 결함 폭 추정성능(8). 0%는 최저, 100%는 최고 성능을 의미함
 Table 1. Width prediction performance using cross-validation(8). 0% and 100% represent the worst and the best results, respectively

| 결함형태 교차 검증방법 | I-In 성능(%) | I-Out 성능(%) | V-In 성능(%) | V-Out 성능(%) |
|--------------------|----------------|----------------|----------------|-----------------|
| D1 | 100 (n=128) | 94.9 (n=64) | 80.0 (n=16) | 96.8 (n=128) |
| D3 | 100 (n=128) | 94.9 (n=64) | 99.8 (n=16) | 96.8 (n=128) |
| D5 | 100 (n=128) | 67.4 (n=8) | 99.8 (n=4) | 96.8 (n=128) |
| D7 | 100 (n=128) | 95.7 (n=16) | 99.8 (n=4) | 100 (n=32) |
| D9 | 100 (n=128) | 94.9 (n=64) | 99.8 (n=4) | 100 (n=32) |

표에서 100%는 6가지 경우($n = 2^2, 2^3, 2^4, 2^5, 2^6, 2^7$)에서 얻을 수 있는 최고 추정성능, 0%는 6가지 경우의 최저 추정성능을 나타낸다.¹⁾ 예를 들어 D1, V-In성능(%)의 수치인 80.0이 의미하는 것은 6가지 경우($n = 2^2, 2^3, 2^4, 2^5, 2^6, 2^7$)의 최고 추정성능의 80%라는 것

1) 4가지 결함(I-In, I-Out, V-In, V-Out)에 대해서 각각의 최고 추정성능 MSE, 최저 추정성능 MSE 값은 참고문헌 [8]을 참고한다.

이다. 또한 괄호 안 수치 $n=16$ 은 교차검증으로 결정된 은닉층 뉴런의 개수가 16개임을 의미한다. 표 1로부터 교차검증을 이용할 경우 20가지 경우 중 18가지 경우에 대해서는 94.99%이상의 추정성능을 얻을 수 있어서 은닉층 뉴런의 개수를 결정하는데 교차검증이 매우 효과적으로 사용될 수 있음을 알 수 있다. 하지만, D1을 이용하는 교차검증 방법에서는 V-In 추정성능이 80.0%로 떨어지며, D5를 이용하는 교차검증 방법에서는 I-Out 추정성능이 67.4%로 상당히 낮아짐을 알 수 있다. 결국 교차검증방법을 이용하면 대부분의 경우 우수한 추정성능을 얻을 수 있지만, 경우에 따라서는 추정성능이 상당히 낮아질 수 있는 문제점이 존재한다.

5. 다중겹 교차검증을 이용한 추정성능 향상 방안

앞서 설명한 바와 같이 기존의 연구결과 [8]의 방식은 검증데이터 선정이 적절하지 않을 경우 추정성능이 상당한 낮아지는 문제점이 있다. 이를 해결하기 위해서 본 논문에서는 다중겹 교차검증(multifold cross-validation)[9]을 사용할 것을 제안한다. 다중겹 교차검증은 K 겹 교차검증(K -fold cross-validation)이라고도 불리는데, 우선 학습데이터를 K 개의 부분집합으로 나눈다. 그 중에서 하나의 부분집합을 검증데이터로 나머지 집합을 추정데이터로 정한 후, 추정데이터를 이용하여 신경회로망을 학습시키고 검증데이터에 대한 추정오차를 계산한다. 이러한 계산을 전체 K 개의 부분집합에 대해서 반복하고, 각각의 계산에서 구한 K 개의 추정오차를 평균한 값으로 추정성능을 최종 평가한다. 다중겹 교차검증은 학습데이터의 개수가 매우 작아서 학습데이터를 검증데이터와 추정데이터로 나누기가 어려운 경우에 주로 사용되는 기법이다[9]. 이전 연구 [8]에서 소개한 교차검증의 문제점이 발생하는 주된 이유는 학습데이터의 일부분만을 검증데이터로 사용하기 때문으로 추측된다. 따라서 다중겹 교차검증기법이 학습데이터의 모든 데이터를 골고루 검증데이터로 사용한다는 점에 착안하면, 다중겹 교차검증기법이 [8]

의 문제점을 해결할 수 있을 것으로 기대된다.

이제 다중겹 교차검증이 이러한 문제를 실제로 해결할 수 있는지 검증해 보자. 5겹 교차검증을 적용하기 위해서 우선 학습데이터를 깊이가 0.1mm인 데이터, 0.3mm인 데이터, 0.5mm인 데이터, 0.7mm인 데이터, 0.9mm인 데이터로 나눈다. 그 다음 깊이가 0.3mm, 0.5mm, 0.7mm, 0.9mm인 데이터를 이용하여 $n=2^2, 2^3, 2^4, 2^5, 2^6, 2^7$ 인 6개의 신경회로망을 각각 학습시킨 후, 깊이가 0.1mm인 데이터에 대한 결합 폭 추정오차를 계산한다(표 1의 D1 방식과 동일). 그 다음, 깊이가 0.1mm, 0.5mm, 0.7mm, 0.9mm인 데이터를 이용하여 $n=2^2, 2^3, 2^4, 2^5, 2^6, 2^7$ 인 6개의 신경회로망을 학습시킨 후, 깊이가 0.3mm인 데이터에 대한 결합 폭 추정오차를 계산한다(표 1의 D3 방식과 동일). 마찬가지로 세 번의 추정오차를 더 계산한 후, 5개의 추정오차를 평균한 값으로 $n=2^2, 2^3, 2^4, 2^5, 2^6, 2^7$ 인 신경회로망의 추정성능을 평가한다. 이 중에서 가장 작은 예측오차를 주는 n 을 선택하여 전체 학습데이터에 대해서 다시 신경회로망을 학습시켜서 결합 폭 추정기를 완성시킨다. 이와 같이 다중겹 교차검증을 이용하여 학습시킨 신경 회로망으로 평가데이터에 대한 결합 폭 추정 성능을 계산한 것을 표 2에 정리하였다(계산 방식은 표 1과 동일하다.).

표 2. 다중겹 교차검증을 이용한 결합 폭 추정 결과
Table 2. Width estimation result using multifold cross-validation

| 결합형태 교차 검증방법 | I-In 성능(%) | I-Out 성능(%) | V-In 성능(%) | V-Out 성능(%) |
|--------------------|----------------|----------------|---------------|----------------|
| 다중겹 교차검증 | 100 (n=128) | 94.9 (n=64) | 99.8 (n=4) | 96.8 (n=16) |

기존 연구 [8]을 적용할 경우 검증데이터 선정에 따라 80.0%(V-In 결합, D1방법) 또는 67.4%(I-Out 결합, D5방법)과 같은 저조한 추정성능을 얻을 수 있는 가능성이 존재하게 된다. 하지만 표 2로부터 다중겹 교차검증을 이용할 경우 4가지 결합형태 모두 94.9%

이상의 추정 성능을 얻을 수 있다. 결국 다중겹 교차검증을 사용할 경우 이전연구 [8]의 문제점을 해결할 수 있음을 알 수 있다.

한편 표 2에서는 결합 폭 추정에 대해서 다중겹 교차검증의 유효성을 입증하였는데, 이를 결합 깊이 추정에 대해서도 검증해 보도록 하자. 결합 깊이 추정을 위해서는 우선 MLP 신경회로망을 학습시켜야 한다. MLP는 초기조건에 따라 설계 변수(weight, bias)가 유일한 해로 수렴하는 것이 보장되지 않기 때문에[9] 여러 번의 컴퓨터 모의실험이 필요하다. 본 논문에서는 [8]과 동일하게 컴퓨터 모의실험을 10회 수행한 후 그 결과를 평균한 값을 이용하였다. 또한 교차검증 방법도 [8]과 동일하게 5가지 방식(즉 D1, D3, D5, D7, D9)을 고려하였다. I-In, I-Out, V-In, V-Out 형태 결합 깊이 추정에 교차검증을 이용한 계산 결과를 표 3에 정리하였다.

표 3. 교차검증을 이용한 결합 깊이 추정성능. 0%는 최저, 100%는 최고 성능을 의미함
Table 3. Depth prediction performance using cross-validation. 0% and 100% represent the worst and the best results, respectively

| 결합형태 교차 검증방법 | I-In 성능(%) | I-Out 성능(%) | V-In 성능(%) | V-Out 성능(%) |
|--------------------|----------------|----------------|----------------|-----------------|
| D1 | 100 (n=64) | 100 (n=128) | 99.7 (n=64) | 99.4 (n=128) |
| D3 | 99.7 (n=32) | 90 (n=64) | 99.7 (n=64) | 98.9 (n=64) |
| D5 | 100 (n=128) | 27 (n=16) | 99.7 (n=64) | 99.4 (n=128) |
| D7 | 100 (n=128) | 100 (n=128) | 100 (n=128) | 99.4 (n=128) |
| D9 | 100 (n=128) | 90 (n=64) | 100 (n=128) | 99.4 (n=128) |

표 3으로부터 교차검증을 이용할 경우 20가지 경우 중 17가지 경우에 대해서는 98.9%이상의 추정성능, 19

가지 경우에 대해서는 90%이상의 추정성능을 얻을 수 있음을 알 수 있다. 하지만, D5을 이용하는 교차검증 방법에서는 I-Out 추정성능이 27%로 매우 악화됨을 알 수 있다. 따라서, 20가지 경우 중 1경우에 대해서는 추정성능이 27%로 떨어져서 거의 사용이 어려운 문제점이 발생할 수도 있다.

결함 폭 추정과 마찬가지로 결함 깊이 추정에서도 다중겹 교차검증이 이러한 문제를 해결 할 수 있는지 검증해 보자. 앞서 표 2의 결과를 얻을 때와 마찬가지로 방법으로 다중겹 교차검증을 이용한 추정성능을 계산할 수 있는데, 표 4는 결함 깊이 추정 결과를 정리한 것이다.

표 4. 다중겹 교차검증을 이용한 결함 깊이 추정 결과
Table 4. Depth estimation result using multifold cross-validation

| 결함형태 교차검증방법 | I-In 성능(%) | I-Out 성능(%) | V-In 성능(%) | V-Out 성능(%) |
|----------------|----------------|----------------|---------------|----------------|
| 다중겹 교차검증 | 100 (n=128) | 100 (n=64) | 99.7 (n=4) | 99.4 (n=16) |

표 4로부터 다중겹 교차검증을 이용할 경우 4가지 결함형태 모두 99.4% 이상의 추정 성능을 얻을 수 있어서 표 3의 최고의 추정성능과 거의 같음을 알 수 있었다. 특히 I-Out 깊이 추정시 교차검증의 성능은 27%까지 떨어질 수도 있는데, 다중겹 교차검증의 성능은 100%여서 획기적으로 성능을 개선할 수 있음을 알 수 있었다.

마지막으로 다중겹 교차검증 기법 계산 량을 [8]의 단순 교차검증 기법 계산 량과 비교해 보자. 표 1과 표 2(또는 표 3과 표 4)를 얻기 위하여 필요한 계산량을 비교해 보면, 다중겹 교차검증기법은 교차검증기법 계산 량의 5배가 필요하다(D1, D3, D5, D7, D9 방식의 모든 결과를 알아야 하기 때문이다). 일반적으로 K 겹 교차검증(K -fold cross-validation)의 경우 단순 교차검증에 비해서 K 배의 계산 량을 필요로 하기 때문에 K 값을 너무 크게 선정할 수는 없다.

6. 결 론

본 논문에서는 원자력 세관 결함크기 예측에 사용되는 신경회로망의 은닉층 뉴런의 개수 결정 방법에 대해서 연구하였다. 기존의 연구 결과 [8]에서는 대부분의 경우 우수한 추정성능을 얻을 수 있지만, 경우에 따라서는 추정성능이 매우 나빠지는 단점이 있었다. 본 논문에서는 이러한 단점을 해결하기 위해서 다중겹 교차검증을 이용할 것을 제안하였다. 모의실험을 통하여 알아본 결과 결함 폭 추정 성능은 최고성능 대비 94.9%, 결함 깊이 추정 성능은 최고성능 대비 99.4%을 얻을 수 있음을 알 수 있었다. 특히 표 2와 표 4의 결과로부터 8가지 경우(폭 추정 4가지, 깊이 추정 4가지)에 대해서 다음을 알 수 있었다. 첫째, 8가지 경우 모두 교차검증의 최저성능보다 다중겹 교차검증의 성능이 훨씬 우수하였다. 둘째, 8가지 경우 중 6가지 경우에서 교차검증의 평균성능보다 다중겹 교차검증의 성능이 우수하며, 그렇지 않은 경우에도 그 차이는 -1.3%(V-Out 폭 추정), -0.1%(V-In 깊이 추정)로 미미하였다.

본 연구는 2011년도 지식경제부의 재원으로 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구과제입니다.
(No. 20114010203140)

References

- [1] G. Chen, A. Yamaguchi, K. Miya, "A novel signal processing technique for eddy-current testing of steam generator tubes," IEEE Trans. Magnetics, Vol. 34, pp. 642-648, 1998.
- [2] P. Xiang, S. Ramakrishnan, X. Cai, P. Ramuhalli, R. Polikar, S.S. Udpa, L. Udpa, "Automated analysis of rotating probe multi-frequency eddy current data from steam generator tubes," International Journal of Applied Electromagnetics and Mechanics, Vol. 12, pp. 151-164, 2000.
- [3] M. Das, H. Shekhar, X. Liu, R. Polikar, P. Ramuhalli, L. Udpa, S. Udpa, "A generalized likelihood ratio technique for automated analysis of bobbin coil eddy current data," NDT & E International, Vol. 35, pp. 329-336, 2002.
- [4] H. Haoyu, T. Takagi, "Inverse analyses for natural and multicracks using signals from a differential transmit-receive ECT probe," IEEE Trans. Magnetics, Vol. 38, pp. 1009-1012, 2002.

- [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] Nam H. Jo, and Hyang-Beom Lee, "A Novel Feature Extraction for Eddy Current Testing of Steam Generator Tubes", NDT & E International, Vol. 42, pp. 658-663, Oct., 2009.
- [7] 이준표, 조남훈, "Bagging 방법을 이용한 원전SG 세관 결함패턴 분류성능 향상기법," 전기학회 논문지, Vol. 58, pp. 2532-2537, Dec., 2009.
- [8] 조남훈, "원전SG 세관 결함크기 예측을 위한 신경회로망 구조에 관한 연구," 조명전기설비학회논문지, Vol. 24, pp. 63-70, Jan., 2010.
- [9] S. Haykin, Neural Networks, New Jersey: Prentice Hall, 1999.

◇ 저자소개 ◇



김남진 (金南珍)

1985년 6월 7일생. 2011년 숭실대 공대 전기공학과 졸업. 현재 숭실대 대학원 전기공학부 석사과정.



지수정 (池洙晶)

1983년 2월 5일생. 2011년 숭실대 공대 전기공학과 졸업. 현재 숭실대 대학원 전기공학부 석사과정.



조남훈 (趙南勳)

1970년 3월 18일생. 1992년 서울대 공대 전기공학과 졸업. 2000년 서울대 대학원 전기공학부 졸업(박사). 2002년~현재 숭실대학교 전기공학부 교수.