

원전SG 세관 결함크기 예측을 위한 신경회로망 구조에 관한 연구

(A Study on the Structure of Neural Network for Predicting Defect Size of Steam Generator Tube in Nuclear Power Plant)

조남훈*
(Nam-Hoon Jo)

요 약

본 논문에서는 원자력발전소 증기세관 크기 예측을 위한 신경회로망 구조에 대해서 연구한다. 와류탐상 시험(ECT) 신호로부터 특징을 추출한 후, 결함크기 예측을 위해서 다층퍼셉트론 신경회로망을 이용한다. 결함크기 예측성능을 최대화하기 위해서는 신경회로망의 구조, 특히 은닉층 내의 뉴런의 개수를 신중히 결정하여야 한다. 본 논문에서는, 결함크기 예측을 위한 은닉층 내의 뉴런의 개수를 교차검증을 이용하여 매우 효과적으로 결정할 수 있음을 보인다.

Abstract

In this paper, we study the structure of neural network for predicting defect size of steam generator tube. After extracting the features from the eddy current testing (ECT) signals, multi-layer neural networks are used to predict the defect size. In order to maximize the prediction performance for the defect size, we should carefully choose the structure of neural networks, especially the number of neurons in the hidden layer. In this paper, it is shown that, for the prediction of defect size, the number of neurons in the hidden layer can be efficiently determined by using cross-validation.

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

1. 서 론

원자력 발전소 운전과 안전에 매우 중요한 요소 중 하나인 증기발생기(SG: Steam Generator)는 고온 고압에 의한 균열(cracking), 관과 관지대 사이의 마멸(wear), 덴팅(denting) 등과 같은 매우 열악한 환경에 계속 노출되어 있다. 증기발생기는 원자로를 거치

* 주저자 : 송실대학교 전기공학부 교수
Tel : 02-820-0643, Fax : 02-817-7961
E-mail : nhjo@ssu.ac.kr
접수일자 : 2009년 5월 20일
1차심사 : 2009년 5월 26일, 2차심사 : 2009년 11월 20일
심사완료 : 2009년 11월 27일

는 1차 계통수의 열을 2차 계통수에 전달하여 터빈 발전기를 돌리는 증기를 발생시킨다. 증기발생기는 보통 수천 개의 세관을 포함하는데, 1차 계통수가 이 세관을 통과하면서 세관 외부의 물에 열을 가하여 증기를 발생시키게 되며, 이러한 구조에 의해 방사능이 2차 계통수로 전달되지 않게 된다. 하지만, 만약 증기발생기 세관에 결함 또는 파단사고가 발생하면 1차 계통수가 누설되어 방사능이 방출될 수 있으며, 이러한 사고를 미연에 방지하기 위해서는 적절한 비파괴검사를 수행하는 것이 필요하다.

와전류탐상시험(ECT: Eddy Current Testing)방법은 증기발생기 세관의 고속 검사에 가장 널리 사용되는 비파괴 검사 중의 하나이다[1-4]. 와전류탐상시험의 주요 목적은 결함 세관과 무결함 세관을 구별하고, 결함 세관에 대해서 결함의 크기를 예측하는 것이다[5-8]. 하지만, 신호에 섞여 있는 잡음, 관지지에 의한 신호 왜곡, 투자율 변화 및 검사 프루브의 흔들림에 의한 신호 왜곡 등이 존재하기 때문에, 증기발생기 세관으로부터 얻은 ECT신호를 분석하여 고도의 정확성을 갖는 결함탐지방법을 개발하는 것은 그리 간단하지 않다.

신경회로망을 이용하여 SG세관 결함 패턴을 분류하고 크기를 예측하는 대표적인 연구가 참고문헌[5],[8]에서 수행되었다. 이 연구에서는 대표적인 신경회로망인 다층퍼셉트론을 이용하였는데, 다층퍼셉트론에는 여러 개의 뉴런으로 구성된 은닉층(hidden layer)이 존재한다. 이러한 은닉층 내의 뉴런의 개수는 패턴분류성능 및 예측성능에 상당한 영향을 미치는 것으로 알려져 있다[9]. 일반적으로 뉴런의 개수가 많아질수록 학습데이터에 대한 예측성능은 향상되지만, 일반화성능(학습되지 않은 데이터에 대한 예측성능)도 좋아지는 것은 아니다. 따라서, 최적의 일반화성능을 얻을 수 있는 뉴런의 개수를 결정하는 것은 매우 중요하다. 하지만, 기존의 연구결과 [5],[8]에서는 뉴런의 개수가 SG세관 결함크기 예측성능에 미치는 영향은 전혀 연구되지 않았다.

본 논문에서는 SG세관 결함크기를 예측할 때, 최적의 일반화성능을 얻을 수 있는 뉴런의 개수를 결정하는 방법에 대한 연구를 수행하고자 한다. 일반화성능

에 지대한 영향을 미치는 은닉층 내의 뉴런의 개수를 체계적으로 결정하는 주요 방법은 교차검증(cross validation)을 이용하는 것이다[9-10]. 참고문헌[10]에서는 교차검증을 사용할 경우, 각각의 개별적인 분류기로부터 얻을 수 있는 예측성능보다 우수한 예측성능을 얻을 수 있는 분류기를 선택할 수 있다는 것을 실험적으로 보였다. 또한, [10]에서는 교차검증을 이용하면 가장 나쁜 예측성능을 갖는 분류기를 선택할 수 있는 위험을 획기적으로 줄일 수 있음을 보였다. 하지만, 교차검증에 의한 신경망 구조 결정 전략이 모든 경우에 효과적임을 증명하는 명확한 이론이 존재하는 것은 아니기 때문에, 이러한 기법의 효용성 여부는 각각의 사례별로 실험적으로 입증되어야 한다. 본 논문에서는 결함크기 예측을 위한 신경회로망 학습에서 교차검증을 이용한 신경망 구조 결정 전략이 매우 유용하다는 것을 실험적으로 입증하고자 한다.

2. 축대칭 결함 및 특징추출

본 논문에서는 축대칭 결함신호의 폭을 추정하는데 교차검증을 적용하여 가능한 최선의 예측성능을 얻는 것을 목적으로 한다. 본 연구에서는 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 고려하는데, 그림 1은 이해를 돕기 위하여 위의 4가지 결함 중 I-Out 결함과 V-Out 결함 형태를 나타낸 것이다.




그림 1. I형 관외벽 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)

신경회로망을 이용하여 크기를 산정하기 위해서는, 신경망을 학습시키기 위한 충분한 량의 ECT 결함신

호 표본들이 필요하다. 이러한 결합신호는 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 [5]에서 밝혀졌다. 따라서, 본 논문에서는 전자기 수치해석으로 생성된 ECT 신호를 이용하는데, 결합의 깊이는 0.1, 0.2, ~, 0.9, 1.0[mm]이고, 폭은 0.2, 0.4, 0.6, 0.8, 1.0[mm]인 I형 결합 표본 100개와 V형 결합 표본 100개를 고려하였다. 이러한 결합 표본에 대해서 와전류탐상 주파수를 2가지(100[kHz]/400[kHz])로 변화시켜 가면서 I형 결합 ECT신호 200개와 V형 결합 ECT신호 200개를 참고문헌 [5],[8]과 동일한 수치해석 프로그램을 이용하여 생성하였다. 이와 같이 생성된 데이터 중에서 깊이가 0.1[mm], 0.3[mm], 0.5[mm], 0.7[mm], 0.9[mm]인 데이터 100개는 신경회로망 학습에 사용하고, 깊이가 0.2[mm], 0.4[mm], 0.6[mm], 0.8[mm], 1.0[mm]인 데이터 100개는 학습된 신경회로망의 예측성능을 평가하는데 사용하였다(전자를 학습데이터, 후자를 평가데이터라고 한다).

한편, 결합의 종류를 분류하고 크기를 예측하기 위해서는 결합의 특징을 적절히 기술할 수 있는 특징벡터의 추출이 필요하다. 결합 형태 분류 및 크기 예측을 위한 특징벡터는 여러 가지 방식이 연구되어 왔다. [5]에서는 ECT 결합신호의 특징 11가지를 추출하였으며, [8]에서는 분류 정확도를 개선하기 위하여 새로운 특징 3가지를 제안하였다. 본 논문에서는 [8]에서 제안한 특징벡터를 이용하는데, 다음과 같은 6개의 특징을 추출하여 신경회로망의 입력으로 사용한다: 1) 주파수가 100[kHz]일 때의 최대 임피던스 값, 2) 주파수가 100[kHz]일 때의 최대 임피던스 값을 갖는 점의 위상, 3) 주파수가 100[kHz]일 때의 최대 임피던스 값을 갖는 점과 최대 임피던스 값의 1/2의 값을 갖는 점 사이의 위상각, 4) 주파수가 400[kHz]일 때의 최대 임피던스 값, 5) 주파수가 400[kHz]일 때의 최대 임피던스 값을 갖는 점의 위상, 6) 주파수가 400[kHz]일 때의 최대 임피던스 값을 갖는 점과 최대 임피던스 값의 1/2의 값을 갖는 점 사이의 위상각.

3. 신경회로망 및 일반화 성능

본 논문에서는 결합크기 예측을 위하여 다층퍼셉트론(MLP: Multi-Layer Perceptron) 신경회로망을 사용한다. MLP는 입력층과 출력층 사이에 하나 이상의 은닉층(hidden layer)이 존재하며, 역전파 신경회로망(Backpropagation neural network)이라고도 불린다. 특히, MLP는 충분히 많은 뉴런을 사용할 경우 임의의 함수를 근사할 수 있는 성질이 알려져 있기 때문에, 함수 근사화, 복잡한 패턴 분류, 예측이론 등에 자주 사용된다[9].

본 논문에서는 I-In 폭, V-In 폭, I-Out 폭, V-Out 폭 예측을 위해서 4개의 독립적인 MLP를 사용한다. 또한, 이러한 MLP 모두 하나의 은닉층을 갖도록 하였으며, 은닉층의 뉴런의 활성화함수(activation function)는 log sigmoid 함수를 사용하였다. 신경회로망의 학습은 일반적으로 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.

한편, 신경회로망 학습시 입력 전처리 과정으로서 입력벡터의 스케일링(scaling)을 수행한다. 입력벡터 스케일링을 수행하지 않으면 알고리즘이 수렴하지 않고 발산하거나, 수렴한다고 하더라도 성능이 별로 좋지 않은 경우가 대부분이다. 본 논문에서는 입력벡터의 모든 성분 변수가 0에서 1사이의 값이 되도록 입력벡터 스케일링을 수행한 후 신경회로망을 학습시킨다.

신경회로망의 일반화성능에 영향을 미치는 요소는 여러 가지가 있지만, 그 중에서도 은닉층 내의 뉴런의 개수 결정은 매우 중요하다. 일반적으로, 이 값이 작으면 학습데이터에 대한 학습이 제대로 이루어지지 않는 경우가 발생할 수 있으며, 반대로 이 값이 너무 커지면 학습데이터에 대한 오차는 매우 작게 만들 수 있

지만 일반화 성능은 악화될 수 있다는 것이 잘 알려져 있다[9]. 실제로 이러한 사실은 축대칭 결함크기 예측 결과중 하나인 그림 2에서도 확인 가능하다. 그림 2는 은닉층의 뉴런의 개수를 $2^2, 2^3, \dots, 2^7$ 으로 증가시켜 나갈 때, 평가데이터에 대한 예측 오차의 변동추이를 보여준다. 그림 2의 위 그림은 I-Out 결함의 폭을 예측할 때의 예측성능이며, 아래 그림은 V-In 결함의 예측성능을 나타낸다. 각각의 그림에서 x 축은 은닉층 내의 뉴런의 개수를 표시한 것으로 2, 3, 4, 5, 6, 7은 각각 $2^2, 2^3, 2^4, 2^5, 2^6, 2^7$ 을 나타내며, y 축은 예측오차를 MSE로 계산한 것이다. 그림 2로부터 I-Out 결함의 폭을 예측하는 경우에는 $2^5 = 32$ 인 경우 가장 우수한 MSE를 얻을 수 있지만, V-In 결함의 폭을 예측하는 경우에는 $2^3 = 8$ 에서 가장 우수한 MSE를 얻을 수 있다는 것을 확인할 수 있다. 특히, I-Out 결함의 폭을 예측하는 경우에는 뉴런의 개수가 너무 작으면 ($2^2 = 4$) 예측성능이 떨어지며, 반대로 V-In 결함의 폭을 예측하는 경우에는 너무 많으면 ($2^7 = 128$) 예측성능이 악화되는 것을 볼 수 있다. 따라서, 우수한 예측 정확도를 얻기 위해서는 은닉층 내의 뉴런의 개수를 체계적으로 결정하는 방법이 필요함을 알 수 있다.

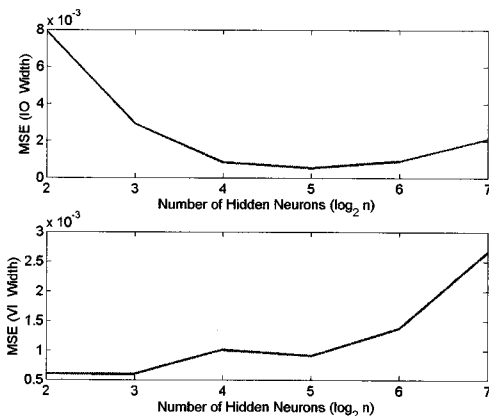


그림 2. 은닉층 내의 뉴런의 개수(n) 변화에 따른 결함 폭 예측오차. I-Out 결함(위 그림)과 V-In 결함(아래 그림)

Fig. 2. Size prediction performance versus the number of neurons in hidden layer (n). The width of I-Out defect (upper figure) and the width of V-In (lower figure) are shown

4. 교차검증을 이용한 신경회로망 구조 결정

신경회로망의 예측성능에 지대한 영향을 미치는 신경회로망 구조를 체계적으로 결정하는 효과적인 방법 중 하나는 교차검증(cross validation)을 이용하는 것이다[9]. 신경회로망 구조 중 은닉층 내의 뉴런의 개수는 예측성능에 특히 많은 영향을 미치는데, 교차검증을 이용하면, 가능한 한 최적의 예측성능을 얻기 위해서는 얼마나 많은 뉴런을 은닉층에 사용해야 하는가를 결정할 수 있다. 교차검증기법은 신경회로망 학습시 사용가능한 데이터를 추정데이터(estimation data)와 검증데이터(validation data)로 나누어서, 추정데이터는 뉴런의 개수를 결정하기 위한 신경망 임시학습에 사용하고 검증데이터는 임시 학습된 신경망의 일반화 성능을 근사적으로 추정하는데 사용하는 것이다. 바꾸어 말하면, 여러 가지 구조의 신경회로망 중에서 검증데이터에 대한 예측성능 MSE가 최소가 되는 뉴런의 개수를 갖는 신경회로망을 선택하는 것이다. 참고문헌 [10]에서는 5 가지 패턴분류 문제에 대해서 여러 가지 분류기를 사용한 예측성능과, 교차검증을 사용하여 선택한 분류기의 예측성능을 실험적으로 연구하였다. 이 연구결과에 의하면, 교차검증을 사용할 경우, 각각의 개별적인 분류기로부터 얻을 수 있는 예측성능보다 우수한 예측성능을 얻을 수 있는 분류기를 선택할 수 있음을 알 수 있었다. 또한, 교차검증을 이용하면 예측성능이 나쁜 분류기를 선택할 수 있는 위험을 획기적으로 줄일 수 있다는 것도 보였다. 하지만, 참고문헌 [10]에서 교차검증의 유효성을 실험적으로 보이기에는 하였지만, 이러한 교차검증이 항상 효과적임을 증명하는 명확한 이론이 존재하는 것은 아니다. 또한, 교차검증의 성공여부는 학습데이터로부터 추정데이터와 검증데이터로 추출하는 방식에 의해 영향을 받을 수도 있다. 본 논문에서는 원전 SG 세관 결함크기 예측에서의 교차검증의 유용성을 여러 가지 검증데이터 추출 방식에 대해서 분석하고자 한다. 결함크기 예측에 사용하는 교차검증은 다음과 같은 과정으로 진행된다.

- 1) 학습 데이터를 추정데이터와 검증데이터로 나눈다.
- 2) 은닉층 내의 뉴런의 개수를 n 이라고 할 때, 여러 가지 n 에 대해서 추정데이터만을 사용하여 신경 회로망을 학습시킨다. 단, 이 단계에서는 검증 데이터는 전혀 사용되지 않는다.
- 3) 2)에서 학습된 여러 가지 신경회로망에 대해서 검증 데이터에 대한 MSE를 계산한다. 이를 통하여 학습되지 않은 새로운 데이터에 대한 예측성능을 평가할 수 있다.
- 4) 3)에서 계산된 검증 데이터에 대한 예측오차를 최소로 하는 뉴런의 개수 n 을 최적의 뉴런의 개수 n^* 로 결정한다.
- 5) 전체학습데이터, 즉 추정데이터와 검증 데이터를 합한 데이터에 대해서 뉴런의 개수가 n^* 인 신경 회로망을 다시 한번 학습시킨다.
- 6) 학습된 신경회로망을 이용하여 평가데이터에 대한 예측성능을 계산하고 이를 이상적으로 얻을 수 있는 최선의 예측성능과 비교한다.

5. 컴퓨터 모의실험

본 장에서는 모의실험을 통하여 4장에서 제시한 교차검증의 유효성을 검증하고자 한다. MLP의 학습에는 학습속도가 빠른 것으로 알려져 있는 conjugate gradient 알고리즘을 사용하였다[9]. 본 논문에서는 conjugate gradient 알고리즘의 최대 반복 횟수는 3,000번, 수렴여부를 판정하는 목표오차(error goal)은 0.003으로 설정하였다. 또한, conjugate gradient 알고리즘의 구간 선정(interval location)을 위한 최대 반복 횟수는 100, 구간 축소(interval reduction)를 위한 최대 반복횟수는 1,000, 구간 축소의 수렴여부 판정에 사용되는 ϵ 은 10^{-6} , 선 탐색의 스텝 크기(step size)는 0.01, 황금분할(golden search) 검색에 사용되는 $\tau=0.618$ 로 설정하였다. 이러한 내용을 반영하여 신경 회로망 학습과 일반화성능 계산은 저자가 개발한 Matlab 프로그램을 이용하였다.

한편, MLP는 초기조건에 따라 설계 변수(weight, bias)가 유일한 해(unique solution)로 수렴하는 것이 보장되지 않기 때문에[9], 여러 번의 컴퓨터 모의실험

이 필요하다. 본 연구에서는 이를 고려하여 컴퓨터 모의실험을 10회 수행한 후 그 결과를 평균한 값을 이용하였다. 또한, 은닉층 내의 뉴런의 개수 n 을 결정해야 하는데, 여러 번의 모의실험 결과 $4 \leq n \leq 128$ 의 값을 고려해도 충분하였다. 이때, $n=4, 5, \dots, 128$ 의 모든 값을 고려하기 보다는 그 중 몇 가지 대표값만을 고려하는 격자검색(grid search)을 사용하는 것이 일반적이다. 또한, 격자검색에서의 대표값으로는 지수적으로 증가하는 수열을 사용하는 것이 일반적이며, 본 논문에서는 $n=2^2, 2^3, 2^4, \dots, 2^7$ 과 같은 값을 고려하였다. 따라서, 신경회로망 학습은 6가지 n 에 대해서 수행하며, 이 중에서 검증데이터에 대한 예측오차를 최소로 하는 뉴런의 개수를 선택하여 실제의 예측시스템에 사용하는 것이다.1)

이제, 학습데이터를 추정데이터와 검증데이터로 나누는 것이 필요한데 참고문헌 [9]에서는 학습데이터의 80[%]를 추정데이터로, 나머지 20[%]를 검증데이터로 할당하는 것을 권장하고 있다. 본 논문에서도 이를 적용하여 전체 100개의 학습데이터 중에서 20개는 검증데이터로, 나머지 80개는 추정데이터로 선정하였으며, 다음과 같은 5가지 방식을 고려하였다:

- 1) 학습데이터 중 깊이가 0.1[mm]인 모든 데이터를 검증데이터로 정하고, 나머지를 추정데이터로 정하는 방법(앞으로 D1로 표기함)
- 2) 학습데이터 중 깊이가 0.3[mm]인 모든 데이터를 검증데이터로 정하고, 나머지를 추정데이터로 정하는 방법(앞으로 D3로 표기함)

위와 비슷한 방식으로, 깊이가 0.5[mm], 0.7[mm], 0.9[mm]인 데이터를 검증데이터로 정하는 방식을 D5, D7, D9로 표시한다.

이제, I-Out 형태 결합의 폭을 예측하는데, 교차검

1) 좀 더 정확한 n 을 구하기 위해서는 격자검색을 2단계로 수행하는 것이다. 즉, $n=2^2, 2^3, 2^4, \dots, 2^7$ 의 값 중에서 최적의 n 을 찾은 후, 다시 미세검색(finer search)을 수행하는 것이다. 예를 들어, 처음 격자검색에서 찾은 값이 $n=2^5=32$ 이라면, 미세검색은 $n=20, 24, 28, 32, 34, 38, 42$ 와 같은 값 중에서 다시 최적의 n 을 찾는 것이다. 본 논문에서는 미세검색을 수행하지 않아도 상당히 우수한 결과를 얻을 수 있었기 때문에, 추가적인 미세검색은 수행하지 않는다.

증을 적용하여 은닉층의 뉴런의 개수를 구하여 보았다. 우선, 모든 학습데이터 (즉, 추정데이터와 검증데이터를 모두 포함)를 이용하여 신경회로망을 학습시킨 후, 평가데이터에 대한 MSE를 구하였다. 그림 3에서 실선으로 표시된 부분이 평가데이터에 대한 MSE이며, x축은 뉴런의 개수를 표시한 것으로 2, 3, 4, ..., 7은 각각 $n=2^2, 2^3, 2^4, \dots, 2^7$ 를 나타낸다. 그림으로부터 최선의 예측결과는 $n=2^5$ 에서 얻을 수 있으며 이때의 MSE는 5.4×10^{-4} 임을 알 수 있다. 이 결과는 우리가 고려하는 뉴런의 개수, $n=2^2, 2^3, 2^4, \dots, 2^7$ 중에서 얻을 수 있는 최상의 예측성능이지만, 평가데이터를 알고 있을 때에만 구할 수 있기 때문에 현실적으로는 얻을 수 없는 예측성능이다.

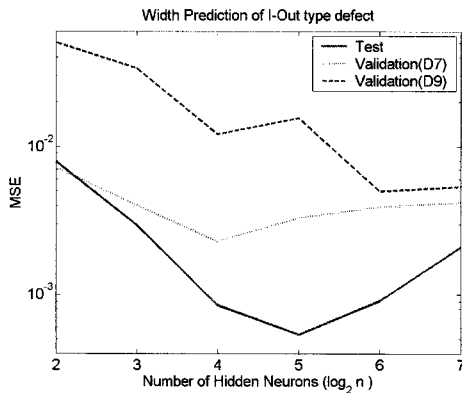


그림 3. 뉴런의 개수(n) 변화에 따른 I-Out 결함 폭 예측 오차
 Fig. 3. Width prediction of I-Out defect versus the number of hidden neurons (n)

이제, 평가데이터를 알 수 없을 때, 최적의 뉴런 개수를 결정하기 위하여 교차검증을 적용해 보자. 전술한 5가지 방식의 검증데이터 선정방식 중에서 우선 2가지 방식, D7, D9를 이용한 교차검증을 적용하여 보았다. 각각의 추정 데이터로 신경회로망을 학습시킨 후, 검증 데이터에 대한 MSE를 구한 결과를 그림 3에서 볼 수 있다. 그림에서 점선(dotted line)과 대취선(dashed line)은 각각 D7과 D9를 이용한 결과이다. 그림 3으로부터 D7에 대한 MSE는 $n=2^4$ 일 때 최소가 됨을 알 수 있다. (검증데이터로부터는 MSE가 최소가 되는 뉴런의 개수를 구하는 것이 목적이기 때문에,

이 때의 MSE 자체는 구할 필요가 없다.) 즉, 평가데이터에 대한 정보를 전혀 사용할 수 없을 때, 학습데이터만을 사용하여 내릴 수 있는 결론은 뉴런의 개수를 $n^*=2^4$ 로 정하는 것이 적절하다는 것이다. 마지막으로 신경회로망(은닉층 내 뉴런의 개수가 $n^*=2^4$ 인 신경망)을 모든 학습데이터를 이용하여 다시 학습시킨 후, 평가데이터에 대한 MSE를 계산하면 MSE는 8.5×10^{-4} 를 얻을 수 있다. 따라서, 이 경우에는 이상적으로 얻을 수 있는 최소 MSE (5.4×10^{-4})와 교차검증에 의해 현실적으로 얻을 수 있는 최소 MSE (8.5×10^{-4})의 차이가 $8.5 \times 10^{-4} - 5.4 \times 10^{-4} = 3.1 \times 10^{-4}$ 이다. 즉, 교차검증으로 결정한 뉴런의 개수를 갖는 신경회로망은 이상적으로 존재할 수 있는 최적의 신경회로망의 예측성능과 거의 비슷함을 알 수 있다. 마찬가지로, 그림 3으로부터 D9에 대한 MSE는 $n^*=2^6$ 에서 최소가 됨을 알 수 있으며, $n^*=2^6$ 개의 뉴런을 갖는 신경회로망을 다시 학습시킨 후 평가데이터에 대한 MSE를 계산하면 MSE는 9.1×10^{-4} 를 얻을 수 있다. 따라서, 이상적인 최소 MSE와 교차검증으로 얻을 수 있는 최소 MSE의 차이는 $9.1 \times 10^{-4} - 5.4 \times 10^{-4} = 3.7 \times 10^{-4}$ 이다. 즉, D7, D9 방식 모두 교차검증으로 적절한 결과를 얻을 수 있음을 알 수 있다.

한편, 위와 동일한 방법으로 I-In, I-Out, V-In, V-Out 형태 결함 폭을 예측하기 위하여 교차검증을 적용하여 보았다. 앞서 기술한 5가지 검증데이터 선정 방식, 즉, D1, D3, D5, D7, D9을 이용한 교차검증 결과를 표 1에 정리하였다. 또한, 비교를 위하여 평가데이터를 사용하여 얻을 수 있는 가능한 최선의 결과와 최악의 결과도 동시에 나타내었다. 표 1에서 각각의 값은 검증 데이터를 사용하여 MSE를 계산할 때 최소 MSE를 얻을 수 있는 뉴런의 개수를 의미하며, 괄호 안은 그 때의 평가데이터에 대한 MSE 값이다. 예를 들어, 'D7로 결정'행과 'I-Out' 열에 의한 값은 $n=2^4$ (8.5×10^{-4})인데, 이는 다음을 의미한다. 우선, I-Out 결함에 대해서 D7 방식의 교차검증을 사용할 경우 검증데이터에 대한 최소 MSE를 얻을 수 있는 뉴런의 개수는 $n=2^4$ 이다. (그림 3에서 점선을 보면 $x=4$ 에서 MSE가 최소가 된다.) 그 다음, 뉴런의 개수를 $n=2^4$ 로 결정하고, 전체 학습데이터를 이용해서 신경

회로망을 학습시킨 후 평가데이터에 대한 MSE를 계산하면 8.5×10^{-4} 이다. (그림 3에서 실선을 보면 $x=4$ 에서 MSE는 8.5×10^{-4} 이다.) 표 1로부터 D1, D3, D7, D9을 이용하는 경우에는 I-In, I-Out, V-In, V-Out 결합 모두에 대해서 '최선의 경우'와 같거나 거의 비슷한 성능을 얻을 수 있는 것을 확인할 수 있다. 이러한 예측성능을 '최악의 경우', '최선의 경우'와 비교하기 쉽게 하기 위하여, MSE가 0과 1사이의 값을 갖도록 각각의 결합별로 아래와 같이 스케일링(scaling)을 수행하였다.

표 1. 교차검증을 이용한 결합 폭 예측 결과. n은 뉴런의 개수, 괄호 안은 평가데이터에 대한 MSE를 나타냄

Table 1. Width prediction result using cross-validation. The number of hidden neurons (n) and MSE computed on the test set are shown

구조 결정방법	결함형태 I-In ($\times 10^{-4}$)	I-Out ($\times 10^{-4}$)	V-In ($\times 10^{-4}$)	V-Out ($\times 10^{-3}$)
최선의 경우	$n=2^7$ (2.11)	$n=2^5$ (5.35)	$n=2^3$ (5.98)	$n=2^5$ (5.61)
최악의 경우	$n=2^6$ (3.57)	$n=2^2$ (79.2)	$n=2^7$ (26.6)	$n=2^2$ (12.9)
D1로 결정	$n=2^7$ (2.11)	$n=2^6$ (9.1)	$n=2^1$ (10.1)	$n=2^7$ (5.84)
D3로 결정	$n=2^7$ (2.11)	$n=2^6$ (9.1)	$n=2^2$ (6.03)	$n=2^7$ (5.84)
D5로 결정	$n=2^7$ (2.11)	$n=2^3$ (29.4)	$n=2^2$ (6.03)	$n=2^7$ (5.84)
D7로 결정	$n=2^7$ (2.11)	$n=2^4$ (8.5)	$n=2^2$ (6.03)	$n=2^5$ (5.61)
D9로 결정	$n=2^7$ (2.11)	$n=2^6$ (9.1)	$n=2^2$ (6.03)	$n=2^5$ (5.61)

$$MSE_{sc} = \frac{MSE_{worst} - y}{MSE_{worst} - MSE_{best}} \quad (2)$$

여기서, MSE_{worst} 는 최악의 경우의 MSE이고, MSE_{best} 는 최선의 경우의 MSE이다. 예를 들어 I-Out 결합에 대해서 D6의 스케일링된 MSE는 아래와 같다.

$$y_{sc} = \frac{79.2 - 29.4}{79.2 - 5.35} = 0.67 \quad (3)$$

이와 같이 스케일링된 MSE를 이용하면, 현재의 예측성능이 어느 정도 우수한 것인가를 쉽게 확인할 수 있다. 이와 같은 방식으로 모든 결합에 대한 예측 결과를 표 2에 정리하였다. 표 2에서 '평균'은 I-In, I-Out, V-In, V-Out, 4가지 결합에 해당하는 값을 평균한 값을 나타내는데, 이를 통하여 전체적인 예측성능을 쉽게 파악할 수 있다.

표 2. 교차검증을 이용한 결합 폭 예측성능. 각각의 수치는 스케일링된 MSE를 나타냄(0은 최악, 1은 최선의 예측성능을 각각 의미함)

Table 2. Width prediction performance using cross-validation. The scaled MSEs are shown(0 and 1 represent the worst and the best results, respectively)

구조 결정방법	결함형태 I-In	I-Out	V-In	V-Out	평균
D1	1	0.95	0.8	0.97	0.93
D3	1	0.95	1	0.97	0.98
D5	1	0.67	1	0.97	0.91
D7	1	0.96	1	1	0.99
D9	1	0.95	1	1	0.99

표 2로부터 D1, D3, D5, D7, D9 모두 평균값이 0.91 이상임을 알 수 있고, 이는 모든 방식이 대체로 최선의 예측성능과 매우 비슷한 예측성능을 나타냄을 의미한다.

그림 4는 교차검증(D7 또는 D9이용)에 의한 V-Out 결합의 폭 예측결과를 보여준다. 실선은 교차검증으로 결정한 뉴런 개수($n=2^5$)를 갖는 신경회로망을 이용한 예측결과를 보여준다. 또한, 교차검증을 이용하지 않는 경우와의 비교를 위하여 2^2 개의 은닉층 뉴런으로 구성된 신경회로망에 의한 예측결과를 대쉬선으로 표시하였다. 그림 4로부터 교차검증으로 결정한 신경회로망 구조가 우수한 예측성능을 주고 있음을 확인할 수 있다.




그림 4. 신경회로망을 이용한 V-Out 형태 결함 폭 예측 결과(실선은 $n = 2^5$ 인 경우이고 대시선은 $n = 2^2$ 인 경우임)

Fig. 4. Prediction result for the width of V-Out defect using neural networks(The solid line stands for $n = 2^5$, and the dashed line for $n = 2^2$)

5. 결 론

본 논문에서는 원자력 세관 결함크기 예측에 사용되 는 신경회로망의 효과적인 구조 결정 방법에 대한 연 구를 수행하였다. 신경회로망의 예측성능은 은닉층 내의 뉴런의 개수에 의해서 많은 영향을 받는데, 본 논 문에서는 교차검증을 이용하여 이를 결정할 경우, 상 당히 우수한 예측성능을 얻을 수 있음을 실험적으로 입증하였다. 모의실험을 통하여 알아본 결과, D3, D7, D9의 경우 최상의 예측성능의 98[%]까지 예측정확도 를 얻을 수 있음을 확인할 수 있었으며, 나머지 두 가 지 경우(D1, D5)의 경우에도 최상의 예측성능의 91[%]이상의 예측정확도를 얻을 수 있음을 알 수 있 었다. 따라서, 본 연구에서 제안한 기법은 원자력 발전 소 세관의 결함 크기를 예측하는데 효과적으로 활용 될 수 있을 것으로 기대된다.

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

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, No. 3, 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, No. 2, 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] 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.
- [7] 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.
- [8] 조남훈, 이항범, 한기원, 송성진 "신경회로망을 이용한 원전SG 세관 결함패턴 분류성능 향상기법," 전기학회 논문지, Vol. 56, No. 7, pp. 1224 - 1230, July, 2007.
- [9] S. Haykin, Neural Networks, New Jersey: Prentice Hall, 1999.
- [10] C. Schaffer, "Selecting a Classification Method by Cross-Validation," Machine Learning, Vol. 13, pp. 135-143, 1993.

◇ 저자소개 ◇

조남훈 (趙南薰)

1970년 3월 18일생. 1992년 서울대 공대 전기공학과 졸업. 2000년 서울대 대학원 전기공학부 졸업(박사). 2001~2002년 삼성전자 DVS사업부 책임연구원. 2002년~현재 숭실대학교 전기공학부 교수. 2006년~현재 대한전기학회 논문지 편집위원 2009년~현재 대한전기학회 편집이사.

관심분야 : 패턴인식 및 비파괴검사에의 응용, 풍력터빈 제어시스템, 제어 시스템 및 시스템 생물학에의 응용.

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