

Shall we start データ駆動地盤工学? ～ベイズ・機械学習を中心として～

第6回：応用編（その2）～機械学習と縮約モデル～

Applications: Part IV – Machine learning and reduced order model

森口 周二（もりぐち しゅうじ）

東北大学災害科学国際研究所 准教授

e-mail: shuji.moriguchi.d6@tohoku.ac.jp

村尾 英彦（むらお ひでひこ）

(株) 村尾地研 代表取締役

外里 健太（とさと けんた）

八戸工業大学 工学部 工学科 助教

キーワード：固有直交分解，代理モデル，画像解析

1. はじめに

本講座では、第1回の総説に始まり、第2～4回にベイズ推定や機械学習の基礎的な事項を確認し、第5回からはその応用編として地盤工学分野の具体的な適用例について説明している。本稿の内容も第5回に続いて応用編であり、「固有直交分解を援用した広域斜面安定性評価」と「写真画像を用いた土質および地質区分」の二つの適用例について説明する。これまでの回で説明してきた内容をふまえて説明を行う箇所があるため、必要に応じて過去の回の内容を再確認しながら読み進めていただきたい。また、今回の内容は、機械学習や縮約モデルが実問題の中でどのように使えるのかのイメージが持てるような内容を狙ったものであり、理論や数式についての詳細な説明は省略されている部分があることをご容赦いただきたい。

2. 固有直交分解を援用した広域斜面安定性評価

ここでは、広域の豪雨災害を対象として、斜面安定性評価のために固有直交分解を援用した研究例¹⁾について説明する。この研究では、実在する地形を対象として、数値解析によって豪雨に伴う雨水の地盤中への浸透、地表流の発生、斜面の不安定化を表現し、複数の解析結果から代理モデルを作成することで、降雨に伴う斜面の不安定化の評価を低い計算コストで実現している。技術の実用化に向けてはまだ課題は多いもの

の、数値解析結果をデータとして活用したデータ駆動型地盤工学の一例として紹介する。

2.1 対象とした豪雨災害とその再現解析

まず、対象とした豪雨災害とその再現解析²⁾について説明する。本研究の対象領域は、2017年5月に大規模な林野火災が発生した岩手県釜石市のある領域である。図-1は、解析領域（図中の Analysis area）と最寄りのアメダス観測点の位置を示した図である。2017年の林野火災では合計で413haの領域が焼損し、その後焼損した樹木の伐採や植林が行われた。その後の2019年10月12～13日にかけて襲来した令和元年東日本台風（2019年台風19号）による豪雨で、多くの斜面崩壊が確認されている。また、伐採された木々が流木となって沢に集積し、作業道のシカ防護ネットを破壊したことなどが確認されている³⁾。

図-1 解析領域とアメダス観測点の位置²⁾

令和元年東日本台風襲来時の状況を再現するため、地形や地質情報を収集し、三次元モデルを作成するとともに、解析雨量のデータを入力として数値解析を実施した。図-2～図-4 は解析結果の例であり、雨水の浸透深さ分布、地表流の水深分布、斜面の安全率分布を示したものである。浸透解析には、Green-Ampt モデル⁴⁾を、地表流解析には Diffusion Wave モデル^{例えば5)}を、斜面安定解析には Hovland 法⁶⁾を適用している。詳細については参考文献²⁾を参照されたい。




図-2 降雨イベント終了時の浸透深さ分布

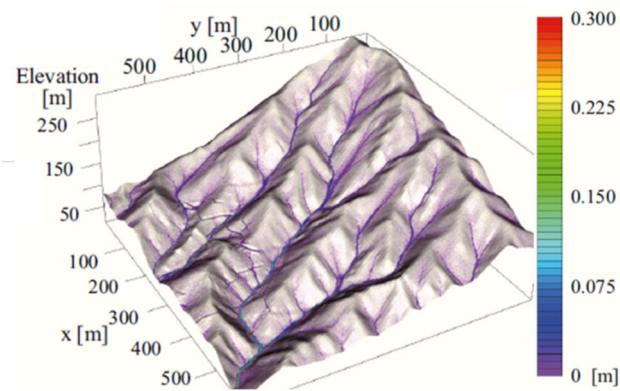


図-3 降雨イベント中の地表流の水深分布




図-4 降雨イベント終了時の安全率分布

2.2 代理モデルの構築

先述の数値解析を用い、入力となる雨量データを変化させれば、様々な降雨シナリオの条件下で豪雨災害を表現することができる。しかしながら、広域を対象としながらある程度解像度の高い細部の物理を表現するアプローチであるために計算コストが高く、発災直後の被害の即時予測のためのツールとしては、そのままでは適用しにくい。そこで、事前に複数ケースの数値解析を実施し、その結果に基づいて代理モデルを構築することを試みた。その結果について説明する。

代理モデル構築の流れのイメージを図-5 に示す。複数ケースを考えるうえで、降雨強度の時系列データを入力の不確実性とする。時系列データを考慮する場合、一つの降雨イベントでの総降水量や継続時間、降水量がピークとなる時間帯といった“雨の降り方”を設定する必要があり、無限の数のシナリオを想定することができる。さらに、本研究では考慮しないものの、広域の評価をする場合には降水量の時間変化だけでなく、空間的なばらつきについても考慮する必要があることから、想定するシナリオがさらに多く、モデルの入力情報として複雑になってしまう。この状況を回避するために、本研究では浸透解析と地表流解析の結果として得られる浸透深さ分布を代理モデルの入力、安全率分布を出力として設定した。すなわち、浸透解析と地表流解析はリアルタイムでシミュレーションを実施し、斜面安定解析の部分だけを代理モデルによって計算コストを下げるという方針とした。実際には、地表流解析もそれなりに計算コストが高いため、実問題に対応するには課題が残るものの、一つの試行的な取り組みとして研究成果を紹介する。図-5 に示すように、入力となる浸透深さ分布と出力となる安全率分布それぞれについて、固有直交分解 (POD, Proper Orthogonal Decomposition) を適用し、それぞれの空間分布の特徴を抽出する。浸透深さ分布については、抽出される POD 係数を浸透深さの特徴を表現する特徴量として用いることとし、その特徴量を安全率の POD 係数を表現する関数の入力値として用いることで代理モデルの構築を行う。なお、安全率分布を表現する代理モデルの POD 係数は、浸透深さ分布の POD 係数の関数として表現されることになるが、その関数構築のための

補間にはガウス過程回帰 (GPR, Gaussian Process Regression) を適用している。このような形で代理モデルが構築されれば、任意の降雨シナリオについて、斜面安定計算を実施せずとも安全率分布の出力が可能となる。

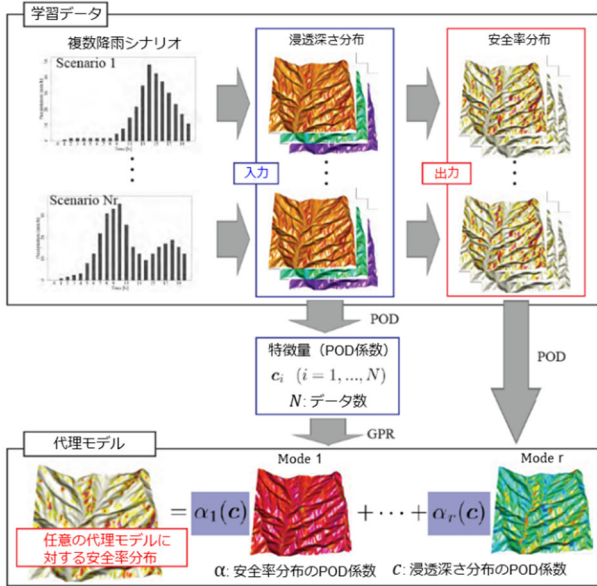


図-5 POD ベースの代理モデルのイメージ

学習用の降雨シナリオを設定するにあたり、累積降水量と時間変化 (降雨強度の時間的変化) の 2 項目を変化させた。まず、累積降水量については、確率降水量を算出することで設定する。本研究では、岩手県釜石市のアメダスの過去の観測データをもとに、気象庁で用いられている確率降水量の算出方法⁷⁾に従って算出している。具体的には、1 日降水量と 2 日降水量について、再現期間 100 年としたときの降水量として設定しており、それぞれ 310 mm, 420 mm とした。時間変化については、先行研究⁸⁾をもとに設定した。この研究例では、Illinois を対象地域としているが、本研究の対象地域付近での時間変化に関する十分なデータが揃わないため、上記先行研究の時間変化のデータを採用している。具体的には、図-6 に示すような降雨特性の異なる 4 つのパターンを想定した。この図の横軸と縦軸は、それぞれ累積降水量と継続時間に対する割合として表現されている。すなわち、曲線の立ち上がり方が早ければ降雨のピークが早期に発生することを意味する。これに加えて先行研究の中では、4 つのカテゴリーの継続時間について、カテゴリー1 では 6 時

間以下、カテゴリー2 では 6 時間から 12 時間程度、カテゴリー3 では 12 時間から 24 時間、カテゴリー4 では 24 時間以上になるような傾向があることが示されている。そのため、本研究でも、この先行研究に倣いシナリオの継続時間および累積降水量を表-1 のように設定した。




図-6 降雨特性 (パターン)

表-1 降雨継続時間と降水量の時間変化のシナリオ

| Case | 累積雨量 | 継続時間 | パターン |
|------|--------|------|------|
| 1 | 310 mm | 10 h | 1 |
| 2 | 310 mm | 10 h | 2 |
| 3 | 310 mm | 20 h | 2 |
| 4 | 310 mm | 20 h | 3 |
| 5 | 420 mm | 30 h | 3 |
| 6 | 420 mm | 30 h | 4 |
| 7 | 420 mm | 50 h | 4 |

代理モデルの入力となる浸透深さ分布データおよび出力結果となる安全率分布については、各シナリオで 1 時間おきにスナップショットとしてデータを保持するものとした。そのため、継続時間が長いシナリオではデータが多くなっている。この例では、合計 170 の入出力関係が得られ、それらのデータを用いて代理モデルの構築を行った。

ここで、代理モデル構築の作業について 1 点補足しておく。先述のように、本研究では時間と空間が変化するシミュレーション結果に対して POD を適用して、特徴モード (基底) と各データに対応する POD 係数

を計算する。本講座の第4回のPODに関する説明の中で述べたように、モードを抽出するためにはデータ行列を作成しなければならない。第4回原稿の中では、空間データをベクトル化するイメージを説明したが、時間変化がある場合には図-7に示すように、各シナリオについての異なる時間の結果（空間分布）を並べたデータ行列を考え、さらにそれをシナリオ別に並べれば良い。つまり、シナリオと時間が異なるすべての空間分布データをすべて並べてデータ行列が作成される。このあたりの操作は、慣れるまでは違和感があるかもしれないが、並べたデータの中に存在する共通のモードが抽出されることになるため、すべての結果（時空間データ）に共通のモードが抽出されることになり、それが故に全シナリオの任意時刻に対する代理モデルの構築が可能となるのである。

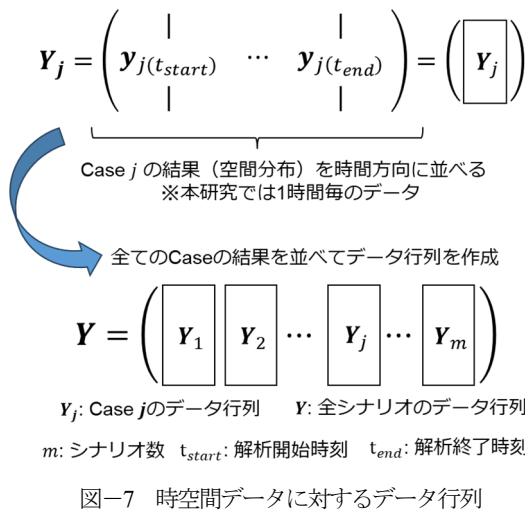


図-7 時空間データに対するデータ行列

2.3 代理モデルの精度検証

ここでは、構築した代理モデルの精度について説明する。第4回の中で説明したように、得られるモードすべてを用いる必要はなく、代理モデルに必要なモード（物理的意味のあるモード）だけを使って代理モデルを構築すれば良い。この作業は、PODの計算の中で得られる情報であるモードの貢献度や学習データを代理モデルで再構築した際の誤差を判断基準として決定されるが、ここではその詳細な説明は省略する。

PODを適用することで得られるモードのイメージとして、浸透深さ分布および安全率分布の第1モードと第2モードを図-8に示す。各モードの値については、絶対値の最大が1になるように標準化して表現し

ている。それぞれのモードについてみると、第1モードが全体的な分布の平均値をコントロールするものであり、第2モードが谷部など局所的な部分の挙動を表現するモードであることがわかる。




図-8 浸透深さ分布と安全率分布の空間モード

構築した代理モデルの精度検証のために、数値計算から直接得られた結果と代理モデルの結果の比較を行う。当然ながら、学習データは再現できて当たり前であるため、学習データにはない検証用の降雨シナリオが必要となる。先述のように、対象地域を対象として令和元年東日本台風襲来時の状況の再現解析を実施している経緯があるため、その豪雨イベントを対象として代理モデルの精度を確認するものとした。具体的には、図-9に示す降雨データを入力として、各時刻で数値解析と代理モデルで得られる安全率分布を比較した。

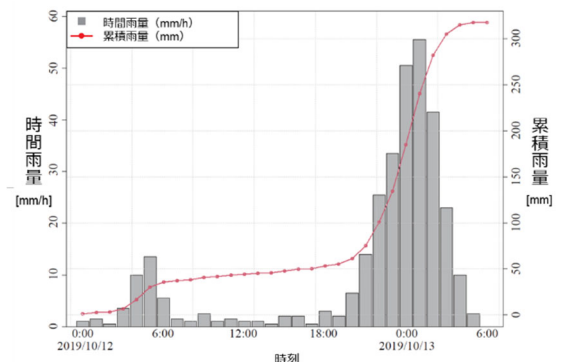


図-9 検証用の降雨シナリオ（令和元年東日本台風襲来時）

数値解析結果と代理モデルによる結果の比較を図-10～図-12示す。図-10は解析開始から24時間後（降雨のピーク時）と31時間後（降雨イベント終了時）の安全率分布である。また、図-12は図-11に示した評

価点における安全率の時間変化を比較したものである。図-12 の代理モデルの結果は幅を持っており、これは GPR から得られる情報に関する標準偏差の2倍の幅を可視化したものである。これらの結果を見てわかるように、代理モデルの結果は高精度にシミュレーションの結果を表現していることがわかる。ただし、先述のように、この研究の中では降雨は空間的に一定と仮定しており、これは代理モデルを構築するうえではかなり有利な条件となっている。今後は、降雨分布が時間的に変化するような複雑な条件や、地表流解析までを含めた代理モデルの構築が可能な枠組みを実現するための研究を進めていく予定である。

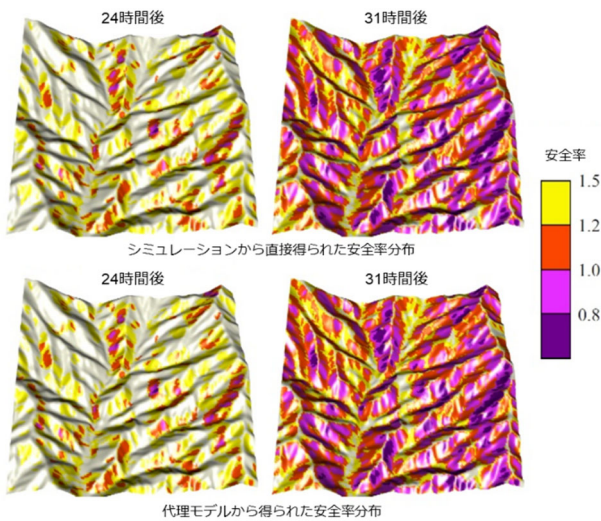


図-10 安全率の空間分布の比較




図-11 安全率の評価点




図-12 安全点上の安全率の時間変化の比較

3. 写真画像を用いた土質区分

深層学習⁹⁾は、機械学習手法の一つであり、データに関するモデルを事前に構築し、モデルのパラメータや構造をデータから学習して、予測や判断を行う「モデリング」である。深層学習を活用した成果は、画像認識、音声認識および自然言語などの課題に対して、高精度の結果が示されていることで、近年注目を集めている。最近の地盤工学研究発表会でも、画像認識に関連した発表が増えていることから期待が高まっていることが伺える。画像認識の分野においては、第4回の講座で説明したニューラルネットワークを目的に特化させた、畳み込みニューラルネットワークを活用するものが多い。3章では畳み込みニューラルネットワークの概要について簡単に説明したうえで、応用事例として写真画像を用いた土質区分例について説明する。

3.1 畳み込みニューラルネットワーク

畳み込みニューラルネットワークは、動物が視覚情報からパターン認識を行う仕組みを、神経細胞のネットワーク構造によるものとした、神経科学分野の仮説にヒントを得たものとされている。畳み込みニューラルネットワーク (Convolution Neural Network) は、その頭文字をとって CNN と表され、以下でもそのように記す。

3.1.1 画像データ

画像のパターン認識では、画像の二次元構造を活用して、二次元状に配列した実数画素値を x_{ij} として表す。この添字は、畳み込みの演算の数式を簡単にするために0から数え始める。画像データは、ある位置 (i, j) に対して様々な情報を持っている。このような情報の種類の数をチャンネル (K) と呼び、実数画素値は x_{ijk} と表す。例えば RGB カラーの画像であれば、ある位置 (i, j) において、赤 (R)、緑 (G)、青 (B) の3色の成分量に応じた $k = 0, 1, 2$ の三つのチャンネルを持ち、図-13のように元の画像が3枚の画像から構成されることになる。

図-13 では縦横比の異なる画像 ($V \neq W$) を示したが、CNN では縦横の画素数が同じサイズの正方形画像を処理することが一般的であるため、以下では $V = W$

として説明する。縦横比の異なる画像は、正方形となるようにリサイズして入力画像とする。




図-13 の RGB 画像 (チャンネル数: 3)

3.1.2 畳み込み層

簡単な例として、まず 1 チャンネルの場合について説明する。畳み込み演算は、入力 $z_{ij}^{(l-1)}$ (ここで、 $(l-1)$ は、ニューラルネットワークの $l-1$ 層目からの出力を表すラベル) に対してフィルタを作用させる処理を行うものである。フィルタは入力画像のサイズ ($W \times W$) よりも小さいサイズ $H \times H$ ($H < W$) の大きさを持つものとして定義され、 h_{pq} ($p, q = 0, 1, \dots, H-1$) と表す。 $z_{ij}^{(l-1)}$ に対するフィルタ h_{pq} の畳み込み演算は式 (1) のようになる。

$$u_{ij}^{(l)} = \sum_{p,q=0}^{H-1} z_{i+p,j+q}^{(l-1)} h_{pq} \quad (1)$$

畳み込み演算の例を図-14 に示す。図-14 では、 8×8 の入力画像に対して、 3×3 のフィルタを用いた畳み込み演算例を図示している。畳み込み演算では、まず $l-1$ 層からの入力画像にフィルタを重ね、フィルタが重なっている箇所の各画素における画素値の積 $z_{i+p,j+q}^{(l-1)} h_{pq}$ を計算する。そしてこれらの値を、フィルタが重なっている箇所全域 (図-14 では 3×3 領域) において足し合わせたものが $u_{ij}^{(l)}$ になる。この計算を、フィルタをずらしながら入力画像の全域に渡って繰り返し行う。畳み込み演算後に出力される画像のサイズは、フィルタを一つずつずらしながら演算を行った場合は、 $(W-H+1) \times (W-H+1)$ となる。なお、畳み込み演算は、画像から元画像の特徴的な構造を示すパターンを抽出するためのものである。なお、フィルタ h_{pq} は、訓練データの学習によって決定されるので、重みパラメータにほかならない。




図-14 畳み込み演算

以上では 1 チャンネルにおける場合についてだったが、ここからは複数のチャンネルに拡張して考える。 $l-1$ 層から出力された K チャンネルの画像は $z_{ijk}^{(l-1)}$ で、 $W \times W \times K$ サイズの画像である。この画像に畳み込み演算を行うには、同じチャンネル数 (K) を持つフィルタ h_{pqk} が必要である。ここで、ニューラルネットワークのときと同様に、バイアス b_{ij} を導入すると畳み込み演算は式 (2) のように表せる。

$$u_{ij}^{(l)} = \sum_{k=0}^{K-1} \sum_{p,q=0}^{H-1} z_{i+p,j+q,k}^{(l-1)} h_{pqk} + b_{ij} \quad (2)$$

複数のチャンネルを持つ入力画像に対して、一つのフィルタで処理を行う場合は、式(2)のように畳み込み後のチャンネルは一つになるが、畳み込み後に多チャンネル画像が必要な場合は、必要とするチャンネル数 M に応じた、複数のチャンネルを持つフィルタ h_{pqkm} を用いて、式 (3) のように畳み込み演算を行う。

$$u_{ijm}^{(l)} = \sum_{k=0}^{K-1} \sum_{p,q=0}^{H-1} z_{i+p,j+q,k}^{(l-1)} h_{pqkm} + b_{ijm} \quad (3)$$

このようにして畳み込み演算によって得られた画像に対して活性化関数 f を作用させたものが出力となり、式(4)のように表せる。

$$z_{ijm}^{(l)} = f(u_{ijm}^{(l)}) \quad (4)$$

ここで示したように、 $l-1$ 層からの出力である $W \times W \times K$ サイズの画像 $z_{ijk}^{(l-1)}$ に畳み込み演算を行い l 層の出力として $z_{ijm}^{(l)}$ を求めるのが畳み込み層の変換である。

3.1.3 ストライド

畳み込み演算ではフィルタをずらしながら繰り返し計算を行うが、このフィルタをずらす操作をストライドという。ストライド数を S とすると、フィルタを 1 回ずらす際に、 S 個の画素分を動かすことになる。ス

ストライド数を少なく設定すると、細かいパターンを抽出できる可能性が高くなるが、計算コストは大きくなる。一方で、ストライド数を大きく設定すれば、大雑把なパターンを捉えることになり、計算コストは小さくなる。ストライドの設定は、計算コストとの兼ね合いだが、大きくし過ぎると、本来捉えるべきパターンを捉えることができなくなることがあるため注意が必要である。

ストライド数を S_i, S_j とした場合の畳み込み演算は、式(5)のように表せる。

$$u_{ijm}^{(l)} = \sum_{k=0}^{K-1} \sum_{p,q=0}^{H-1} z_{S_i+p, S_j+q, k}^{(l-1)} h_{pqkm} + b_{ijm} \quad (5)$$

また、ストライドを S とした場合の畳み込み後の画像サイズは、式(6)のようになる。

$$\left(\left\lfloor \frac{V-H}{S} \right\rfloor + 1\right) \times \left(\left\lfloor \frac{W-H}{S} \right\rfloor + 1\right) \quad (6)$$

ここで、 $\lfloor x \rfloor$ は x を超えない最大の整数を表す。

3.1.4 パディング

畳み込み演算を行うと画像サイズは小さくなる。フィルタを重ねる際には、元の入力画像からはみ出さないようにするため、フィルタのサイズやストライドが大きい場合には、画像サイズの減少が特に顕著になる。画像が小さくなり過ぎると、特徴を捉えるのが難しくなり得るため、縮小した画像を拡張することがある。画像を拡張するには、小さくなった画像の周りに幅 P の縁を付加して、画像サイズをある程度の大きさにすることをパディングという。 $W \times W$ の画像に対してストライド S の畳み込み処理をした後に、幅 P のパディングをした画像のサイズは、式(7)ようになる。

$$\left(\left\lfloor \frac{W-H+2P}{S} \right\rfloor + 1\right) \times \left(\left\lfloor \frac{W-H+2P}{S} \right\rfloor + 1\right) \quad (7)$$

画像の縁を増やすパディングを行った際には、増やした画素の中に、何らかの値を入れる必要がある。最も簡単なのは画素値 0 を入れるゼロパディングで、それ以外にも、元画像の上下左右に同じ画像が周期的に続くと仮定して画素値を入れる方法、画像を反転させる方法および画像の縁の値を入力する方法などがある。

3.1.3 プーリング層

畳み込み層で捉えた局所的なパターンを、その位置がある程度移動しても特徴を捉えることができるよう

な処理を行うのがプーリング層である。

プーリング層では、まず $l-1$ 層から出力されたパディング済みの $W \times W \times K$ サイズの入力画像 $z_{ijk}^{(l-1)}$ の各チャンネルに対し、各画素位置 (i, j) を中心とした $H \times H$ の大きさの領域 P_{ij} を考える。この領域 P_{ij} 内の画素値から、領域内での代表的な画素値 $u_{ij}^{(l)}$ を決定するのがプーリングである。代表値の決め方としては、領域内の画素値の最大値を代表値とする最大プーリングや、画素値の平均を代表値とする平均プーリングなどがある。

3.1.3 ネットワーク構造

CNN では、畳み込み層とプーリング層の処理を繰り返す。その後、いくつかの全結合層や活性化関数処理層を付加して最終的に画像認識を行うのが一般的である。図-15 に CNN の構造例を示す。なお、同図のネットワーク構造は、後述する VGG16¹⁰⁾ の構造を示している。




図-15 CNNのネットワーク構造 (VGG16)

3.2 転移学習を用いた実用例

CNN を用いて画像認識を行った事例を示す。この事例は、本来は土質試験結果に基づいて行われる土の工学的分類と同程度の分類を、深層学習による画像認識によって行うことを目的として実施したものである。

3.2.1 画像と学習手法

地盤調査においては、公共事業支援統合情報システムである CALS/EC に従って、一定水準以上の解像度を持つボーリングコア写真を撮影することが義務付けられている。CALS/EC に定められているボーリングコア写真の撮影方法は、図-16 に示すように、ボーリングコア箱を 1 枚に収め、デジタル写真のファイルを jpeg 形式 (可能な限り圧縮を行わない) とすることが

定められている。写真の有効ピクセルは約 200 万 (1600 × 1200) ピクセル以上の撮影機材を使用することが推奨されている。有効ピクセルを、約 200 万ピクセル以上とする理由は、約 1 mm の亀裂を確認するのに十分な画像を撮影するためとされている。また、撮影時には色見本を同時に写さなければならない。学習データには、これらの画像から切り出したものを用いることとし、学習データ作成に際しては、すでに土の工学的分類がされており、ラベル付けが可能な画像データを用いた。学習および検証用に用いた画像データの内訳を表-2 に示す。なお、画像データのオリジナルデータ数は 9366 枚で、回転と反転によって 74928 枚にデータ拡張している。今回用いた画像は、ボーリングコア写真から、実際の寸法で 50 mm 四方に切り出したものを 1 枚とした。画像の 1 辺当たりの画素数は 128 ~ 256 画素となっており、1 画素の大きさは約 0.2 ~ 0.4 mm 相当である。データサイズが異なる理由は、使用するカメラのスペックが異なったためである。図-17 に使用した各土質の画像例を示す。




図-16 CALS/EC の基準に基づいて撮影したコア写真

深層学習手法としては、図-15 にネットワーク構造を示した CNN の一手法である VGG16 を利用した。VGG16 は、畳み込みを 2 回、もしくは 3 回行った後にプーリングを 1 回繰り返すモデルであり、畳み込み層 13 層、全結合層 3 層の計 16 層から構成されており、プーリング手法としては、最大プーリングを用いる。また VGG16 は、100 万枚を超える既存の大規模画像データセット (ImageNet¹¹⁾) によって事前学習済みのネットワークをベースとして、そのネットワークに対して新たなデータによる再学習を行い、目的に特化させた高精度な判別器を作成する、転移学習 (あるタスクに対して訓練されたモデルを他のタスクに転用する手

法) に用いられる。転移学習には、重みデータを更新せずに特徴抽出器として利用する方法と、重みの一部を更新するファインチューニングがある。ファインチューニングは、CNN の浅い層ではエッジなどの汎用的な特徴を抽出し、深い層では教師データに特化した特徴を抽出する傾向があることを利用して、再調整が必要な層に対して再度学習を行う手法である。今回の検討では上から 11 層を固定し、それ以降の 5 層の重みを更新するファインチューニングを行った。

表-2 画像データの内訳

| ラベル | 土質名 | 数量 |
|------|----------|--------|
| f | 細粒土 | 15,328 |
| f-s | 砂混じり細粒土 | 6,336 |
| fs | 砂質細粒土 | 12,608 |
| gfs | 細粒分質砂質礫 | 4,016 |
| sf | 細粒分質砂 | 20,752 |
| gs | 砂質礫 | 992 |
| s-f | 細粒分混じり砂 | 12,112 |
| s-fg | 細粒分礫混じり砂 | 2,784 |
| 計 | | 74,928 |




図-17 画像データの例

3.2.3 学習結果

表-3 に各手法における各土質と、粘性土、砂質土、礫質土および全体の検証結果を示す。正解率は、粘性土では 0.48、砂質土では 0.66、礫質土では 0.71 で、全体での正解率は 0.60 となった。礫質土、砂質土、粘性土の順で正解率が低下し、礫質土に関しては 7 割以上の正解率となっている。一方で、細粒分を多く含む土質の判定精度は低かった。これは、シルトの粒径が 0.005 ~ 0.074 mm、粘土の粒径は 0.005 mm 以下であるのに対して、今回のデータの 1 画素の大きさが 0.2 ~ 0.4

mm 相当となり、学習において、構造認識による分類が行われていると考えれば、当然の結果だということができる。また、粒径の観点からは、中砂の粒径が 0.25～0.85 mm であることから、今回のデータでは、中砂より細かい粒径の土質の判別は当初から困難であった可能性が高いとも言える。市販されているカメラでも、マクロ撮影によって 1 画素が 0.015 mm 程度までの画像取得が可能であることから、精度向上のためには、より高画質の画像データを取得することで細粒土を含む土質の判別が可能となるよう検討を進める必要がある。なお、上記の条件を満たすように接写した画像データは、今回使用した、既存ストックである CALS/EC のデータには含まれないので、独自のデータベース構築が必要となる。また、先述のように、中砂より粒径の大きい土質に関しては、現状の解像度でも判別精度を向上させることができる可能性があるため、砂質土、礫質土の学習データ数をさらに増やすことで、判別器の精度向上を見込むことが可能であると考えられる。

表-3 VGG16 による正解率

| ラベル | 正解率 |
|------|------|
| f | 0.58 |
| fs | 0.41 |
| f-s | 0.33 |
| gfs | 0.40 |
| gs | 0.25 |
| gs-f | 0.87 |
| sf | 0.77 |
| s-f | 0.48 |
| s-fg | 0.42 |
| 粘性土 | 0.48 |
| 砂質土 | 0.66 |
| 礫質土 | 0.71 |
| 全体 | 0.60 |

以上、CNN の概略と応用例を示した。紙面の都合で触れることができなかつた CNN における誤差逆伝播法などに加えて、深層学習全般について興味のある読者は参考文献^{9,12)}を参照されたい。特に「これならわ

かる深層学習入門¹²⁾」は説明や数式の展開が丁寧で、初学者にもわかりやすくお勧めである。本講座でも十分に参考にさせていただいた。

4. まとめ

本稿「第 6 回 応用編 (その 2) ～機械学習と縮約モデル～」では、POD と GPR を用いた豪雨による斜面崩壊を対象とした代理モデルおよび CNN による写真画像を用いた土質区分判別の例を示した。どちらの研究例も未だ課題は残っており、実用化に向けて更なる研究やデータの蓄積が必要な状況ではあるものの、これらの例を通じて、読者がデータ駆動型地盤工学の可能性を感じていただければ幸甚である。

参考文献

- 1) 外里健太: 広域災害ハザード評価のための数値解析とモード分解の融合, 東北大学博士論文, 2023.
- 2) Tozato, K., Dolojan, N. L. J., Touge, Y., Kure, S., Moriguchi, S., Kawagoe, S., Kazama, S. and Terada, K.: Limit equilibrium method-based 3D slope stability analysis for wide area considering influence of rainfall, *Engineering Geology*, 308, 106808, 2022.
- 3) Touge, Y., Hasegawa, M., Minegishi M., Kawagoe, S. and Kazama, S.: Multitemporal UAV surveys of geomorphological changes caused by postfire heavy rain in Kamaishi city, northeast Japan, *CATENA*, Vol. 220, Part A, 106702, 2023.
- 4) Green, W. and Ampt, G.: Studies on soil physics, *The Journal of Agricultural Science*, Vol. 4, pp. 1-24, 1911.
- 5) Sayama, T., Ozawa, G., Kawakami, T., Nabesaka, S. and Fukami, K.: Rainfall-runoff-inundation analysis of the 2010 Pakistan flood in the Kabul river basin, *Hydrological Sciences Journal*, Vol. 57, pp. 298-312, 2012.
- 6) Hovland, H. J.: Three-dimensional slope stability analysis method, *Journal of the Geotechnical Engineering Division*, Vol. 103, pp. 971-986, 1977.
- 7) 気象庁: 「異常気象リスクマップ」平成 18 年度版, <https://www.jma.go.jp/jma/press/0703/28b/riskmap18.pdf>, (Accessed October 9, 2022).
- 8) Huff, F. A.: Time distributions of heavy rainstorms in Illinois, *ILLINOIS STATE WATER SURVEY CHAMPAIGN*, 1990.
- 9) Goodfellow, I., Bengio, Y. and Courville, A.: 深層学習, KADOKAWA, 2018
- 10) Simonyan, K. and Zisserman A.: Very deep convolutional networks for large-scale image recognition, *International Conference on Learning Representations*, 2015.
- 11) Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., and Fei-Fei, L.: “ImageNet: A large-scale hierarchical image database,” *Proc. IEEE CVPR*, pp. 248-255, 2009.
- 12) 瀧雅人: これならわかる深層学習入門, 講談社, 2017

(原稿受理 2024.5.1)