# 論文 高層 RC 建物の乾燥収縮およびクリープ量の推定へのニューラルネットワ ークの適用

楊 元稙\*<sup>1</sup>·李 元虎\*<sup>2</sup>

要旨: 高層 RC 建物の鉛直部材の縮小は建物の挙動および使用性に大きな影響を与える要素 の一つである。しかし, RC 建物の縮小量を推定するための既存の ACI, CEB-FIP, BP モデ ルなどがあるが、まだこのような数式モデルは正確な推定が期待できない状況である。そこ で、本研究では数式化し難い非線形データのモデル化に有効であるニューラルネットワーク を用い RC 建物の縮小量を推定するためのアルゴリズムを構築しその実用化を検討した。 キーワード:乾燥収縮、クリープ、ニューラルネットワーク、一括学習アルゴリズム

#### 1. はじめに

高層 RC 建物の鉛直部材の縮小は載荷する際, 応力の大きさに比例して発生する弾性縮小と時 間とともに発生する乾燥収縮およびクリープに よる非弾性縮小に分類できる。一般的にコンク リート柱には弾性縮小と乾燥収縮およびクリー プによる影響を受ける。特に、乾燥収縮および クリープによる非弾性縮小量の推定のために提 案されたモデルは ACI, CEB-FIP, BP モデル 1)~3)などがある。しかし、このような数式モデル は複雑で多様な変数により正確な推定が期待で きない<sup>4)</sup>。従って、文献<sup>5)</sup>では乾燥収縮およびク リープの縮小量を推定するため, ASTM C 596, 512 で提示したコンクリート乾燥収縮およびク リープ縮小量の計測方法に従って行った供試体 の実験データを用い、それらの推定の可能性を ニューラルネットワークで検討した。

続いて、本研究では実物の 1/3 スケールで製 作した SRC 柱の試験体を用い現場の施工スケジ ュールと同一の載荷により計測した縮小量のデ ータと施工スケジュールを 1/2 に短縮し載荷し た縮小量のデータ2種類を用いニューラルネッ トワークによる未知の所の収縮量の推定可能性 を検討した。また、その知見により実際の超高 層建物の柱の収縮量データを用い実用化の可能 性も検討した。

#### 2. ニューラルネットワークの構造

## 2.1 階層型ニューラルネットワーク

本研究では、図-1に示す階層型のニューラル ネットワーク <sup>6</sup>を用い、学習方法には一括学習 アルゴリズム法 (Whole Learning 法)<sup>7)</sup>を,結合 係数の初期値は-0.5~0.5 の範囲の乱数によって 作成した。なお、入力層と中間層の伝達関数に は図-2に示すシグモイド関数を,出力層には多 少学習範囲を超える推定ができるようにするた め,図-3に示す線形関数をそれぞれ適用した。

#### 2.2 一括学習アルゴリズム法

一括学習アルゴリズム法による学習は教師デ ータ(T<sup>(n)</sup>)と出力値(O<sup>(n)</sup>)の誤差(f<sup>(n)</sup>)を結合係 数(W)に関して最小化する最適化問題である。そ こで $(\mathbf{O}^{(n)})$ を $(\Delta W_i)$ についてテーラー級数展開 し,(f<sup>(n)</sup>)を一次近似すると式(1)が得られる。

$$\mathbf{f}^{(n)} = \mathbf{T}^{(n)} - \left(\mathbf{O}^{(n)} + \sum_{j=1}^{J} \frac{\partial \mathbf{O}^{(n)}}{\partial \mathbf{W}_{j}} \Delta \mathbf{W}_{j}\right)$$
(1)

式(1)を全学習データについて示すと式(2)となる。  ${\mathbf{f}} = {\mathbf{b}} - [\mathbf{A}] {\Delta \mathbf{W}}$ 

$$[A]{\Delta W}$$
 (2)

$$\mathbb{I} \subset \mathbb{I} \setminus \{b\} = \{T^{(n)} - O^{(n)}\}, \ [A] = \sum_{j=1}^{J} \frac{\partial O^{(n)}}{\partial W_j}$$

式(2)の{f}は 0 に近似できるので、{**Δ**W}に対し て定義すると式(3)が得られる。

$$\{\Delta W\} = [A]^{-}\{b\}$$
 (3)  
ここに $[A]^{-}$ : ムーアペンローズ一般逆行列<sup>8</sup>

* 1	光云大学	ESnS柞	構造研究センタ	研究助教授	博(工)	(正会員)	
* 2	光云大学	教授	工博			(正会員)	



上記のように WL 法は全学習データセットに対して(ΔW)を求める数値演算である。

## 2.3 ネットワークの構築

本研究におけるネットワークの構造を表-1 に示す。入力層は表-1の6個の成分に設定し、 中間層は1層とし文献<sup>7)</sup>の様に入力層のノード 数と同一の6個から開始し、100回学習の20セ ット(総:2000回)で収束しない場合は、ノード 数を1個ずつ増加するアルゴリズム<sup>9)</sup>を用いた。 また、入力層データの基準化方法は文献<sup>9)</sup>で提 案された基準化方法Iを用いた。出力値は柱の 縮小量である。

表-1	ニューラルネットワークの構造

基準化	[-0.5~0.5]			
入力層	1.28 日圧縮強度 2. 体積/表面積比 3. 養生温度,	4. 相対湿度 5. 載荷荷重, 6. コンクリート材齢日		
中間層	1層,6個から開始			
出力層	柱の縮小量			

#### 3. SRC 柱試験体の縮小量推定

鉛直部材の縮小量の計算で弾性縮小量は力学 的な面では簡単に計算できる。しかし,乾燥収 縮およびクリープのような非弾性縮小量は材料 的な面で計算する必要がある。特に,高層建物 で使用するコンクリートは高強度化されるため, これに対する別の評価方法もいる。従って,以 上のようなことを解決するためには現場で実測 した縮小量のデータをそのままモデル化し縮小 量の推定ができれば最適であると考えられる。

そこで、本章ではその可能性を検討のため、

実際の施工中の高層建物の柱を 1/3 スケールで 製作し,現場と同じ施工スケジュールで固定荷 重と積載荷重を相似効果を考慮し,実際の軸力 の 1/9 に載荷した実験を行い,そのデータを用 いてニューラルネットワークによる学習(モデ ル化)および推定可能性を検討した。

#### 3.1 試験体設計

高層建物の鉛直部材になる材料は基本的に鉄 骨,鉄筋コンクリート,鉄骨・鉄筋コンクリート などがある。この中鉄骨柱は長期変形(乾燥収縮 およびクリープ)の影響を受けないため載荷によ る弾性縮小だけ生じる。従って,縮小量の推定お よび補正に困難な問題が鉄筋コンクリートより 少ない。しかし、コンクリート柱、鉄骨・鉄筋コ ンクリート柱などは弾性縮小以外に乾燥収縮お よびクリープなどの非弾性長期変形の影響を受 けるためその推定が困難になる。そこで、本研究 では乾燥収縮およびクリープによる鉛直部材の 縮小量の推定可能性を検討するため載荷荷重を パラメータとした柱2本を製作した。その試験体 の調合および諸元を表-2,3 に示した。計測に 対しては埋立形型ゲージ(PML-60-2L)を柱の真 中に埋め込み実験を行った。また,材齢日に対す る載荷荷重は図-4に、載荷荷重に対する試験体 の縮小量は図-5に示した。

表-2 コンクリートの調合

		_		. · · · #		
配合強度	W/C	S/a	単位材料量(kg/m³)			
(MPa)	(%)	(%)	セメント	水	砂	砕石
24.5	37.0	44.0	402	166	755	960

	試験体名	EC5-240-T/EC5-240-TT		
コンク	ァリート強度(MPa)	24.5		
Ţ	最終荷重(kN)	338		
柱	断面性能	H-150×150×7×10 RC-300×300×1070 16-HD10, HD6@150		
断面	断面積(cm <sup>2</sup> )	H 形鋼:40.14, 鉄筋:11.408		
	引張強度	H 形鋼:SS400		

表-3 試験体諸元



#### 3.2 学習および推定パラメータ

本節ではニューラルネットワークによる鉛直 部材の縮小量の推定可能性を検討するため学習 および推定対象データの設定や学習最大許容誤 差について検討した。

まず,学習データとしては施工スケジュール に合わして載荷した EC5-240-T 試験体の縮小 量データを用い,推定データとしては施工スケ ジュールの 1/2 に短縮し載荷した EC5-240-TT 試験体を対象とした。

次は最大許容誤差設定による学習および推定 精度を検討するため全範囲に対して学習および 推定を行った。その結果 10<sup>-2.6</sup>以上では学習時間 は短いが学習および推定誤差が大きく, 10<sup>4.0</sup>以 下では学習時間が長く過学習<sup>10)</sup>に成ったため, 本稿では最大許容誤差範囲を 10<sup>-2.6</sup>~10<sup>4.0</sup>まで に示した。以上の範囲に対する学習結果を図-6 に示した。図-6を見ると最大許容誤差 10<sup>-2.6</sup>に よる学習結果だけ誤差が大きく,10<sup>-2.7~-3.8</sup>,10<sup>-3.9</sup>,10<sup>-4.0</sup> では学習データである EC5-240-T 試験 体の縮小量データとほぼ一致する結果が得られ た。また,10<sup>-2.7~-3.8</sup> までの学習精度が同一にな った理由に対しては次の3.3 節で述べる。

以上の学習結果により本研究で設定した入力 層成分および学習アルゴリズムにより鉛直部材 の縮小量のモデリングが可能であることが分か った。本節で構築したネットワークを用いた推 定結果については次の節で比較・検討した。



#### 3.3 推定結果

本節では、学習精度に対する推定精度との関 係を検討するため、3.2節で構築したネットワー クを用い推定を行った。また、その結果を比較・ 検討した。推定データの目標値としては EC5-240-TT データを時間補正して用いた。それ ぞれの推定状況を図-7~図-10に示した。図-7では初期部分で誤差が大きいが、図-8~図-10 の結果では学習範囲 83 日までは推定データ である EC5-240-TT 試験体の縮小量とほぼ-致しているが、83日以後では推定精度が低いこ とが分かる。これはニューラルネットワークの 特性である外挿の部分に対しては推定不可能の はずであるが、本研究では学習範囲を若干外れ る部分に対しても推定を必要としているので出 力層の関数をシグモイドではなく、図-3の線形 関数を設定し学習範囲を超える推定ができるよ うにしたためである。

図-8の最大許容誤差が10<sup>-2.7</sup>~10<sup>-3.8</sup>まで同一 の結果を示した理由は次のように説明できる。 階層型ニューラルネットワークの学習は全ての データが設定した最大許容誤差[E=1/2 (教師値 -出力値)<sup>2</sup>]を満足する所で学習を終了する。今 回の学習では最大許容誤差10<sup>-2.7</sup>の設定にも関ら ず 10<sup>-3.8</sup>を満足する所で収束したため,最大許容 誤差 10<sup>-2.7</sup>~10<sup>-3.8</sup>までは学習および推定結果が 全て同一になった。

推定結果の精度は出力値/目標値(EC5-240 -TT 試験対の計測値)の標準偏差で各々精度を 比較した。その結果を図-11に示した。図-11 により最大許容誤差が小さい順に推定精度も高 かった。これは今回示した学習範囲では過学習 10)が起きず推定精度が良い所で収束したと考え られる。また、過学習の場合推定精度に悪影響 を与える原因に対して述べると次のように考え られる。今回の学習データのように滑らかでは なく不規則的な計測データに対しては過学習<sup>10)</sup> が生じし易くなる。滑らかで規則的なデータで はそのパタンを認識しやすくネットワークの中 でそのパタンが認識される。しかし、滑らかで はなく不規則的なデータに対しては精度良いパ タン認識が不可能であるため学習精度を高める とネットワークの中で学習データーつーつに対 してその値を再現するような学習が行われる。 そのため学習結果は一つ一つの値に対してよい 精度で再現しているが,学習データで経験して いない推定データを入力するとその値に敏感に 反応し推定精度を低くすることもある。これは4 章の図-14, 図-15の学習および推定結果によ り分かる。従って、今回のような不連続的な計 測データに対する最大許容誤差の設定は最も重 要であることがわかった。





#### 4. 高層建物の柱縮小量の推定

本章では3章での知見に基いて縮小量推定の 実用化のため現場で適用可能な補正アルゴリズ ムを提案し、その検証のため建設中である66層 超高層建物の現場で計測したデータを用い検討 を行った。また、学習および推定はその提案補 正アルゴリズムに従って行った。

#### 4.1 補正アルゴリズム

超高層建物の鉛直部材の縮小量の補正は施工 過程で柱の高さを調節して補正する。しかし, 各層ごとに補正するのは補正量が小さすぎ,各 層補正することは工費および技術的な問題が大 きいため不可能である。そのため現在は補正を 10層,または一定な層数に設定し補正するのが 一般的である。

そこで、本研究ではニューラルネットワーク を用い縮小量を推定するアルゴリズムを提案し た。その補正アルゴリズムの概念図を図-12 に 示した。柱部材の縮小量は軸力により最下層で 最大であり、補正を行う階での高さ調整を行う 補正層の補正量は、累積した縮小量である。

従って,縮小量が最も大きい最下層にゲージ を埋め込み補正階に至るまでの縮小量を計測す る。その計測データを用いニューラルネットワ ークで学習させネットワークを構築する。その 構築されたネットワークにより補正階の縮小量 (補正量)を推定するアルゴリズムである。

次の節では本提案アルゴリズムの実用化の可 能性を検討するため施工中の建物の 13 階と 33 階で計測した縮小量のデータを用い本提案アル ゴリズムの検証を行った。



\* NN:ニューラルネットワーク

図-12 補正アルゴリズムの概念図

## 4.2 計測データを用いた縮小量の推定

## (1) 学習および推定対象

66 層超高層建物の 13 階と 33 階で計測したデ ータを用い学習および推定を行った。学習および 推定は補正アルゴリズムに従って 13 階(最下層 と仮定)のデータを学習データとして用い,33 階(補正層と仮定)を推定対象とした。対象部材 は図-13の平面図に示してある C1 柱とした。ま た,ニューラルネットワークのパラメータは3章 で構築したアルゴリズムをそのまま用いた。



図-13 対象建物の平面図

## (2) 学習および推定結果

一般的に縮小量の計測データは不連続で不規 則的なデータが多いため3章での知見により最 大許容誤差の設定を10<sup>-3.0</sup>,10<sup>-3.5</sup>,10<sup>4.0</sup>の3つに 設定し推定結果を検討した。その学習および推 定結果をそれぞれ図-14と図-15に示した。

図-14 の学習結果により許容誤差 10<sup>-3.5</sup> と 10<sup>4.0</sup> では不連続的な学習データ(13F-C1)を 精度良く再現していることが分かる。しかし, 10<sup>-3.0</sup> では 50~100 日の所で若干学習データと離 れていることが分かる。これは,点一つ一つの 再現よりパタン認識に重点した学習が行われた と考えられる。また,推定結果を示した図-15 では最大許容誤差の大きい順に推定精度が良い ことが分かる。これは 3 章で記述したように 10 -<sup>3.5</sup> と 10<sup>-4.0</sup> では学習データに対する過学習<sup>10)</sup> が起きたため学習データのパタンより一つ一つ の点の再現に重点を置いた学習が行われたため であると考えられる。従って,このような不連 続で不規則性が大きいデータに対しては適切な 最大許容誤差の設定が最も重要であることが分 かった。また,以上の検証により本提案アルゴ リズムは適切な最大許容誤差を設定することに より可能であることが分かった。



## 5. まとめ

超高層建物での鉛直部材の実用化可能な縮小 量推定のため、ニューラルネットワークを用い た実用化可能な補正アルゴリズムの提案および 実計測のデータを用い実用化および縮小量の推 定可能性の検討を行った。その結果より得られ たことを以下に記する。

- 1) 超高層建物の鉛直部材の縮小量の推定が 可能であることが分かった。
- 2)縮小量の推定は適切な最大許容誤差の設定により精度良い推定ができることが分かった。
- 3) 学習精度と推定精度がいつも比例する関

## 係ではないことが分かった。

今後本研究での手法を実用化するためには学 習精度と推定精度の関係を明らかにし,推定精 度に最適な最大許容誤差設定方法について検討 する必要がある。

## 参考文献

- ACI Committee, "Prediction of Creep, Shrinkage, and Temperature Effects in Concrete Structures, Manual of Concrete Practice", American Concrete Institute, Detroit, MI., 1999.
- Comite Euro-International du Beton "CEB-FIP Model Code, Design Code", Thomas Telford, 1990.
- 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.
- 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) 楊元稙, 李元虎, 康大彦, 李政翰: ニューラル ネットワークを利用した高層 RC 建物の乾燥収 縮およびクリープ量を推定するための基礎的 研究, 日本建築学会大会学術講演梗概集, pp.301 -302, 2005.9.
- 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) 半谷裕彦, 川口健一: 形態解析, 培風館, 1991.
- 9) 楊元稙,中埜良昭,真田靖士:ニューラルネットワーク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・オンライン実験手法の提案,日本建築学会構造系論文集,第 582 号,pp.73-80,2004.8
- 10) Hiroshi Ichikawa, "Application of Multilayer Feed-forward Neural Network to Non-linear Analysis," kyoritsu Pub. Co., Ltd. 29–30, 1993.