

# 機械学習を用いた圧密沈下対策地盤改良の最適設計 Optimization for Improvement of Ground Consolidation Settlement using Machine Learning

津國 正一<sup>\*1</sup>  
Shoichi Tsukuni

濱名 正泰<sup>\*1</sup>  
Masahiro Hamana

山戸田 武史<sup>\*2</sup>  
Takeshi Yamatoda

<sup>\*1</sup> 株式会社竹中土木  
Takenaka Civil Engineering & Construction Co., Ltd.

<sup>\*2</sup> 株式会社 IDAJ  
IDAJ Co., LTD.

We studied a new approach to optimize the improvement of ground consolidation settlement using machine learning. We estimate a ground settlement by using a FEM simulator called MuDIAN. The simulator calculates a two-dimensional settlement pattern from a two-dimensional improvement pattern. Firstly, we explore improvement patterns to minimize the settlement by random design of experiment and additional genetic algorithm optimization (Step-1). Secondly, we analyze the exploration result using machine learning (Step-2). The machine learning model consists of an encoder and two decoders using Convolutional Neural Networks (CNN). The CNN encoder can transform two-dimensional improvement patterns into a latent space and visualize the similarity of the patterns. The one of CNN decoders can predict a settlement pattern from an arbitrary point on the latent space. Another CNN decoder can recover an improvement pattern. We can predict other improvement patterns which are not included in the exploration result to use these CNN decoders.

## 1. はじめに

軟弱な粘性土地盤上に道路等を建設するために盛土を施工すると、新たに加わる盛土荷重によって粘性土層に圧密沈下現象が発生し、長期的な沈下が盛土に発生する。圧密沈下は粘性土地盤に作用する盛土荷重によって粘性土層の間隙が小さくなることによって発生する沈下である。この沈下を防ぐために盛土の下地盤を地盤改良する方法が採用されることが多い。

有限要素法を用いた解析(FEM解析)で地盤改良の設計を行う場合、図-1 に示すように改良杭の改良長を変えた解析を数ケース行い、得られた解析結果から設計仕様を満足する改良長を設計で採用するのが通常の方法である。解析モデルの作成では解析技術者の経験から解析パターンを決め、得られた解析結果の評価も解析技術者の経験に基づいて行っている。

この方法で得られた改良パターンが必ずしも最適な改良パターンとは言えないが、解析モデル作成と解析に要する手間と時間の制約から、実務の設計レベルでこれ以上の検討を行うことは難しい。そこで、解析技術者の経験に依存しない最適な改良パターンを求めるために、人工知能の活用を図った。この方法では次の2ステップで検討を行う。ステップ-1では、想定している地盤改良の対象範囲に対して改良する要素と改良しない要素の組み合わせを変えた数千の改良パターンに対して、最適化アルゴリズムを用いた最適改良パターンの探索を行う。その結果、改良パターンに対応する数千の変位量コンター図が出力として得られる。ステップ-2では、ステップ-1で得られた数千の改良パターンと変位量コンター図を用いて機械学習を行い、改良パターンから変位量コンター図を予測した。そして、学習結果を潜在空間に表示することによって、最適な改良パターンの可視化を図っている。

本報告では地盤条件が既知の解析モデル(津國 2014)を参考に設定した解析モデルを用いて、最適な改良パターンを求める手法の妥当性を検討した。




図1 従来法での設計解析イメージ

## 2. 関連研究

### 2.1 地盤改良手法

本検討は、現在実用化されているシミュレーションを用いた圧密沈下対策のための地盤改良手法[津國 14]に、近年発達の著しい機械学習技術を組み合わせ、より最適な改良パターンを求めるための手法を検討したものである。

### 2.2 自己符号化器

機械学習手法のうち深層学習による手法を用いることで、多次元情報に対する新しいデータ分析や予測が可能となること

示されている。特に、機械学習における深層学習手法のうち自己符号化器(Autoencoder, AE)は、現実世界の多次元情報の低次元空間への符号化と、低次元空間からの復号化が可能である可能性が示されている[Hinton 06]。この手法は対象とする事象が多様体仮説に従うかどうか課題となるものの、汎用性が高い手法であると考えられる。

2.3 自己符号化器を用いたパターン最適化

従来型の機械学習、例えば競合学習型ベクトル量子化ニューラルネットワークである自己組織化マップ[臼井 95]などでは、多次元情報の低次元写像化や未知のパターンの予測で用いる場合に様々な課題があった。

近年、多次元情報の低次元写像化や未知のパターンの予測に自己符号化器を用いる研究が見られるようになった。例えば、分子の構造設計のための研究がある[Gómez-Bombarelli 16]。この研究では、目的の分子構造を得るために符号化器で得られた潜在空間を用いて特徴探索を行い、復号化器を未知のパターンの予測に用いる概念が示されている。本概念は分子構造に限らず応用可能な手法であると考えられる。

2.4 深層ニューラルネットワークによる予測技術

また、深層ニューラルネットワークによる新しい近似モデルの研究も行われている。数値流体解析(Computational Fluid Dynamics, CFD)において、深層学習の畳み込みニューラルネットワーク(Convolutional Neural Networks, CNN)を用いることで、計算前二次元形状情報からの計算後二次元流速ベクトルの直接的な予測が可能である可能性が示された[Guo 16]。この手法は一般的な CNN 符号化器、CNN 復号化器によって構成されており、汎用性が高い手法である。また、中間層の全結合層で潜在空間を得ることも可能である。

3. モデルケースの設定

圧密沈下対策のための地盤改良で最適な改良パターンを求めるために設定したモデルケースの解析断面を図 2 に示す。盛土高さ 7.0m、盛土下の軟弱粘性土層厚 19.8m である。このモデルは遠心模型実験の模型断面を模擬して作成されており、軟弱粘性土層は関口・太田モデルでモデル化し、パラメータはカオリンクレー(ASP100)に対して設定されている。




図 2 圧密解析モデル

表 1、表 2 に解析で用いた主な地盤定数を示す。最適設計での評価指標は最終変位量であるので、透水係数を 100 m/s と模型地盤よりも大きく設定することによって、1 ステップの解析で最終変位量を求められるようにしている。圧密解析で用いた解析コードは MuDIAN である[塩見 1998]。地盤改良の対象とした盛土下の地盤には水平方向と鉛直報告に各 10 要素あるので、地盤改良パターンは 100 要素に対する組合せになる。最適設計

での評価は、盛土法尻から 4m 離れた周辺地盤地表面 B 点での変位量に対して行った。地盤改良を行わない無対策断面に対しての B 点での沈下量は 408mm、盛土天端中央 A 点での沈下量 2227mm であった。地盤改良部は一軸圧縮強度  $q_u=1000\text{kPa}$  と想定し、ヤング率  $E=170q_u$  (日本建築センター 2002)の関係より、改良体のヤング率  $E=170000\text{kPa}$  に設定し、弾性要素でモデル化した。

| 土質区分  | 解析でのモデル化 | 単位体積重量<br>( $\text{kN/m}^3$ ) | ポアソン比 | $M$   | $\lambda$ | $\kappa$ | $A$ | $e_0$ | $D$     | 透水係数<br>( $\text{m/sec}$ ) |
|-------|----------|-------------------------------|-------|-------|-----------|----------|-----|-------|---------|----------------------------|
| 粘性土地盤 | 関口・太田モデル | 15.0                          | 0.49  | 0.997 | 0.274     | 0.0274   | 0.9 | 2.243 | 0.07627 | 1.00E-02                   |

表 1 解析で用いた地盤定数(1)

| 土質区分          | 解析でのモデル化 | 単位体積重量<br>( $\text{kN/m}^3$ ) | ポアソン比 | ヤング率<br>$E$ ( $\text{kN/m}^2$ ) | 透水係数<br>( $\text{m/sec}$ ) |
|---------------|----------|-------------------------------|-------|---------------------------------|----------------------------|
| 盛土 (高さ 7.0m)  | 弾性要素     | 19.0                          | 0.33  | 28000                           | —                          |
| 支持層 (厚さ 3.0m) | 弾性要素     | 17.8                          | 0.33  | 56000                           | 1.00E-05                   |

表 2 解析で用いた地盤定数(2)

4. 最適改良パターンの探索(ステップ-1)

4.1 入出力

本検討で用いる入力データは、前述のように改良パターンを示す 10 列×10 行の二次元配列データであり、数値は 0(改良)か 1(未改良)のバイナリデータとなる。

出力データは前述の地盤の各節点における変位[m]を示す 32 列×21 行の二次元配列データであり、実数データとなる。変位は水平方向変位、鉛直方向変位の 2 種類出力される。水平鉛直変位から得られる変位の絶対値が変位ノルムとなる。左上 11 列×8 行が盛土部分、右上 21 列×8 行はデータなしとなる。下部 32 列×13 行が盛土横地盤を含む軟弱粘性土層となる。

4.2 最適化

学習と検証で用いるデータの生成は、modeFRONTIER というソフトウェアを用いて自動化した。計算開始時の地盤改良パターンの 100 要素は準乱数法(SOBOL)を用いて 100 通りの実験計画を生成した。その後、遺伝的アルゴリズムを用いて 99 世代分の入力変数組み合わせの最適化計算を行った。最適化の目的関数は、B 点における変位ノルム最小化とした。拘束条件として地盤改良部の上方(斜めを含む)は少なくとも 1 つの地盤未改良部を含むこととした。その結果、最適化計算結果として拘束条件を満たす 1,976 組の入出力組み合わせを得た。図 3 の最適化計算の経過から、B 点変位を最小化する入力パターンの探索が行われていることが確認できる。この目的関数および拘束条件の設定は暫定あり、実用上はより適切な設定が必要となるが、本検討ではこのデータをそのまま機械学習の検討に用いた。




図 3 最適化計算の経過

5. 機械学習と潜在空間での可視化(ステップ-2)

5.1 機械学習の手順

関連研究を参考に次の手順を考えた。まず、入力パターンを入力、出力変位を出力とする図 4 のような深層ニューラルネットワークを学習する。符号化器と復号化器は畳み込みニューラルネットワークで構成されている。潜在空間の部分のみ線形層による全結合を用いている。この学習により入力パターンを潜在空間に符号化する符号化器 1、潜在空間から出力変位を得る復号化器 1 を得ることができる。




図 4 符号化器 1 および復号化器 1

次に先に学習した潜在空間を入力、入力パターンを出力とする図 5 のような深層ニューラルネットワークを学習する。この学習により潜在空間から入力パターンを得る復号化器 2 を得ることができる。




図 5 復号化器 2

符号化器 1 を用いることで、最適化計算で得られた計算結果を入力パターンと出力変位組み合わせの類似性で可視化することができる。また、復号化器 1 を用いることで、全節点個別に潜在空間における予測変位分布を可視化することができる。A 点、B 点の予測変位分布を合わせることで、両点の希望の変位を満たす領域を探索することができる。そして、得られた領域に対して復号化器 2 を用いることで、入力パターンを予測することができる。

5.2 ネットワークアーキテクチャ

前述の符号化器 1 と復号化器 1 を表 4 の構成で実装した。また、前述の復号化器 2 を表 3 の構成で実装した。実装には TensorFlow を用いた。

| ネットワーク種類     | 入力サイズ    | カーネル | ストライド | チャネル数<br>もしくはノード数 | 出力サイズ    | パディング | 活性化関数      |
|--------------|----------|------|-------|-------------------|----------|-------|------------|
| Conv1        | 10x10x1  | 3x3  | 1x1   | 32                | 10x10x32 | VALID | Leaky ReLU |
| Conv2        | 10x10x32 | 3x3  | 2x2   | 64                | 5x5x64   | SAME  | Leaky ReLU |
| Conv3        | 5x5x64   | 3x3  | 2x2   | 128               | 2x2x128  | SAME  | Leaky ReLU |
| FullConnect1 | 512      | -    | -     | 2                 | 2        | -     | Tanh       |
| FullConnect2 | 2        | -    | -     | 512               | 512      | -     | Leaky ReLU |
| Deconv1      | 2x2x128  | 3x3  | 2x2   | 64                | 4x4x64   | SAME  | Leaky ReLU |
| Deconv2      | 4x4x64   | 3x3  | 2x2   | 32                | 8x8x32   | SAME  | Leaky ReLU |
| Deconv3      | 8x8x32   | 5x5  | 2x2   | 16                | 16x16x16 | SAME  | Leaky ReLU |
| Deconv4      | 16x16x16 | 17x6 | 1x1   | 2                 | 32x21x2  | VALID | -          |

表 4 ネットワーク構成(1)

| ネットワーク種類     | 入力サイズ   | カーネル | ストライド | チャネル数<br>もしくはノード数 | 出力サイズ   | パディング | 活性化関数      |
|--------------|---------|------|-------|-------------------|---------|-------|------------|
| FullConnect2 | 2       | -    | -     | 512               | 512     | -     | Leaky ReLU |
| Deconv5      | 2x2x128 | 3x3  | 2x2   | 64                | 4x4x64  | SAME  | Leaky ReLU |
| Deconv6      | 4x4x64  | 3x3  | 2x2   | 32                | 8x8x32  | SAME  | Leaky ReLU |
| Deconv7      | 8x8x32  | 3x3  | 1x1   | 16                | 10x10x1 | VALID | Sigmoid    |

表 3 ネットワーク構成(2)

潜在空間は可視化するために二次元としている。また、潜在空間のための活性化関数には Tanh を用いた。

5.3 学習

1,976 組のデータは、最適化計算後の変位が  $2 \times 10^{-4} \text{m}$  以下の 16 組を検証データ、残りの 1,960 組を学習データとして分割して用いた。学習は 2,000 エポック、ミニバッチ数 128 のミニバッチ学習で行った。各層の入力ではバッチ正規化を用いており、ドロップアウトは用いていない。勾配評価時の損失は平均二乗誤差(Mean Square Error, MSE)を用いた。勾配降下のアルゴリズムは Adam 法を用いた。学習は GPU(NVIDIA Geforce GTX1080Ti)を用いて行った。符号化器 1 および復号化器 1 を先に学習し、その結果を用いて復号化器 2 の学習を行った。符号化器 1 および復号化器 1 の学習には約 415 秒かかり、復号化器 2 の学習には約 75 秒かかった。図 6 に本検討における学習時の損失を示す。




図 6 学習時の損失

5.4 実験結果

まず、符号化器 1 および復号化器 1 を用いて検証データの推論を行った。図 7 に検証パターンによる出力変位の予測例を示す。このように未知検証パターンの出力をある程度の精度で予測できることがわかった。




図 7 復号化器 1 による予測例

次に復号化器 2 を用いて検証データの推論を行った。図 8 に符号化器 1 から得られる検証入力パターンとの潜在空間座標を復号化器 2 に入力し、元の入力パターンを得た例を示す。入力変数組み合わせは準乱数による実験計画を含むため、多様体仮説の条件を満たさない可能性があることに注意する必要があるものの、このような未知検証パターンにおいても、潜在空間からの入力パターンの復元がある程度可能であることがわかった。




図 8 復号化器 2 による予測例

符号化器 1 による潜在空間への符号化結果を図 9 に示す。未知検証データは学習データの分布の範囲に含まれており、精度良く予測可能な範囲にあると考えられる。




図 9 符号化器 1 による潜在空間

次に復号化器 1、復号化器 2 を用いて目的を満たす未知の入力パターンを得る手法を試した。




図 10 復号化器 1 と復号化器 2 による入力パターンの予測

図 10 のように復号化器 1 を用いて潜在空間内を探索する。今回、A 点変位が 0.05m 以下、B 点変位が 0.002m 以下の領域を探索し、両者を満たす領域を抽出した。次に、その領域における潜在空間座標を復号化器 2 に入力し、複数の入力パターン予測を得た。得られた入力パターン予測を平均した。このパターンが目的を満たす平均的なパターンであると考えられる。今回抽出された領域は検証パターンの潜在空間位置と近く、得られた予測パターンもある程度検証パターンに近いことがわかる。

## 6. まとめ

本検討では、圧密沈下対策のためのより最適な改良パターンを求める手法として、機械学習を積極的に用いた新しい手法の検討を行った。新しい手法として、最適化計算によるデータ生成と深層学習による特徴抽出およびパターン予測を組み合わせた手法を検討した。その結果、最適化計算から入力パターンを予測する一連の手順を確立することができた。

本手法は、現段階ではまだ予測精度が不十分である。今後、予測精度を高めるための最適化計算の条件および深層ニューラルネットワークモデルの改善を検討する予定である。

## 参考文献

- [白井 95] 白井支朗, 岩田彰, 久間和生, 浅川和雄: 基礎と実践 ニューラルネットワーク, コロナ社, 1995
- [塩見 98] 塩見忠彦, 吉澤睦博, 鬼丸貞友, 津國正一: 地盤と構造物の非線形挙動を考慮した構造解析システムの開発, 竹中技術と研究報告, No.54, pp1007-1008, 1998.
- [津國 14] 津國正一: 3 次元 FEM 解析による杭状・壁状配置併用型改良工法の詳細設計法の検討, 土木学会論文集 C(地圏工学), Vol.70, No.3, pp.313-327, 2014.
- [日本建築センター 2002] 改訂版 建築物のための改良地盤の設計及び品質管理指針—セメント系固化材を用いた深層・浅層混合処理工法—: 日本建築センター, pp.349, 2002.
- [Guo 16] Xiaoxiao Guo, Wei Li, Francesco Iorio: Convolutional Neural Networks for Steady Flow Approximation, KDD '16 Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining Pages 481-490, ACM, 2016
- [Gómez-Bombarelli 16] Rafael Gómez-Bombarelli, Jennifer N. Wei, David Duvenaud, José Miguel Hernández-Lobato, Benjamín Sánchez-Lengeling, Dennis Sheberla, Jorge Aguilera-Iparraguirre, Timothy D. Hirzel, Ryan P. Adams, k and Alán, Aspuru-Guzik: Automatic Chemical Design Using a Data-Driven Continuous Representation of Molecules, <https://arxiv.org/abs/1610.02415>, arXiv preprint, 2016
- [Hinton 06] GE Hinton, RR Salakhutdinov: Reducing the dimensionality of data with neural networks, science 313 (5786) 504-507, AAAS, 2006