

## 図面画像と諸元に基づいた橋梁の簡易 3 次元モデルの自動生成

東京大学大学院 工学系研究科 博士前期 学生会員 ○川野輪 壮太  
東京大学大学院 工学系研究科 特任准教授 正会員 全 邦釘

### 1. はじめに

3 次元モデルを維持管理に活用して、業務の効率化を図る取り組みの研究が進んでいる。しかし、新設する橋梁については BIMCIM モデルを作ることが求められる一方で、多くの既設橋梁には BIMCIM モデルが存在していない。その理由として、3 次元モデルの生成にかかる労力やコストが膨大であることが考えられる。

そこで、本研究では橋梁の簡易図面と諸元データから 3 次元モデルを自動生成する方法論の確立を目指している。そして、現段階では図面からの形状データ抽出手法を構築した。具体的には、画像変換モデルを使用し、図面を部材ごとに色分けした画像を出力させることに成功した。これによって、図面上の各部材を示す領域が明確になり、AI が自動で形状データを抽出できるようになった。なお、図面を含む各データについては、2022 年に国土交通省が整備した xROAD より取得する。

本稿では、主に画像変換モデルを用いた図面を色分けする解析について説明する。その後、今後の研究の展望について述べる。

### 2. 図面を色分けする解析の概要

使用した図面は、国土交通省管理の橋梁の点検調書作成時に作成される図面であり、1533 枚である。図面には基本的に側面図、平面図、断面図が載っており、それらをなるべく余白がないように切り抜いた。側面図が 999 枚、平面図が 1730 枚、断面図が 1337 枚であった。その後、全てを 256px×640px にリサイズし、各図の 2 割をテストデータとした。また、データ拡張として架空の図面を描画した。Python の画像処理ライブラリである PIL を用いて、4 種類から 6 種類の構造形式でそれぞれの図を描いた。同じ構造形式でも全く同じ図にならないよう、ランダム性を持たせた。特定の構造形式に枚数が偏らないよう配慮し、側面図は 1000 枚、平面図は 500 枚、断面図は 700 枚を追加した。そして、図の種類ごとに解析を実行した。

### 3. 画像変換モデル

使用した画像変換モデルは、Ting-Chun Wang et al.によって 2018 年に提案された pix2pixHD<sup>1)</sup>である。ある画像とその画像がどう変換されてほしいかを示す正解画像のペアを十分に用意し、それらを教師データとして pix2pixHD に学習させた。

ここで、大まかな学習の流れを説明する。この学習では、生成モデル G (Generator) と識別モデル D (Discriminator) が使用される。G は、画像の画素値の分布を予測し本物らしい画像を生成するように学習される。D は、与えられた画像が本物か偽物かを正しく判断できるように学習される。G と D は、交互に更新されることで互いに精度を高め合うことが期待される。それを式で示したのが式(1)の通りである。なお、 $p_z$ は G に入力されるノイズ  $z$  が従う確率分布であり、 $D(x)$ は 0 から 1 の値をとる D の出力である。1 に近いほど本物らしいと識別されたことを示している。

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log (1 - D(G(z)))] \quad (1)$$

pix2pixHD は、比較的短い学習時間で 2048px×1024px までの高解像度な画像を扱えるモデルである。しかし、作者が GitHub において公開しているものをそのまま使用しても解析は成功しなかった。この原因として、G・D において入力画像よりも高い解像度で学習する段階があることが考えられた。そこで、ベースモデルで

---

キーワード 橋梁, 3 次元モデル, 図面の活用, pix2pix, xROAD

連絡先 〒113-8656 東京都文京区本郷 7 丁目 3-1

東京大学院 工学系研究科 E-mail:chun@g.ecc.u-tokyo.ac.jp

ある pix2pix<sup>2)</sup>を参考に入力画像の解像度でしか学習しないようにしたところ、解析が成功した．参考までに、その学習の流れは図 1 の通りである．図において、 $x$  が入力画像、 $y$  が正解ラベルを示している．




図-1 pix2pix (pix2pixHD) における学習の流れ<sup>2)</sup>

4. 解析結果

表 1 に示す．学習時間はどれも 18,19 時間ほどであった．自分の目で確かめたところ、どの図も約 8 割前後の成功率で解析が成功していた．

表-1 解析結果

|                    | 例①   |      | 例②   |      |
|--------------------|------|------|------|------|
|                    | 入力画像 | 出力画像 | 入力画像 | 出力画像 |
| 側面図<br>テスト画像 200 枚 |      |      |      |      |
| 平面図<br>テスト画像 346 枚 |      |      |      |      |
| 断面図<br>テスト画像 268 枚 |      |      |      |      |

5. 今後の方針

今後の方針として、まず色分けされた各部材の形状を AI に解釈させ、個々の橋梁に特有な形状データを抽出する．その後、得られた各データを一つのデータセットに統合し、不足するデータは他のデータをもとに推測する．最後に、データセットに基づき、構造形式がわかる精度の 3 次元モデルを生成する．また、そこからさらに FEM モデルの生成も目指している．ここで、構造物の応力分布や耐荷性能を可視化できる FEM モデルを生成できれば、点検の補助・効率化や災害時の広範囲な被害シミュレーションなどが可能となる．

今後の課題は 2 点ある．1 点目は、図面の解釈方法である．データベース上の構造形式や橋長・幅員をもとに、各橋梁に固有な形状や床版厚を抽出するのが目標である．現在、T 桁橋の断面図から桁の本数と床版厚を解釈するアルゴリズムを構築した．こういったアルゴリズムの汎用性を高めること、また、各構造形式に対してアルゴリズムを構築していくことが今後の課題である．

2 点目は、得られたデータを格納するデータ構造の考案である．こういった構造だと不足したデータの推定や 3 次元モデル生成において有効であるか、について検討したい．

参考文献

1) Ting-Chun Wang, Ming-Yu Liu, Jun-Yan Zhu, Andrew Tao, Jan Kautz, Bryan Catanzaro : High-Resolution Image Synthesis and Semantic Manipulation with Conditional GANs, CVPR, pp.8798-8807, 2018 年.

2) Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, Alexei A. Efros : Image-to-Image Translation with Conditional Adversarial Networks, CVPR, pp.1125-1134, 2017 年.