

RC 梁の有限要素解析結果を教師データに用いたひび割れ予測 AI の開発及び精度の考察

早稲田大学 学生会員 ○高柳雅樹  
早稲田大学 正会員 佐藤靖彦

1. はじめに

近年、非線形有限要素解析は、構造物の挙動を的確に再現できるようになった。現在、膨大な情報を有するこの解析ツールを、設計のみならず維持管理においても有効に活用しようとする議論が続けられ、新しい技術<sup>1)2)</sup>も開発されつつある。本研究では有限要素解析で得られたひび割れ情報を教師データとして用いて、機械学習によりひび割れ性状を予測できる AI 技術の開発を試みた。

2. 解析概要

教師データを作成するために RC 梁の 2 次元有限要素解析を行った。対象とした RC 梁を図 1 に示す。解析には 2 次元有限要素解析汎用プログラム DIANA を用いた。構成モデルと物性値を図 2 に示す。




図 1 RC 梁の概要

|                 |                         |         |                         |
|-----------------|-------------------------|---------|-------------------------|
| コンクリート諸元        |                         | 引張鉄筋諸元  |                         |
| ヤング率            | 28000N/mm <sup>2</sup>  | ヤング率    | 210000N/mm <sup>2</sup> |
| ポアソン比           | 0.2                     | 材料モデル   | Von Mises塑性モデル          |
| ひび割れモデル         | 固定                      | 塑性硬化    | なし                      |
| 引張軟化曲線          | Hordijk                 | 降伏応力    | 440N/mm <sup>2</sup>    |
| 引張強度            | 2.22N/mm <sup>2</sup>   | 引張鉄筋断面積 | 634mm <sup>2</sup>      |
| 引張破壊エネルギー       | 0.0909N/mm <sup>2</sup> |         |                         |
| 等価要素長の指定        | Rots                    |         |                         |
| 圧縮曲線            | 放物線                     |         |                         |
| 圧縮強度            | 30N/mm <sup>2</sup>     |         |                         |
| 圧縮破壊エネルギー       | 48.04N/mm <sup>2</sup>  |         |                         |
| 横方向ひび割れによる低減モデル | JSCE 2012(図 2.2.5)      |         |                         |
| 横拘束効果による圧縮拘束モデル | Selby and Vecchio       |         |                         |
| せん断伝達モデル        | Al-Mahaidi              |         |                         |
| せん断伝達係数の下限値     | 0                       |         |                         |

図 2 構成モデルと物性値

解析にあたり、RC 梁には 1 点集中荷重もしくは 2 点集中荷重を載荷し、図 1 の載荷点上の荷重位

置を左から L1~L13 とし、梁中央について対称な 2 点に載荷する荷重を荷重ケース D1~D6 とする。例えば、荷重ケース D1 は L1 と L13 に集中荷重が与えられることを意味する。それぞれの載荷方法において 1 点につき 2500~300000N (2500N 刻み) の範囲で荷重の大きさを変化させてひび割れ図を取得した。

本研究で扱うのは表 1 のように FEM 解析ソフト Diana から得られたひび割れデータにひび割れが入っていない箇所の情報を加えたデータである。学習させる内容は入力値とそれに対応する出力値であり、入力値の内訳は終局荷重に対する荷重の大きさの割合である case percentage[%], 要素の位置座標(X0, Y0), 要素の載荷点からの距離(水平, 鉛直, 直線距離をそれぞれ dX, dY, dXY [mm]), そして載荷点における変位[mm]である。出力値はひび割れ方向ベクトル(yx, yy)とひび割れひずみの大きさ ε [-]である。

表 1 教師データの一例

| caseLO | case load | case percentage | X0 | Y0   | dX  | dY     | dXY      | Tdty     | yx | yy | Eknn |
|--------|-----------|-----------------|----|------|-----|--------|----------|----------|----|----|------|
| 2      | 0.25      | 1.25            | 11 | 7.92 | 489 | 442.08 | 659.2084 | -3.02731 | 0  | 0  |      |
| 2      | 0.25      | 1.25            | 39 | 7.92 | 461 | 442.08 | 638.7141 | -3.02731 | 0  | 0  |      |

機械学習のモデルはプログラミング言語 Python で作成し、ディープラーニングのフレームワークは Keras の Sequential を用いた。

4. 解析結果

ここで、荷重ケース D1~D6 のうちいくつかの載荷方法におけるひび割れデータを学習させ、それとは異なる載荷方法のひび割れ図を予測させたときの結果を示す。その際、学習 A: DL1~DL3 を学習させた場合、学習 B: DL1, DL3, DL5 を学習させた場合、学習 C: DL1~DL5 を学習させた場合の 3 ケースについて実験した。なお、全ての学習

において、荷重ケース DL6 を予測させた。

図 2 は上から DIANA の解析結果, A, B, C の予測結果である。Diana の出力結果と予測結果をプロットした図において、ひずみの大きさを表すカースケールは同じである。




図 2 DIANA の解析結果と AI 予測の比較

A は B と比べて教師データにしている載荷位置の個数は等しいが、B の方が梁の広範囲にわたるひび割れのデータを学習している。また、B と C の教師データが分布する範囲は同じだが C はより多くのデータを学習している。

A の場合、梁中央に本来発生するはずのひび割れが見受けられず、DL6 のような荷重が梁に載荷されているとは図から判断できないため、精度は悪い。一方 B は大まかな分布を捉えており、斜めひび割れも出力されている。B と C を比べると、ひび割れの分布は似ているが B で出力できた斜めひび割れが C の予測結果には現れなかった。B と C の結果から学習するデータを増やすとかえって精度が上がらないという考察もできてしまう。今回 A, B, C は共に構造が同じニューラルネットワークで学習・予測を行っている点を考慮すると、データを増やした際にはニューラルネットの構造もそれに対応して大きくする必要があると考えられる。どの場合の予測も外挿であるため、解析結果

に近い予測結果を得るにはより複雑な関数近似が可能な深いニューラルネットの作成が改善案の 1 つである。

また、A～C 全ての予測結果では共通してひび割れひずみの大きさが過小評価されている。A と同じ条件で DL4 について予測を行ったとき、case percentage が 97%のときの予測結果のひび割れひずみ最大値が DIANA の解析結果のわずか 0.34%程度であった。だが、ニューラルネットの層を 2 増やすと予測値の最大値が解析結果の 12%程度になったため、ニューラルネットの層を増やすことでひずみの大きさの過小評価は改善される。

## 5. まとめ

(1) 教師データの選び方によって予測結果が異なった。学習するデータが解析する対象の広範囲にわたるときに予測精度は向上する。

(2) 教師データを増やしても精度が上がらなかったことから、場合によってニューラルネットの構造を大きくする必要がある。各種パラメータについても適宜調整しなければならない。

(3) ひび割れひずみの大きさは過小評価されるが、ニューラルネットの層を増やすことで予測精度は向上する。分布については大まかな予測が行えているため、モデル構造の工夫やハイパーパラメータ調整を行うことで実用的な予測システムの開発は可能であると考えられる。

## 参考文献

- 1) 町口敦志, 喜多敏春, 多田徳夫, 武井宏将, 近田康夫: ディープラーニングによるコンクリート構造物の劣化要因判定支援システムの開発に関する基礎的研究, 構造工学論文集 Vol.64A, pp.129-136, 2018
- 2) 奥水良亮, 佐藤靖彦: 深層学習を用いた画像処理による軸重推定手法の開発, 第 75 回土木学会年次論文講演集, 2020