

초고층 건축물의 부등축소량 예측을 위한 뉴럴-네트워크의 적용

Application of Neural Network to Prediction of Column Shortening of High-rise Buildings

양 원 직* 이 정 한* 김 옥 종** 이 도 범*** 이 원 호****
Yang, Won-Jik Lee, Jung-Han Kim, Ook-Jong Lee, Do-Bum Yi, Waon-Ho

ABSTRACT

The objectives of this study are to develop and evaluate the Neural Network algorithm which can predict the inelastic shortening such as the creep strain and the drying shrinkage strain of reinforced concrete members using the previous test data. New learning algorithms for the prediction of creep strain and the drying shrinkage strain are proposed focusing on input layer components and a normalization method for input data and their validity is examined through several test data. In Neural Network algorithm, the main input data to be trained are the compressive strength of the concrete, volume to surface ratio, curing condition, relative humidity, and the applied load. The results show that the new algorithms proposed herein successfully predict creep strain and the drying shrinkage strain.

1. 서론

건조수축 및 크리프에 의한 비탄성축소량의 예측을 위해 제안된 모델은 ACI, CEB-FIP, BP모델¹⁾⁻³⁾ 등이 있다. 그러나 이와 같은 수식모델은 복잡하고 다양한 변수에 의해 정확한 예측값을 기대하기 어렵고⁴⁾ 실험에 의한 많은 양의 데이터와 시간을 필요로 한다. 따라서 기존연구⁵⁾에서는 건조수축 및 크리프의 축소량을 예측하기 위하여 10×10×40cm의 각형 공시체와 15×10cm 원형 공시체를 이용 ASTM C 596, 512에서 제시한 콘크리트 건조수축 및 크리프 축소량의 계측방법에 따라 실시한 실험 데이터를 이용하여 예측의 가능성을 뉴럴-네트워크로 검토하였다.

본 연구에서는 실구조물로의 적용가능성을 검증하기 위하여 실구조물의 계측 데이터를 이용, 본 연구에서 제안한 기둥부재의 축소량 예측 알고리즘의 적용 가능성 및 실용성을 검토하고자 한다.

2. 뉴럴-네트워크의 구조

2.1 계층형 뉴럴-네트워크

본 연구에서는 그림 1과 같은 계층형 뉴럴-네트워크를 사용하며⁶⁾, 네트워크 학습방법으로 일괄학습 알고리즘(Whole Learning 법)⁷⁾을 사용하였다. 입력층과 중간층의 전달함수로는 그림 2와 같은 시그모이드 함수를, 출력층의 전달함수로는 그림 3과 같은 선형함수를 각각 적용하였다.

* 정회원, 광운대학교 에센스 구조연구센터 연구교수, 공학박사

** 정회원, 대림산업 기술산업연구소 책임연구원, 공학박사

*** 정회원, 대림산업 기술산업연구소 부장, 공학석사

**** 정회원, 광운대학교 건축학부 교수, 공학박사

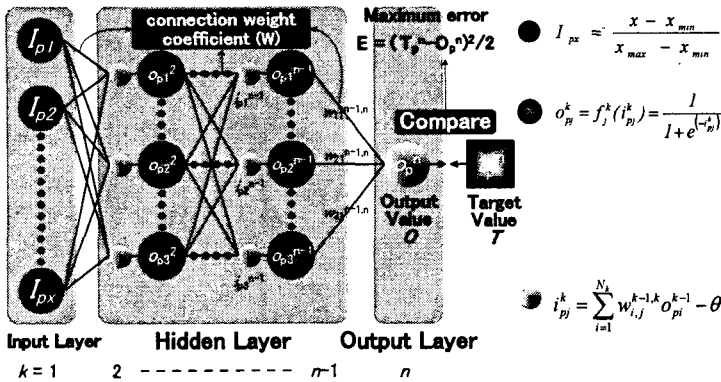


그림 1. 계층형 뉴랄-네트워크의 개념도




그림 2. 시그모이드 함수




그림 3. 선형함수

2.2 일괄 학습 알고리즘

학습 데이터 총수를 N으로 가정, 네트워크 출력을 $O^{(n)}$, 정해를 $T^{(n)}$ 로 한 경우, 식 (1)의 오차함수 $f^{(n)}$ 에 의해 구성된 다목적 함수 $\{f\}$ 은 결합계수 W에 의해 최소화 하는 최적화 문제이므로, $O^{(n)}$ 을 ΔW_j 에 대해서 테라 급수 전개하면 $f^{(n)}$ 은 식(2)와 같이 나타낼 수 있고 이를 전학습 데이터에 대해 표시하면 식 (3)이 된다. 학습효율이 높은 네트워크가 구축 될수록 식 (3)의 $\{f\}$ 는 0에 근사하기 때문에, $\{\Delta W\}$ 에 대해서 정리하면 식 (4)와 같이 나타낼 수 있다. $\{f\}$ 가 설정오차 범위 내에 들면, 결합계수 $\{W\}$ 가 구해진다. 이와 같이 일괄 학습 알고리즘은 전 학습데이터에 대해서 $\{\Delta W\}$ 를 계산하는 수치 연산법으로 정식화 할 수 있다.

$$f^{(n)} = T^{(n)} - O^{(n)} \quad (n=1, \dots, N) \dots\dots\dots (1)$$

$$f^{(n)} = T^{(n)} - \left(O^{(n)} + \sum_{j=1}^J \frac{\partial O^{(n)}}{\partial W_j} \Delta W_j \right) \dots\dots\dots (2)$$

$$\{f\} = \{b\} - [B]\{\Delta W\} \dots\dots\dots (3)$$

$$\text{단 } \{b\} = \{T^{(n)} - O^{(n)}\}, \quad [B] = \left[\sum_{j=1}^J \frac{\partial O^{(n)}}{\partial W_j} \right]$$

$$\{\Delta W\} = [B]^{-1} \{b\} \dots\dots\dots (4)$$

단, $[B]^{-1}$: 일반 역행렬

2.3 네트워크의 구조

건조수축 및 크리프 수축량을 예측하기 위한 계층형 뉴랄-네트워크의 입력층 성분은 표 1과 같다. 초기 결합계수(W)는 랜덤으로 결합계수를 발생시켜 100회의 학습을 시도하였고 수렴하지 않는 경우 100회씩 20회의 재학습을 하도록 하였다. 또한 입력층 성분에 대한 기준화 수법은 문헌⁸⁾의 결과를 참조하여 각각의 입력층 성분에 대한 절대값의 최대치를 사용 정방향과 부방향을 대칭시켜 사용하는 기준화 방법으로 설정하였다.

표 1. 뉴랄-네트워크의 입력층 성분

| | | |
|--------------------|-----|---|
| 크리프 축소 예측을 위한 네트워크 | 입력층 | ① 28일 압축강도, ② 체적/표면적 비, ③ 양생온도, ④ 상대습도, ⑤ 재하하중, ⑥ 콘크리트 재령 |
| | 중간층 | 1층, 6노드 출발 |
| | 출력층 | 기둥의 부등 축소량 |


3. 고층건축물의 기둥 축소량 예측을 위한 알고리즘 구축

본장에서는 문헌⁹⁾의 연구결과를 통하여 축소량의 예측이 가능하다는 것을 알았고, 이에 현장적용을 위

한 실용성 있는 알고리즘을 제안하였다. 또한 실용성의 여부를 검증하기 위하여 건설 중에 있는 66층 초고층건물의 현장에서 계측한 데이터를 이용하여 제안 알고리즘의 학습 및 예측가능성을 비교·분석하였다.

3.1 예측 알고리즘

본 연구에서는 그림 4와 같은 뉴랄-네트워크를 이용한 축소량을 예측하는 알고리즘을 제안하였다. 그림 4와 같이 축소량은 최하층에서 최대이지만 보정량은 중간층에서 최대가 된다. 또한 각 층마다의 보정량은 미비하여 5층 또는 10층의 간격으로 보정층을 설정하여 보정하는 것이 일반적이다. 따라서 본 연구에서는 축소량이 가장 큰 최하층에 게이지를 설치하여 보정층에 달할 때까지의 계측 데이터를 이용하여 뉴랄-네트워크를 구축하고, 구축된 네트워크로부터 보정층의 보정량(축소량)을 예측하는 알고리즘이다. 다음의 절에서는 본 제안 알고리즘의 실용성을 검토하기 위하여 시공 중인 건물의 13층과 33층에서 계측한 축소량의 데이터를 이용하여 제안 알고리즘의 검증을 실시하였다.



* NN : 뉴랄-네트워크
그림 4. 보정 알고리즘의 개념도

3.2 뉴랄-네트워크를 이용한 축소량의 예측

3.2.1 학습 및 예측 대상

66층 초고층건물의 13층과 33층에서 계측한 데이터를 이용하여 학습 및 예측을 실시하였다. 학습 및 예측은 제안 알고리즘에 따라 13층(그림 4의 최하층에 상당)의 데이터를 학습 데이터로 이용하고, 33층(그림 4의 보정층에 상당)을 예측대상으로 하였다. 따라서 본 알고리즘에서는 13층의 시공완료 후 일정시간 간격을 가지고 계측한 32층까지의 고정하중에 의한 13층 기둥의 축소량 데이터를 이용하여 33층의 축소량을 예측한 결과이다. 대상부재는 그림 5의 평면도에 나타난 C1기둥으로 하였다.




그림 5. 대상건물의 평면도

3.2.2 학습 및 예측 결과

학습 및 예측의 결과를 각각 그림 6, 7에 나타내었다. 그림 6의 학습결과로부터 허용오차 $10^{-3.5}$ 와 $10^{-4.0}$ 에서는 불연속적인 13층 C1기둥의 축소량 데이터를 정도 높게 재현하고 있는 것을 알 수 있다. 그러나 $10^{-3.0}$ 에서는 50-100일 사이에 약간 학습데이터와 이격이 있는 것을 알 수 있다. 이것은 데이터 하나하나의 재현보다 패턴 인식에 중점을 둔 학습결과에 의한 것으로 사료된다. 또한 예측결과를 나타낸 그림 7에서는 최대허용오차가 큰 순으로 예측정도가 좋은 것을 알 수 있다. 이것은 문헌⁹⁾에서도 언급한바 있지만 $10^{-3.5}$, $10^{-4.0}$ 에서는 학습데이터에 대한 과학습⁶⁾이 발생하여 학습 데이터의 패턴보다 데이터 하나하나의 재현에 치중한 학습이 되어진 것이 원인으로 사료된다. 따라서 이와 같은 불연속적이고 불규칙성이 큰 데이터에 대해서는 적절한 최대허용오차의 설정이 매우 중요한 것으로 판단된다. 또한 이상의 검증으로부터 본 제안 알고리즘은 적절한 최대허용오차를 설정함으로써 실용화가 가능할 것으로 판단된다.

4. 결론 및 향후계획

초고층건물의 수직부재의 축소량의 예측을 위한 뉴랄-네트워크의 적용 가능성 및 실용화를 위하여 학습 및 예측 알고리즘을 제안하였다. 또한 제안 알고리즘에 대한 예측의 정밀도를 분석하기 위하여 실구조물에

서 얻은 데이터를 이용 축소량에 대한 학습 및 예측을 실시하였다. 그 결과를 다음과 같이 정리하였다.

- 1) 뉴럴-네트워크를 이용한 초고층 건축물의 수직부재 축소량 예측이 가능하다는 것을 알았다.
- 2) 뉴럴-네트워크의 정밀도 높은 허용오차의 설정이 예측의 정밀도와 항상 비례하지 않는다는 것을 알았다.

이러한 결과에 기초하여 향후 본 연구의 기법을 실용화하기 위해서는 학습정밀도와 예측정밀도의 관계를 명백히 하고 예측정밀도의 향상을 위해서는 적절한 최대허용오차 설정방법에 대한 검토가 필요할 것으로 사료된다.

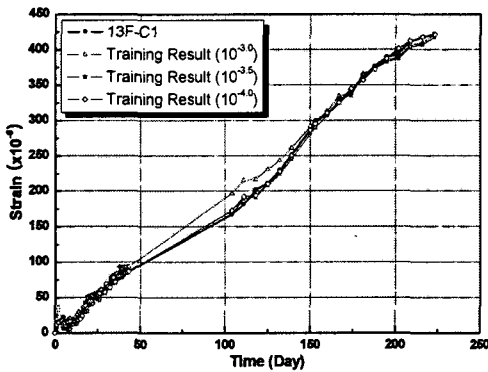


그림 6. 학습결과

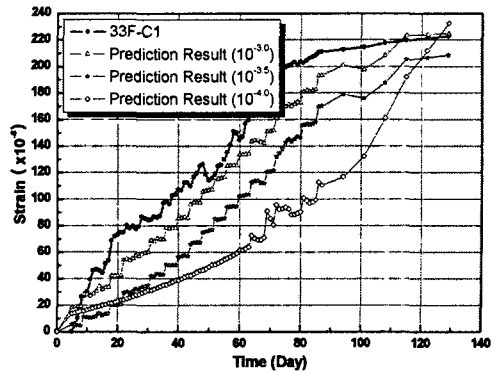


그림 7. 예측결과

참고문헌

1. ACI Committee, "Prediction of Creep, Shrinkage, and Temperature Effects in Concrete Structures, Manual of Concrete Practice", American Concrete Institute, Detroit, MI., 1999.
2. Comite Euro"International du Beton "CEB-FIP Model Code, Design Code", Thomas Telford, 1990.
3. Bazant, Z. P., Kim, Joong"Koo and Panula, L., "Improved Prediction Model for Time Dependent Deformations of Concrete", "Part 1"Shrinkage", Ibid 24, 1991 ; "Part 2"Basic Creep", Ibid. 24, 1991 ; "Part 3"Creep at drying", Ibid. 25, 1992 "Part 4"Temperature effects", Ibid. 25, 1992 ; "Part 5"Cyclic load and cyclic humidity", Ibid. 25, 1992.
4. J. H. Lee, H. S. Park, W. H. Yi, "An Experimental Study on Prediction of the SRC Column Shortening", Proceedings of AIK, Vol.22, No.1, pp.131-134, 2002. 4.
5. 楊元植, 李元虎, 康大彦, 李政翰: 뉴럴네트워크를 이용한 고층RC建物の乾燥收縮およびクリープ量を推定するための基礎的研究, 日本建築學會大會學術講演梗概集, pp.301-302, 2005.9.
6. Hiroshi Ichikawa, "Application of Multilayer Feed-forward Neural Network to Non-linear Analysis," kyoritsu Pub. Co., Ltd. 29-30, 1993.
7. Kayo Satoh, Nobuhiro Yoshikawa, Yoshiaki Nakano and Wonjik Yang, "Whole learning algorithm of the neural network for modeling nonlinear and dynamic behavior of RC members", Structural Engineering and Mechanics, An International Journal, Vol. 12, No.5 pp. 527-540, 2001.
8. 楊元植, 中埜良昭, 眞田靖士: 뉴럴네트워크による非線形履歴の推定手法を応用したサブストラクチャ・オンライン實驗手法の提案, 日本建築學會構造系論文集, 第582号, pp.73-80, 2004.8
9. 양원직, 이원호, 강대연, 이정환, "뉴럴-네트워크 기법을 이용한 초고층 건물의 기둥부재의 부등축소량 예측 정밀도 향상을 위한 연구," 대한건축학회 60주년 기념 추계학술발표대회논문집, 제25권, 제1호, 2005, 10, pp.353-356.