

## 회귀 문제에서 예측값들의 분산을 줄이기 위한

### 딥뉴럴 네트워크 구조 연구

김중환<sup>\*\*</sup>, 여도엽<sup>o</sup>

<sup>\*</sup>한양대학교 기계공학과,

<sup>\*\*</sup>한국원자력연구원 스마트기기진단연구부,

<sup>o</sup>한국원자력연구원 스마트기기진단연구부

e-mail: jhkim0630@kaeri.re.kr<sup>\*\*</sup>, yeody@kaeri.re.kr<sup>o</sup>

## A study on the architecture of a deep neural network to reduce the variance of predicted values in a regression problem

Jonghwan Kim<sup>\*\*</sup>, Doyeob Yeo<sup>o</sup>

<sup>\*</sup>Department of Mechanical Engineering, Hanyang University,

<sup>\*\*</sup>Smart Sensing & Diagnosis Research Division, KAERI,

<sup>o</sup>Smart Sensing & Diagnosis Research Division, KAERI

### ● 요약 ●

본 논문에서는 회귀 문제에서 예측값들의 분산을 줄이기 위한 딥뉴럴 네트워크 구조를 제안한다. 일반적인 회귀 문제에서 딥뉴럴 네트워크 학습 시, 하나의 입력에 대한 레이블 값을 이용하여 학습한다. 본 논문에서는 하나의 입력에 대한 레이블 값뿐만 아니라 두 입력에 대한 레이블 값들의 차이를 학습시키는 딥뉴럴 네트워크 구조를 제안한다. 통계학 이론을 통하여 예측값들의 분산이 줄어든다는 것을 증명한다. 또한, 배관 곡관의 감육두께를 예측하는 문제를 통해 제안된 네트워크의 성능을 검증한다. 일반적인 딥뉴럴 네트워크 구조를 이용하였을 때에 비하여 제안한 네트워크 구조를 이용하였을 때, 회귀 문제의 예측값들의 분산이 감소함을 확인한다.

**키워드:** 회귀(regression), 감육(wall thinning), 딥러닝(deep learning)

### I. Introduction

고온 고압의 유동에 의한 배관의 감육은 원자력 발전소에서 발생하는 고장의 일종으로, 1986년과 2004년에도 배관 감육으로 인한 심각한 사고가 보고되었다[1-3]. 이에 따라, 정기 점검 방법과 더불어, 예상치 못한 사고를 예방하기 어려운 정기 점검의 약점을 보완하기 위해 상태기반 유지보수(Condition-Based Maintenance, CBM)가 개발되었다. CBM을 위하여 배관에 센서를 부착하여 배관의 감육 상태를 모니터링 하는 연구들이 제안되어왔다. [4-7] 하지만, 초음파 waveguide 방식[4]을 이용한 방법은 waveguide 설치가 어려운 지역에서 사용하기 어렵고, DCPD (Direct-Current Potential Drop) 방식은 높은 전류로 인해 안전상의 문제가 발생할 수 있다[5]. 따라서, 최근에는 설치가 비교적 쉬운 가속도계를 이용하여 감육 상태를 모니터링하는 방법이 제안되고 있다. [6-7] 저자들은 주파수 도메인을 이용하여 데이터 변환을 한 후 합성곱 신경망(Convolutional Neural Network, CNN)을 이용하여 감육 상태를 예측하는 회귀모델을 제안하였다. 학습에 사용한 감육 정도의 경우 예측 성능이 뛰어나지만,

학습에 사용하지 않은 감육 정도의 경우 상대적으로 예측 성능이 저하됨을 볼 수 있다. 특히, 예측값의 분산이 크게 나오는 것을 관찰할 수 있다.

예측값에 대한 분산이 클 경우, 예측에 대한 신뢰도를 떨어트리는 주요 요인이 되므로 분산을 작게 만드는 것이 매우 중요하다. 따라서, 본 논문에서는 회귀 문제에 대한 예측값의 분산을 줄이는 방법을 제안하고자 한다. 먼저, 통계적 기법을 통하여 예측값에 대한 분산을 줄이는 방법을 고안하고, 실제로 예측값에 대한 분산을 줄이는 딥뉴럴 네트워크(Deep Neural Network, DNN)를 제안하고자 한다.

## II. Preliminaries

### 1. Related works

#### 1.1 가속도계를 이용한 감속 상태 모니터링

가속도계를 이용하여 감속 상태를 모니터링 하는 관련 연구로서 [6]과 [7] 연구가 있다. [6] 연구는 가속도계 센서 신호의 PSD (Power Spectral Density)를 구한 다음, DNN을 통해 감속 정도를 예측하는 회귀 모델을 제안하였다. [6] 연구에서는 DNN의 구조로 CNN을 이용하였다. [7] 연구는 4초간 가속도계 센서 신호를 평균내어 Mel-spectrogram을 구하여 CNN을 통해 감속 정도를 예측하는 회귀 모델을 제안하였다. [6]의 경우, 데이터 분석을 통해 특정한 주파수 영역대의 PSD 데이터를 입력 데이터로 사용하여야 한다. 하지만, [7]의 경우 별도의 데이터 분석없이 전 주파수 영역대의 데이터를 이용한다는 장점이 있다. 따라서, 본 연구는 [7]에서 제안한 전처리 기법과 동일하게 데이터 전처리를 수행하였다.

[7]에서 구현한 회귀 문제를 풀기 위한 답뉴럴 네트워크의 구조를 간단하게 표현하면 Fig. 1.과 같다. 단일 입력에 대해 하나의 감속 정도를 예측하는 네트워크 구조이다. [7]에서 구현한 코드를 재현한 결과, Fig. 2와 같은 결과를 보인다. (자세한 실험 환경에 대한 설명은 IV장에 있다.) 학습에 사용한 감속 정도의 경우에는 정확한 값을 잘 예측하고 있는 것을 볼 수 있는 반면, 학습에 사용하지 않은 감속 정도의 경우에는 정확한 값을 잘 예측하지 못하고, 예측값들에 대한 분산도 큰 것을 볼 수 있다.




Fig. 1. Deep Neural Network Architecture for the Regression Problem in [7]




Fig. 2. Regression Results of [7] for the Test Dataset

## III. The Proposed Scheme

본 장에서는 회귀 문제에 대한 예측값의 분산을 줄이는 방법을 제안하고자 한다. 먼저, 통계적 접근법을 기반으로 예측값의 분산을 줄이기 위한 방법을 제안한다. 다음, 실제로 회귀 문제를 위한 답뉴럴 네트워크 구조를 설계하고자 한다.

### 1. 통계적 접근

기존의 회귀 문제 해결을 위한 답뉴럴 네트워크의 구조를 단순히 선형(linear)이라 가정한다면 다음과 같이 모델링할 수 있다.

$$Y = Ax + B + \epsilon, \epsilon \sim N(0, \sigma^2) \quad (1)$$

하나의 입력 데이터에 대해 n개의 결과를 예측할 수 있는 회귀 모델의 경우 다음과 같이 표현할 수 있다. 계산의 편의를 위해 여러항들은 독립항등분포(independent and identically distribution, iid)를 가진다고 가정하자.

$$Y = A_1x + B_1 + \epsilon_1, \epsilon_1 \sim N(0, \sigma^2)$$

$$Y = A_2x + B_2 + \epsilon_2, \epsilon_2 \sim N(0, \sigma^2)$$

...

$$Y = A_nx + B_n + \epsilon_n, \epsilon_n \sim N(0, \sigma^2)$$

이 때 각각의 회귀 예측값을 평균내어 새로운 예측값으로 사용하면 여러항의 분포는 다음과 같이진다.

$$\epsilon = \frac{\epsilon_1 + \epsilon_2 + \dots + \epsilon_n}{n} = Y - \frac{A_1x + B_1 + \dots + A_nx + B_n}{n}, \quad \epsilon \sim N(0, \sigma^2/n) \quad (2)$$

따라서, 수식 (2)에서는 수식 (1)에서의 기존의 회귀 모델의 예측값들의 분산에 비하여 1/n의 분산을 얻을 수 있음을 알 수 있다.

이를 위해, n개의 모델을 학습시킨 다음 앙상블(ensemble)하는 방법도 있지만, 여기서는 하나의 네트워크를 통해 여러 예측값을 얻을 수 있는 회귀 네트워크를 제안한다.

### 2. 네트워크 구조 설계

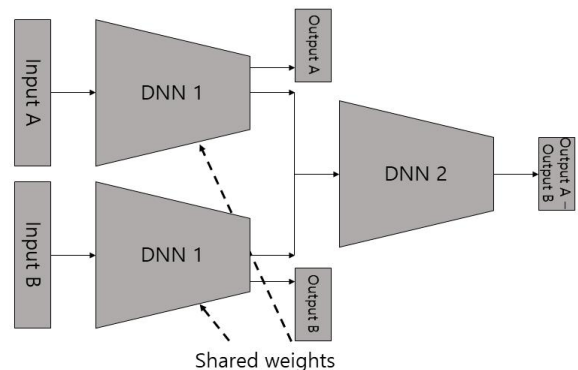


Fig. 3. Proposed Deep Neural Network Architecture for the Regression Problem

단일 네트워크를 이용하여 예측값의 분산을 줄이기 위한 회귀 네트워크의 구조를 Fig. 3.과 같이 구성하였다. Fig. 3.에 나타나있는

각각의 네트워크의 역할은 다음과 같다.

1. 웨이트를 공유하는 DNN 1은 한 입력데이터에 대한 라벨값을 예측하는 역할 뿐만 아니라 입력데이터의 특징을 추출하는 역할을 한다.
2. DNN 2은 추출된 특징으로부터 두 입력데이터 (Input A, Input B)의 라벨값의 차이 (Output A - Output B)를 학습하는 역할을 한다.

Fig. 3.에서 입력데이터로 Input A와 Input B, 두 개의 데이터가 동시에 주어진다. 학습 시에는 Input A의 라벨, Input B의 라벨, 그리고 (Input A의 라벨 - Input B의 라벨) 세 가지 라벨 값을 통해 학습이 된다.

회귀값 예측시, Input A에는 값을 예측하고자 하는 데이터를 입력하고, Input B에는 학습에 사용했던 데이터를 입력한다. 그러면 출력되는 차이값을 통해 Input A의 결과값을 예측할 수 있다. 반대로, Input A에는 학습에 사용했던 데이터를, Input B에 값을 예측하고자 하는 데이터를 입력해도 Input B의 결과값을 예측할 수 있다. 따라서, 하나의 예측하고자 하는 데이터에 대하여 (학습 데이터의 개수 x 2)개 만큼 예측 결과를 얻어낼 수 있다.

#### IV. The Experimental Results

본 장에서는 III장에서 제안한 회귀 문제를 위한 딥러닝 네트워크의 성능을 배관 감육 예측 문제를 이용하여 검증하고자 한다. 배관 감육 예측 문제를 위한 실험 환경에 대해 서술하고, 해당 실험 환경에서 제안한 회귀 네트워크의 성능을 검증하고자 한다.

##### 1. 배관 감육 실험 환경

Fig. 4.와 같이 배관 시스템 상의 한 엘보 부분에 감육 엘보 시편을 제작하여 결합하는 방식으로 배관 감육 현상을 모사하는 테스트베드를 구성하였다. 감육 엘보 시편은 총 6개로 Table 1.과 같이 구성되어 있다.

진동 신호 측정을 위한 시스템 구성 및 가속도계 센서설치 위치는 Fig. 5.와 같다. 감육 엘보 시편에 따라 가속도계 센서의 신호를 수집하였고, 이 데이터를 통하여 배관 감육 정도 예측을 위한 모델을 학습하였다.

본 논문에서는 Table 1.에 나타나있는 6개의 감육 엘보 시편 중 5개의 감육 엘보 시편을 이용하여 수집된 가속도계 센서 신호를 이용하여 나머지 하나의 감육 엘보 시편의 최소 두께를 예측하는 모델을 만들었다.




Fig. 4. (a) Cross section of a elbow specimen and (b) Pipeline systems with an elbow specimen attached [7]

Table 1. The thickness of six elbow specimens [7]

최대 감육 정도 (%)	감육 엘보 시편의 최소 두께 (mm)
0	7.48
20.3	5.96
30.2	5.22
41.4	4.38
53.0	3.59
77.9	2.40




Fig. 5. Location of the accelerometers on the elbow specimen [7]

##### 2. 배관 감육 실험 결과

Fig. 2.와 Fig. 6.은 Table 1.에서 감육 엘보 시편의 최소 두께가 5.22mm인 시편에 대한 데이터는 제외하고 학습을 시켰을 때의 예측 결과이다. 그림 4는 기존의 회귀 네트워크를 이용한 결과이고, 그림 6은 제안한 회귀 네트워크를 이용한 결과이다. 제안한 회귀 네트워크를 통해 예측값들의 분산은 상당히 감소시킬 수 있음을 볼 수 있다.




Fig. 6. Regression Results of the Proposed Regression Methods for the Test Dataset

## V. Conclusions

본 논문에서는 회귀 문제에서 예측값들의 분산을 줄이기 위한 딥뉴럴 네트워크 구조를 제안하였다. 일반적인 회귀 문제에서 사용되는 딥뉴럴 네트워크의 구조와 달리, 하나의 입력에 대한 레이블 값뿐만 아니라 두 입력에 대한 레이블 값들의 차이를 학습시키는 딥뉴럴 네트워크 구조를 제안하였다. 통계학 이론을 통하여 하나의 입력에 대해 여러 예측값을 예측해내고, 이 값들을 평균내어 새로운 예측값으로 사용한다면, 예측값들의 분산이 줄어든다는 것을 증명하였다. 또한, 앞서 제안한 네트워크 구조는 단일 네트워크로 예측값들의 분산이 줄어드는 것을 가능하게 하였다. 마지막으로, 배관 곡관의 감속두께를 예측하는 문제를 통해 제안된 네트워크의 성능을 검증하였다. 일반적인 딥뉴럴 네트워크 구조를 이용하였을 때에 비하여 제안한 네트워크 구조를 이용하였을 때, 회귀 문제의 예측값들의 분산이 감소함을 실험적으로 확인할 수 있었다.

## ACKNOWLEDGEMENT

이 논문은 과학기술정보통신부의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2020M2C9A1062710)

## REFERENCES

[1] F. N. Remy, and M. Bouchacourt, "Flow-assisted corrosion: A method to avoid damage," Nucl. Eng. Des. Vol. 133, pp. 23-30, 1992.

[2] P. C. Wu, "Erosion/Corrosion-Induced Pipe Wall Thinning in US Nuclear Power Plants," No. NUREG-1344, US Nuclear Regulatory Commission (NRC):Washington, DC, USA, 1989.

[3] M. Matsumura, "A case study of a pipe line burst in the Mihama Nuclear Power Plant," Mater. Corros. 57, pp. 872-882, 2006.

[4] K. H. Ryu, T. H. Lee, J. H. Kim, I. S. Hwang, N. Y. Lee, J. H. Kim, J. H. Park, and C. H. Sohn, "Online monitoring method using Equipotential Switching Direct Current potential drop for piping wall loss by flow accelerated corrosion," Nucl. Eng. Des. Vol. 240, pp. 468-472, 2010.

[5] S. B. Oh, Y. M. Cheong, D. J. Kim, and K. M. Kim, "On-Line Monitoring of pipe wall thinning by a high temperature ultrasonic waveguide system at the flow accelerated corrosion proof facility," Sensors, Vol. 19, No. 1762, 2019.

[6] J. Kim, B. Jung, J. Park, and Y. Choi, "Estimation of Pipe Wall Thinning Using a Convolutional Neural Network for Regression", Nuclear Technology, Vol. 208, No. 7, pp. 1184-1191, 2022.

[7] J. Kim, B. Chung, J. Park, and Y. Choi, "Estimation of Elbow Wall Thinning Using Ensemble-Averaged Mel-Spectrogram with ResNet-like Architecture", Sensors, Vol. 22, No. 3976, 2022.