

조기 학습정지를 이용한 원전 SG세관 결함크기 예측 신경회로망의 성능 향상

論 文

57-11-32

A performance improvement of neural network for predicting defect size of steam generator tube using early stopping

趙南熏[†]
(Nam-Hoon Jo)

Abstract In this paper, we consider a performance improvement of neural network for predicting defect size of steam generator tube using early stopping. Usually, neural network is trained until MSE becomes less than a prescribed error goal. The smaller the error goal, the greater the prediction performance for the trained data. However, as the error goal is decreased, an over-fitting is likely to start during supervised training of a neural network, which usually deteriorates the generalization performance. We propose that, for the prediction of an axisymmetric defect size, early stopping can be used to avoid the over-fitting. Through various experiments on the axisymmetric defect samples, we found that the difference between the prediction error of neural network based on early stopping and that of ideal neural network is reasonably small. This indicates that the error goal used for neural network training for the prediction of defect size can be efficiently selected by early stopping.

Key Words : Tube defect, Neural network, Prediction, Over fitting, Early stopping,

1. 서 론

2002년 4월 울진 4호기의 증기발생기 세관 파단사고와 같은 사고를 미연에 방지하기 위해서는 비파괴검사 신뢰도를 개선하기 위한 연구가 매우 중요하다. 원자력발전소에서의 사고는 방사능이라는 문제와 연결되기 때문에 기술적인 문제, 정치적인 문제, 사회적인 문제 모든 면에서 반드시 예방하여야만 하는 문제이다. 원전 선비 중 원자력 발전소 증기발생기 세관은 원자로를 거치는 1차 계통수와 2차 계통수 사이에서 열을 전달하고 터빈 발전기를 돌리는 증기를 발생시키며 동시에 방사능 차단벽으로서 중요한 기능을 하고 있다. 증기발생기 세관은 가동 특성상 결함발생 가능성이 매우 높으며, 실제로 원전 수명관리에 큰 영향을 미치고 있다. 만일 증기 세관 결함을 검출할 수 있는 비파괴검사법에 대한 연구가 충분히 이루어져 있었다면 2002년 울진 4호기 사고는 미연에 방지할 수도 있었을 것이다.

원전설비검사에 사용되는 대표적인 비파괴검사법으로 와전류탐상시험(Eddy Current Testing: ECT)방법이 있는데, 이는 도체에 와전류를 유도하여 그 왜곡 여부를 관찰함으로써 검사체의 이상 유무를 판단하는 비파괴검사 방법이다. ECT는 비접촉 방식으로서 고속 자동화가 가능하고 다른 비파괴 검사법에 비하여 상대적으로 비용이 저렴한 장점이 있어 증기발생기 세관 검사에 가장 널리 사용되고 있다. 그러나 ECT 신호를 발생시키는 요인과 결함의 종류가 다양하여 검사 결과의 분석이

복잡하고 많은 경우 경험에 의존하므로, 검사 결과의 신뢰성 평가를 병행해야 한다. 현재 선진 각국에서는 유한요소법이나 경계요소법 등 수치해석 기법을 이용하여 와전류탐상 검사의 전 과정을 모사하고, 결함 신호를 이론적으로 예측코자 하는 연구를 경쟁적으로 수행하고 있다 [1-4]. 또한, 신경회로망 기법 등 최첨단 인공지능 기술을 적용하여 결함신호를 분석하여 결함의 위치, 종류, 크기 등을 자동적으로 결정하는 기법의 개발에도 심혈을 기울이고 있다 [5-10]. 이러한 결함 검출 기법의 예측 정확성을 더욱 높이기 위해서는 적절한 특징추출과 분류기 및 예측기의 설계가 매우 중요하다.

본 논문에서는 신경회로망 결함크기예측에서 예측성능에 적지 않은 영향을 주는 목표오차(target error)의 선택기법에 대한 연구를 수행하고자 한다. 결함크기 예측을 위한 신경회로망의 학습은 일반적으로 MSE(Mean Square Error)가 미리 정한 목표오차(Error goal)보다 작아질 때까지 계속된다. 일반적으로 목표오차를 줄일수록 학습데이터에 대한 예측성능은 향상되지만, 학습되지 않은 데이터에 대한 예측성능이 좋아지는 것은 아니다. 이와 같이 학습에 사용되지 않은 새로운 데이터에 대한 신경회로망의 성능을 일반화 성능(Generalization performance)이라고 하는데, 우수한 일반화 성능을 얻을 수 있는 목표오차를 설정하는 것은 중요한 문제이다. 이를 위하여 본 논문에서는 신경회로망 학습시 일반화성능을 높일 수 있는 것으로 알려져 있는 조기학습정지(early stopping) 기법을 결함크기 예측에 적용해 보고자 한다. 하지만, 조기학습정지 전략이 모든 경우에 효과적임을 증명하는 명확한 이론이 존재하는 것은 아니기 때문에, 조기학습정지 기법의 효용성 여부는 각각의 사례별로 실험적으로 입증되어야 한다. 본 논문에서는 결함크기 예측을 위한 신경회로망 학습에서 조기학습정지 전략이 매우 유용하다는

[†] 교신저자, 正會員 : 崇實大 工大 電氣工學部 副教授 · 工博

E-mail : nhjo@ssu.ac.kr

接受日字 : 2008年 8月 1日

最終完了 : 2008年 9月 8日

것을 실험적으로 입증하고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 본 논문에서 고려하는 4가지 축대칭 결함의 형태를 소개하고, 결함 크기 예측을 위해서 필요한 특징벡터의 추출에 대해서 기술한다. 3장에서는 결함크기 예측을 위해서 사용하는 신경회로망 구조를 소개하고, 전체 ECT 신호 샘플을 학습데이터와 평가데이터로 나누는 방법을 기술한다. 또한, 과대학습시 나타날 수 있는 과대적합의 문제를 살펴보고, 이를 회피할 수 있는 조기학습정지 전략을 소개한다. 4장에서는 모의실험을 통하여 조기학습정지 전략이 목표오차를 효과적으로 선택할 수 있음을 보이며, 마지막으로 5장에서는 본 논문의 결론을 제시한다.

2. 축대칭 결함 및 특징추출

2.1 축대칭 결함

본 논문에서는 축대칭 결함신호의 깊이와 폭 크기를 추정하는데 조기학습정지 전략의 효용성을 검증하는 것을 목적으로 한다. 본 연구에서는 4가지 결함형태, 즉 I형 관외벽 결함(I-In type), I형 관외벽 결함(I-Out type), V형 관외벽 결함(V-In type), V형 관외벽 결함(V-Out type)을 고려하는데, 그림 1은 위의 4가지 결함 중 I-Out 결함과 V-Out 결함 형태를 나타낸다.




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 예측 알고리즘을 학습시키는 데 충분한 량의 ECT 결함신호 표본들이 필요하다. 이를 위하여, 참고문헌 [7], [10]과 동일한 방법으로, I형 결함 100개와 V형 결함 100개의 ECT 신호를 수치해석 프로그램을 이용하여 생성하였다. 결함의 종류는 형상에 따라 2가지(I/V-type), 위치에 따라 2가지 (In/Out) 총 4가지로 구분하였다. 그 후, 각 범주에 속한 결함의 크기 (폭과 깊이)를 다양하게 변화시킨 후, 각 결함에 대해 와전류탐상 주파수를 2가지 (100kHz / 400kHz)로 변화시켜 가면서 I형 결함에 대해서 200개, V형 결함에 대해서 200개의 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.

2.2 결함 크기 예측을 위한 특징 벡터

결함 형태 분류 및 크기 예측을 위한 특징벡터는 몇 가지 방식이 기존에 학계에 보고되었다. [7]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 신

호 시작점의 출발각, 결함 신호 끝점의 도착각 등등)를 추출하였다. 이러한 분류기를 사용할 경우 I-Out, V-Out, V-In 결함에 대해서는 대부분 정확하게 분류할 수 있었지만, I-In 결함에 대해서는 25개의 샘플신호 중 8개를 V-In 결함으로 분류하였다. 즉, 분류 실패율이 $8/25 \times 100 = 32\%$ 로 상대적으로 높다는 것이 보고되었다. 한편, 최근에 [10]에서 분류 정확도를 개선하기 위하여 새로운 특징 3가지를 제안하였다. [10]에서 제안된 특징벡터는 최대 임피던스 값, 최대 임피던스 값을 갖는 점의 위상, 최대 임피던스 값을 갖는 점과 최대 임피던스 값의 1/2의 값을 갖는 점 사이의 위상각을 의미한다. 참고문헌 [10]에서는 이러한 세 가지 특징을 사용하여 결함패턴을 분류할 경우 기존의 연구결과 [7]보다 우수한 결과를 얻을 수 있음을 보였다.

본 논문에서는 [10]에서 제안한 특징벡터를 이용하며, 결함 크기 예측을 위하여 100 kHz와 400 kHz ECT신호를 동시에 사용한다. 결과적으로 본 논문에서는 6가지 특징, 즉, 1) 주파수가 100 kHz일 때의 최대 임피던스 값, 2) 주파수가 100 kHz일 때의 최대 임피던스 값을 갖는 점의 위상, 3) 주파수가 100 kHz일 때의 최대 임피던스 값을 갖는 점과 최대 임피던스 값의 1/2의 값을 갖는 점 사이의 위상각, 4) 주파수가 400 kHz일 때의 최대 임피던스 값, 5) 주파수가 400 kHz일 때의 최대 임피던스 값을 갖는 점의 위상, 6) 주파수가 400 kHz일 때의 최대 임피던스 값을 갖는 점과 최대 임피던스 값의 1/2의 값을 갖는 점 사이의 위상각을 사용한다.

3. 신경회로망 예측시스템과 조기 학습정지 전략

3.1 NN 구조, 학습데이터, 검증데이터, 평가데이터

본 논문에서는 결함크기 예측을 위하여 신경회로망을 사용한다. 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 퍼셉트론으로서 그림 2는 두 개의 은닉층을 갖는 MLP의 구조를 나타낸다. MLP는 충분히 많은 뉴런을 사용할 경우 임의의 함수를 근사할 수 있는 성질이 알려져 있기 때문에, 함수 근사화, 복잡한 패턴 분류, 예측이론 등에 자주 사용된다 [11],[12].

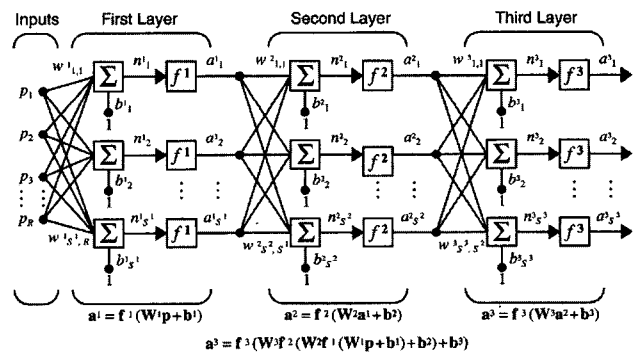


그림 2 두 개의 은닉층을 갖는 다층 퍼셉트론 구조
Fig. 2 The structure of multi-layer perceptron (MLP) with two hidden layers

본 논문에서는 I-In 깊이, I-In 폭, V-In 깊이, V-In 폭, I-Out 깊이, I-Out 폭, V-Out 깊이, V-Out 폭 예측을 위해서 각각 독립적인 MLP를 사용한다. 하지만, 8개의 MLP는 모두 동일한 구조로 설계하는데, 하나의 은닉층을 갖고, 그 은닉층은 10개의 뉴런을 갖도록 하였다. 또한, 2장에서 기술한 바와 같이 결합크기 예측을 위해서 6개의 특징을 이용하므로, 입력층의 뉴런은 6개로 구성하였다.

한편, 신경회로망의 학습에 사용되는 학습 데이터는 깊이가 0.1mm, 0.3mm, 0.5mm, 0.7mm, 0.9mm 인 데이터 100개로 선정하였으며, 신경회로망의 예측정확도를 측정하는데 사용되는 평가데이터는 깊이가 0.2mm, 0.4mm, 0.6mm, 0.8mm, 1.0mm 인 데이터로 선정하였다. 신경회로망의 예측오차 계산에는 MAPE(Mean Absolute Percentage Error)가 많이 사용되는데, MAPE는 아래와 같이 정의된다.

$$MAPE = 100 \times \frac{\sum_{i=1}^n \left| \frac{x_i - \hat{x}_i}{x_i} \right|}{n}$$

여기서, x_i 는 실제 결합크기이고 \hat{x}_i 는 결합크기 추정치이며, n 은 실험 데이터 개수이다.

3.2 신경회로망의 일반화 성능 및 과대학습

결합크기 예측을 위한 신경회로망 시스템을 현장에 적용하기 위해서는 우선, 적절한 데이터를 이용하여 신경회로망을 학습하여야 한다. 신경회로망의 학습은 일반적으로 평균 제곱오차(Mean Square Error; MSE)가 미리 정한 목표오차(Error goal) ϵ 보다 작아질 때까지 계속된다. 일반적으로 목표오차를 작게 선택할수록 학습데이터에 대한 예측성능은 향상된다. 하지만, 실제로 현장에서 신경회로망 예측시스템을 사용하는 경우에는 학습되지 않은 새로운 데이터가 신경회로망의 입력으로 사용된다. 이와 같이 학습에 사용되지 않은 새로운 데이터에 대한 신경회로망의 성능을 일반화 성능(Generalization performance)이라고 한다. 전술한 목표오차가 작아질수록 일반화성능도 좋아질 것이라고 생각하기 쉽지만 항상 그렇지는 않다. 실제로, 이러한 사실은 축대칭 결합 크기 예측 결과중 하나인 그림 3에서도 확인할 수 있다. 그림 3은 목표오차를 $\epsilon = 2^{-2}, 2^{-3}, \dots, 2^{-12}$ 으로 점점 줄여갈 때, 평가데이터에 대한 MAPE가 어떻게 변하여 가는가를 나타낸다. V-Out 결합의 깊이를 예측할 때의 MAPE 변동추이를 그림 2의 위 그림에서 볼 수 있으며, V Out 결합의 폭에 대한 MAPE 변동추이는 아래 그림에서 볼 수 있다. 각각의 그림에서 x축은 목표오차를 표시한 것으로 2, 4, 6, ...은 각각 $\epsilon = 2^{-2}, 2^{-4}, 2^{-6}, \dots$ 을 나타낸다. 그림 2로부터 깊이를 예측하는 경우, $\epsilon = 2^{-10}$ 일 때, 가장 우수한 MAPE를 얻을 수 있지만, 폭을 예측하는 경우에는, $\epsilon = 2^{-5}$ 에서 가장 우수한 MAPE를 얻을 수 있다는 것을 확인할 수 있다.

따라서, 목표오차를 줄인다고 해서 학습되지 않은 데이터에 대한 예측정확도를 높일 수 없으며, 적절한 목표오차에서 학습을 멈추지 않으면 과대적합(over-fitting)으로 인한 일반화성능의 저하가 초래된다. 또한, 우수한 예측정확도를 얻을 수 있는 목표오차는 예측 대상에 따라 달라질 수 있으며, 이와 같은 이유로 적절한 목표오차를 체계적으로 결정하는 것

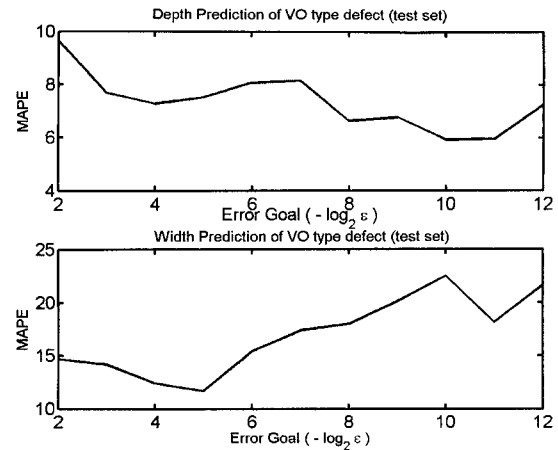


그림 3 목표오차(ϵ)의 변화에 따른 V-Out 결합 크기 예측오차. 위 그림은 깊이 예측결과이며, 아래 그림은 폭 예측 결과임

Fig. 3 Size prediction of V-Out defect versus the error goal (ϵ). The depth prediction result (upper figure) and the width prediction result (lower figure) are shown.

은 매우 중요하다는 것을 알 수 있다.

3.3 과대적합 방지를 위한 조기학습정지

과대적합의 징후를 확인하는 방법 중의 한 가지는 교차검증(cross validation)을 이용한 조기학습정지(early stopping)이다 [12],[13]. 교차검증을 적용하기 위해서는 학습데이터를 추정데이터(estimation data)와 검증데이터(validation data)로 나누는데, 추정데이터는 목표오차를 결정하기 위한 신경망 임시학습에 사용하고, 검증데이터는 임시 학습된 신경망의 일반화 성능을 근사적으로 추정하는데 사용한다. 추정데이터로 신경망을 학습시켜 나갈 때, 목표오차가 작아질수록 추정데이터에 대한 MAPE는 점점 줄어들지만, 검증데이터에 대한 MAPE는 줄어들다가 어느 순간부터는 커지는 경우가 일반적이다. 조기학습정지 전략은 이와 같이 검증데이터에 대한 MAPE가 최소점을 지나서 증가하기 시작하면 학습을 멈추는 기법이다. 바꾸어 말하면, 여러 가지 목표오차 중에서, 검증데이터에 대한 MAPE가 최소가 되는 목표오차를 사용하여 신경회로망을 학습하자는 것이다. 하지만, 이러한 조기학습정지 전략이 항상 효과적임을 증명하는 명확한 이론이 존재하는 것은 아니다. 또한, 조기학습정지 전략의 성공 여부는 학습데이터를 추정데이터와 검증데이터로 나누는 방법에 의해 영향을 받을 수도 있다. 따라서, 조기학습정지 기법의 효용성 여부는 각각의 사례별로 실험적으로 입증되어야 하며, 본 논문에서는 결합크기 예측에서의 조기학습정지의 유용성을 검증하고자 한다. 결합크기 예측에 사용하는 조기학습정지는 다음과 같은 과정으로 진행된다.

- 1) 학습 데이터를 추정데이터와 검증데이터로 나눈다.
- 2) 여러 가지 목표오차에 대해서 추정데이터만을 사용하여 신경회로망을 학습시킨다 여기서, 검증 데이터는 신경회로망을 학습시킬 때 전혀 사용되지 않는다..
- 3) 2)에서 학습된 신경회로망에 대해서 검증 데이터에 대한 MAPE를 계산한다. 이를 통하여 학습되지 않은 데이터

에 대한 예측성능을 더 정확히 평가할 수 있다.

4) 3)에서 계산된 검증 데이터에 대한 예측오차를 최소로 하는 목표오차 ϵ 를 최적의 목표오차 ϵ^* 로 결정한다.

5) 목표오차 ϵ^* 를 이용하여 전체학습데이터, 즉 추정데이터와 검증 데이터를 합한 데이터에 대해서 신경회로망을 다시 한번 학습시킨다.

6) 학습된 신경회로망을 이용하여 평가데이터에 대한 예측을 수행한다.

다음 장에서는 위에서 제시한 조기학습정지를 사용하여 학습된 신경회로망의 예측성능과 이론적으로 최적의 목표오차로 학습된 신경회로망과의 예측성능을 비교할 것이다. 이를 통하여 조기학습정지를 이용한 결함 크기에측기법이 충분히 만족할 만한 효과를 낼 수 있음을 실험적으로 입증한다.

4. 컴퓨터 모의실험

본 장에서는 모의실험을 통하여 3장에서 제시한 조기 학습정지 전략의 유효성을 검증하고자 한다. 여러 번의 모의 실험 결과 목표오차를 $\epsilon=0.0002$ 보다 작게 설정하면 $\epsilon=0.0002$ 인 경우와 예측성능이 거의 차이가 없으며, 단지 학습시간이 불필요하게 길어진다는 것을 알 수 있었다. 이와 같은 이유로 본 논문에서는 다음과 같은 목표오차만을 고려하기로 한다: $\epsilon=2^{-2}, 2^{-3}, \dots, 2^{-12}$. 따라서, 신경회로망 학습은 각각의 결함크기 예측에 대해서, 11가지 목표오차에 대해서 수행하며, 이 중에서 검증데이터에 대한 예측오차를 최소로 하는 목표오차를 선택하여 실제의 예측시스템에 사용하는 것이다.

또한, 신경회로망 학습시 입력 전처리 과정으로서 입력벡터의 크기조정(scaling)을 수행한다. 입력벡터 크기조정을 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 크기조정을 수행한 후 신경회로망을 학습시킨다. 여기서 주의할 점은, 결함크기를 예측할 때 사용하는 입력벡터(즉, 평가데이터)도 반드시 위와 같은 크기조정을 거친 후 사용되어야 한다는 것이다. 마지막으로, MLP는 초기조건에 따라 설계변수(weight, bias)가 유일한 해(unique solution)로 수렴하는 것이 보장되지 않기 때문에 여러 번의 컴퓨터 모의실험이 필요하다. 본 연구에서는 이를 고려하여 컴퓨터 모의실험을 10회 수행한 후 그 결과를 평균한 값을 이용하였다.

4.1 결함 폭(defect width) 예측

첫 번째로, V-Out 형태 결함의 폭을 예측하는데, 조기 학습정지를 적용하여 보았다. 우선, 모든 학습데이터 (즉, 추정데이터와 검증데이터를 모두 포함)를 이용하여 신경회로망을 학습시킨 후, 평가데이터에 대한 MAPE를 구하였다. 그림 4에서 실선으로 표시된 부분이 평가데이터에 대한 MAPE이며, x축은 목표오차를 표시한 것으로 2, 4, 6, ..., 12는 각각 $\epsilon=2^{-2}, 2^{-4}, 2^{-6}, \dots, 2^{-12}$ 를 나타낸다. 그림으로부터 MAPE 최소값은 11.7% 이고, 이를 얻을 수 있는 목표

오차는 $\epsilon=2^{-5}$ 임을 알 수 있다. 이 결과는 우리가 고려하는 목표오차를 사용하는 경우 중에서 얻을 수 있는 최상의 예측성능이지만, 평가데이터를 이미 알고 있다는 비현실적인 가정을 토대로 얻은 결과이다. 따라서, 실제의 경우에는 이러한 MAPE를 갖는 예측시스템을 구성하는 것은 일반적으로 불가능하다.

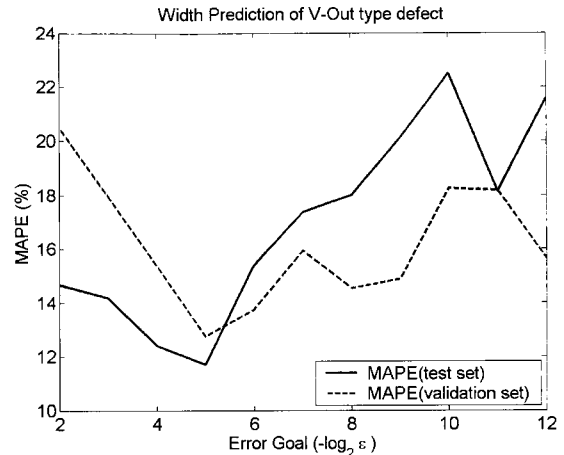


그림 4 목표오차(ϵ)의 변화에 따른 V-Out 결함 폭 예측오차. 실선은 평가데이터에 대한 예측결과이며, 점선은 검증데이터에 대한 예측 결과임

Fig. 4 Width prediction of I-In defect versus the error goal (ϵ), MAPE for test data (solid line) and MAPE for validation data (dotted line) are shown.

이제, 평가데이터를 알 수 없을 때, 목표오차를 결정하기 위하여 조기학습정지를 적용해 보자. 이를 위해서는 우선 학습데이터를 추정데이터와 검증데이터로 나누어야 한다. 본 논문에서는 전체 학습데이터 중에서 깊이가 0.5mm, 0.9mm 인 데이터를 검증 데이터로 정하고, 나머지를 추정 데이터로 정하도록 한다. 추정 데이터로 신경회로망을 학습시킨 후, 검증 데이터에 대한 MAPE를 구한 결과를 그림 4의 점선에서 볼 수 있다. 그림으로부터 검증데이터에 대한 MAPE는 $\epsilon=2^{-5}$ 일 때 최소가 됨을 알 수 있다. (이 때의 최소값은 12.7% 임을 알 수 있지만, 이 값은 사실 구할 필요가 없다.) 즉, 평가데이터를 사용하지 않고 학습데이터만을 사용하여 내릴 수 있는 결론은 목표오차를 $\epsilon=2^{-5}$ 로 정하는 것이 적절하다는 것이다. 마지막으로 목표오차를 $\epsilon=2^{-5}$ 로 정한 후 모든 학습데이터에 대해서 신경회로망을 학습시킨 후, 평가데이터에 대한 MAPE를 계산하면 MAPE는 11.7%이다. 따라서, 이 경우에는 이상적으로 얻을 수 있는 최소 MAPE와 교차검증에 의해 현실적으로 얻을 수 있는 최소 MAPE가 동일함을 알 수 있고¹⁾, 조기학습정지가 매우 효과적임을 알 수 있다.

한편, V-Out 형태 결함의 경우와 동일한 방법으로 I-In,

1) 교차검증에 의해 현실적으로 얻을 수 있는 최소 MAPE는 이상적으로 얻을 수 있는 최소 MAPE 보다 일반적으로 큰 경우가 대부분이다. 실제로 표 1의 I-In, I-Out, V-In 결함의 폭 예측 결과로부터 이를 확인할 수 있다.

I Out, V In 형태 결함의 폭을 예측하는 데에도 조기학습정지를 적용하여 보았으며 그 결과를 표 1에 정리하였다. 표 1에서 '검증데이터 최적 MAPE'는 검증데이터에 대한 예측 수행시(추정데이터만으로 학습시킨 신경회로망 이용) 얻을 수 있는 최적의 MAPE와 이때 사용된 목표오차를 의미한다. 따라서, 여기서 구할 수 있는 목표오차가 실제 예측시스템에 최종적으로 사용되는 값이다. '평가데이터 최적 MAPE'는 평가데이터에 대한 예측 수행시(모든 학습데이터를 이용하여 학습시킨 신경회로망 이용) 얻을 수 있는 최적 MAPE와 이때 사용된 목표오차를 나타낸다. 마지막으로 '평가데이터 MAPE (조기학습정지 적용)'는 조기학습정지를 적용하여 평가데이터에 대한 예측 수행시(모든 학습데이터와 '검증데이터 최적 MAPE'에서 구한 목표오차를 이용하여 학습시킨 신경회로망 이용) 얻을 수 있는 MAPE이다.

표 1 조기학습정지를 이용한 폭 예측 결과
Table 1 Width prediction result using early stopping

결함종류	검증데이터 최적 MAPE	평가데이터 최적 MAPE	평가데이터 MAPE (조기 학습정지 적용)
I In	5.62 % ($\epsilon = 2^{-10}$)	1.25% ($\epsilon = 2^{-11}$)	1.39% ($\epsilon = 2^{-10}$)
I Out	7.32 % ($\epsilon = 2^{-7}$)	4.72% ($\epsilon = 2^{-5}$)	5.45% ($\epsilon = 2^{-7}$)
V In	1.57% ($\epsilon = 2^{-6}$)	3.20% ($\epsilon = 2^{-7}$)	3.37% ($\epsilon = 2^{-6}$)
V Out	12.7% ($\epsilon = 2^{-5}$)	11.7% ($\epsilon = 2^{-5}$)	11.7% ($\epsilon = 2^{-5}$)

표 1로부터 최상의 MAPE를 기준으로 할 때, I In, I Out, V-In, V-Out 결함 예측성능이 각각 0.14%, 0.73%, 0.17%, 0% 저하되는 것을 확인할 수 있으며, 이는 조기학습정지 기법을 적용하여 우수한 예측성능을 얻을 수 있음을 의미한다.

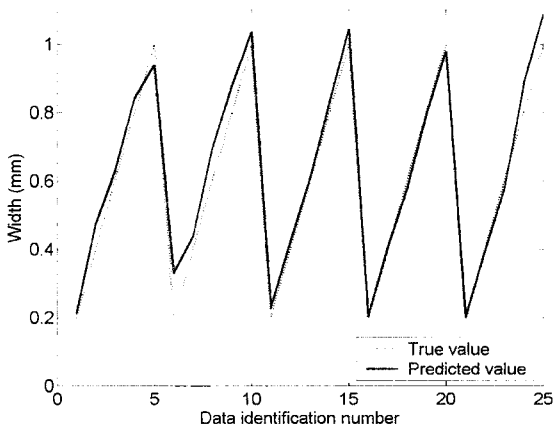


그림 5 조기학습정지를 이용한 V-Out 형태 결함 폭 예측결과
Fig. 5 Prediction result for the width of V-Out defect using early stopping

그림 5는 조기학습정지 전략(목표오차 $\epsilon = 2^{-5}$ 이용)으로 학습시킨 신경회로망을 이용한 V-Out 결함의 폭 예측결과를 보여준다. 조기학습정지를 이용하지 않는 경우는 일반적으로 임의의 작은 값을 목표오차로 사용한다. 이러한 경우 (여기서는 $\epsilon = 2^{-12}$ 이용)의 예측결과를 그림 6에서 볼 수 있는데, 그림 5와 비교하여 예측성능이 상당히 악화되었음을 볼 수 있다.

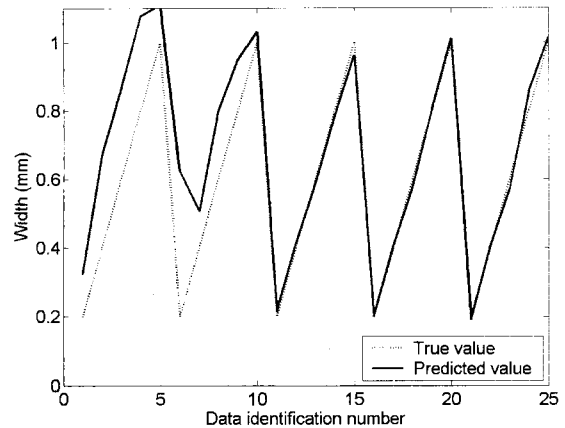


그림 6 목표오차 $\epsilon = 2^{-12}$ 를 이용한 V-Out 형태 결함 폭 예측결과
Fig. 6 Prediction result for the width of V-Out defect using error goal $\epsilon = 2^{-12}$

4.2 결함 깊이(defect depth) 예측

우선 I-In 형태 결함의 깊이를 예측하는데, 4.1절과 마찬가지로 조기학습정지를 적용하여 보았다. 우선, 모든 학습데이터를 이용하여 신경회로망을 학습시킨 후, 평가데이터에 대한 MAPE를 구하였다. 그림 7에서 실선으로 표시된 부분이 평가데이터에 대한 MAPE인데, MAPE 최소값은 1.12% 이고 이 때 사용된 목표오차는 $\epsilon = 2^{-11}$ 임을 알 수 있다. 이 결과는 신경회로망을 사용할 때 얻을 수 있는 최상의 예측성능이지만, 평가데이터를 이미 알고 있다는 비현실적인 가정을 토대로 목표오차 ϵ 를 결정하기 때문에 실제의 경우에는 사용할 수가 없다.

이제, 평가데이터를 알 수 없을 때, 목표오차를 결정하기 위하여 조기학습정지를 적용해 보자. 이를 위해서는 우선 학습데이터를 추정데이터와 검증데이터로 나누어야 한다. 본 절에서는 전체 학습데이터 중에서 폭이 0.4mm, 0.8mm 인 데이터를 검증 데이터로 정하고, 나머지를 추정 데이터로 정하도록 한다. 이제 추정 데이터로 신경회로망을 학습시킨 후, 검증 데이터에 대한 MAPE를 구한 결과를 그림 7의 점선에서 볼 수 있다. 그림으로부터 검증데이터에 대한 MAPE는 $\epsilon = 2^{-12}$ 일 때 최소이며, 그 값은 0.88% 임을 알 수 있다. 마지막으로 목표오차를 $\epsilon = 2^{-12}$ 로 정한 후 모든 학습데이터에 대해서 신경회로망을 학습시킨 후, 평가데이터에 대한 MAPE를 계산하면 MAPE는 1.14% 이다. 따라서, 이상적으로 얻을 수 있는 최상의 MAPE는 1.12% (그림 7에서 목표오차가 $\epsilon = 2^{-11}$ 일 때의 실선 참조)일 때, 조기학습정지에 의해 현실적으로 얻을 수 있는 최소 MAPE는 1.14% (그

림 7에서 목표오차가 $\epsilon = 2^{-12}$ 일 때의 실선 참조임을 알 수 있다. 이는 최상의 MAPE를 기준으로 할 때, 예측성능이

$$1.14 - 1.12 = 0.02\%$$

저하되는 것을 의미하며, 조기 학습정지 전략으로 학습시킨 신경회로망은 이상적으로 존재할 수 있는 최적의 신경회로망의 예측성능과 거의 비슷함을 의미한다.

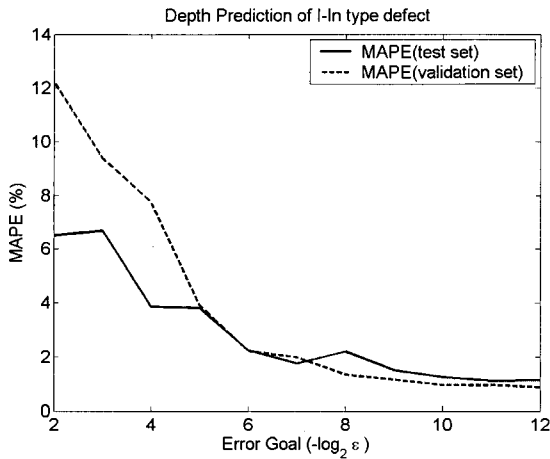


그림 7 목표오차(ϵ)의 변화에 따른 I-In 결함 깊이 예측오차. 실선은 평가데이터에 대한 예측결과이며, 점선은 검증데이터에 대한 예측 결과임

Fig. 7 Depth prediction of I-In defect versus the error goal (ϵ), MAPE for test data (solid line) and MAPE for validation data (dotted line) are shown.

표 2 조기학습정지를 이용한 깊이 예측 결과
Table 2 Depth prediction result using early stopping

결함종류	검증데이터 최적 MAPE	평가데이터 최적 MAPE	평가데이터 MAPE (조기 학습정지 적용)
I-In	0.88 % ($\epsilon = 2^{-12}$)	1.12% ($\epsilon = 2^{-11}$)	1.14% ($\epsilon = 2^{-12}$)
I-Out	1.28 % ($\epsilon = 2^{-9}$)	2.98% ($\epsilon = 2^{-12}$)	3.57% ($\epsilon = 2^{-9}$)
V-In	2.83% ($\epsilon = 2^{-7}$)	1.50% ($\epsilon = 2^{-10}$)	2.22% ($\epsilon = 2^{-7}$)
V-Out	3.22% ($\epsilon = 2^{-12}$)	5.93% ($\epsilon = 2^{-10}$)	7.26% ($\epsilon = 2^{-12}$)

한편, 마찬가지로 방법으로 I-Out, V-In, V-Out 형태 결함의 깊이를 예측하는 데에도 조기학습정지를 적용하여 보았으며 그 결과를 표 2에 정리하였다. 표 2로부터 최상의 MAPE를 기준으로 할 때, I-Out, V-In, V-Out 결함 예측성능이 각각 0.59%, 0.72%, 1.33% 저하되는 것을 알 수 있다. 이는 이상적인 경우의 최적의 MAPE와 조기학습정지에 의한 MAPE의 차이가 매우 작다는 것을 의미하며, 이로부터 조기학습정지 전략이 결함크기 예측에서 매우 효과적으로 사용될 수 있음을 보여준다.

그림 8은 조기학습정지 전략으로 학습시킨 신경회로망을 이용한 V-Out 결함의 깊이 예측결과를 보여준다.

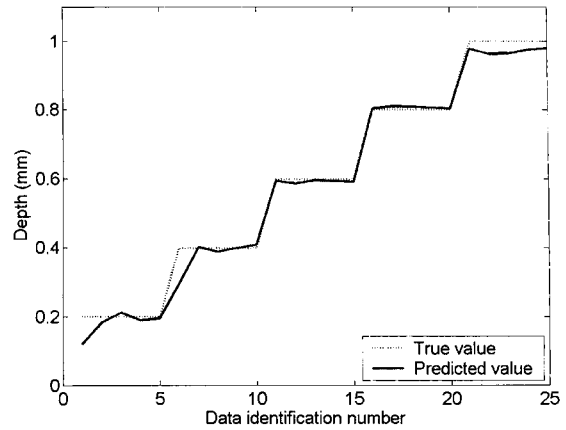


그림 8 조기학습정지를 이용한 V-Out 형태 결함의 깊이 예측결과

Fig. 8 Prediction result for the depth of V-Out defect using early stopping

5. 결 론

본 논문에서는 원자력 결함크기 예측에 사용되는 신경회로망의 효과적인 목표오차 선정 방법에 대한 연구를 수행하였다. 기존의 원자력 세관 결함크기 예측연구에서는 목표오차를 체계적으로 선택하는 방법이 제시되지 않아서 실제적인 응용에는 상당한 한계를 안고 있었다. 본 논문에서는 목표오차를 체계적으로 선택하기 위하여, 조기학습정지(early stopping)을 원자력 세관결함 크기예측에 사용할 것을 제안하였다. 4장의 여러 가지 사례연구 결과로부터 조기학습정지에 의해 학습된 신경회로망을 사용하였을 때의 예측오차와 이론상 최적의 신경회로망을 사용하였을 때의 예측오차 차이가 0.33% 이내로 매우 작다는 것을 알 수 있었다. 이는 원자력 세관 결함크기 예측에 조기학습정지를 이용할 경우 신경회로망 학습이 매우 효과적으로 수행될 수 있음을 실험적으로 입증한 것이다.

감사의 글

본 연구는 숭실대학교 교내연구비 지원으로 이루어졌음

참 고 문 헌

- [1] D.P. Labridis, D.P. "Comparative presentation of criteria for adaptive finite-element mesh generation in multiconductor eddy-current problems," IEEE Trans. Magnetics, Vol. 36, No. 1, pp. 267-280, 2000
- [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] K. Miya, "Recent advancement of electromagnetic nondestructive inspection technology in japan," IEEE Trans. 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 Trans. Magnetics, Vol. 42, No. 4, pp. 1079-1082, 2006
- [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] H. Huang, T. Takagi, H. Fukutomi, "Fast signal predictions of noised signals in eddy current testing," IEEE Trans. Magnetics, Vol. 36, No. 4, pp. 1719-1723, 2000
- [7] 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
- [8] 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
- [9] 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
- [10] 조남훈, 이항범, 한기원, 송성진 "신경회로망을 이용한 원전SG 세관 결함패턴 분류성능 향상기법," 전기학회 논문지, Vol. 56, No. 7, pp. 1224 - 1230, July, 2007
- [11] M.T. Hagan, H.B. Demuth, and M.H. Beale, Neural Network Design, PWS Pub. Co, 1995
- [12] S. Haykin, Neural Networks, New Jersey: Prentice Hall, 1999
- [13] L. Prechelt, "Automatic early stopping using cross validation: quantifying the criteria," Neural Networks, Vol. 11, No.4, pp. 761-767, 1998

저 자 소 개



조 남 훈 (趙南熏)

1992년 서울대 공대 전기공학과 졸업.
 2000년 서울대 대학원 전기공학부 졸업 (공학박). 2000년~2001년 서울대 자동화시스템공동연구소 연구원. 2001년~2002년 삼성전자 DVS사업부 책임연구원. 2002년부터 숭실대학교 전기공학부에 재직중이며 현재 부교수. 2006년~현재 대한전기학회 영문논문지 편집위원, 2004년~현재 제어자동화시스템공학회 국문논문지 편집위원. 관심분야는 비선형제어시스템, 시스템생물학, 인공지능 및 그 응용.

Tel : 02-820-0643

E-mail : nhjo@ssu.ac.kr,

professor.jo@gmail.com

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