

(一財) 日本建設情報総合センター研究助成事業

既存橋梁の2次元図面の意味解釈を通じた

3次元CIMモデル自動生成手法の提案

研究報告書

令和4年12月

研究関係者紹介

ちよん ぼんじょ
全 邦釘

現職：東京大学大学院工学系研究科 総合研究機構 特任准教授

謝辞

本研究を助成していただいた日本建設情報総合センターに感謝いたします。

令和4年12月1日

既存橋梁の2次元図面の意味解釈を通じた
3次元CIMモデル自動生成手法の提案
—研究報告書—

目次

内容

1. 研究背景・目的	1
2. 研究内容	2
2. 1. 概要	2
2. 2. 形状復元	4
2. 3. 寸法の読み取りと理解	22
2. 4. 変換および解析	24
3. まとめ	28


1. 研究背景・目的

JACIC'i-Con'チャレンジ戦略によれば、JACIC クラウドではインフラデータプラットフォームを介した統合モデルである 3 次元管内図の作成を重要機能の 1 つとし、またその管理や利活用を通して最終的に Digital twin の実現を目指すとしている。この Digital twin を例えば 3 次元解析などで活かすためには、対象物が網羅的に 3 次元化されていることが重要である。しかし多くの既存インフラ構造物については 2 次元図面しか存在しない。例えば以下の図-1 は PLATEAU で台東区と墨田区を表示した例であるが、建物などが 3 次元化されている一方で橋梁は 3 次元化されていない。

例えば PLATEAU を含む 3 次元都市 Digital twin のユースケースとしては、地震／津波被害予測や、避難時・パンデミック時の交通・人動シミュレーション、都市インフラの分析・老朽化予測・マネジメント、自動運転、環境対策などが挙げられている。また都市の 3 次元 Digital twin は、現実世界ではほとんど不可能な様々な政策オプションを検証するための有用なシミュレーション環境を提供することで、全体最適を目指した政策設計や計画立案の提案・補助への活用も見据えられている。しかし、網羅的に 3 次元化されていなければ、低次元側に引き摺られて解析の次元数が落ち、精度、解像度が低下してしまう。特にインフラ構造物はサイズが大きいため、それらが 3 次元化されていなければ、解析にあたっての明確なボトルネックとなってしまう。

そこで本研究では、まず橋梁構造物を対象とし、その 2 次元図面を読み込み、記載されている詳細な寸法や形状、表、単語の意味を理解した上で、3 次元 FEM モデルや CIM モデルを自動で構築する AI の研究開発を目的とする。今後都市システムの一部として橋梁を位置づけた場合、相互運用性を担保し多種多様なニーズに対応するには 3 次元であることが要求され、その観点から本技術は、橋梁が都市進化の最前線を走るための必須技術であると考えている。

また、橋梁維持管理の学術・実務の発展という観点でも橋梁 3 次元 Digital twin があることの意義は大きい。これまでは、2 次元的に蓄積されたデータをもとに診断や劣化予測が行われてきた。しかし、本来 3 次元空間にある橋梁を 2 次元にしてしまうことで空間的位置関係などの情報が失われ、劣化機構の推定などが困難という課題がある。また、性能評価のために 3 次元 FEM を行う場合には、手作業でモデル構築する必要があるため、大変な労力を要している。橋梁 3 次元 Digital twin が構築されていれば、3 次元空間での現象を 3 次元モデル内で検討するという自然かつ本質的なアプローチが可能となり、また 3 次元 FEM 解析への接続も容易になる。つまり橋梁 3 次元 Digital twin は、橋梁維持管理の新たな学術的基盤となり、また実務の課題解決や生産性向上に繋がることが期待できる。

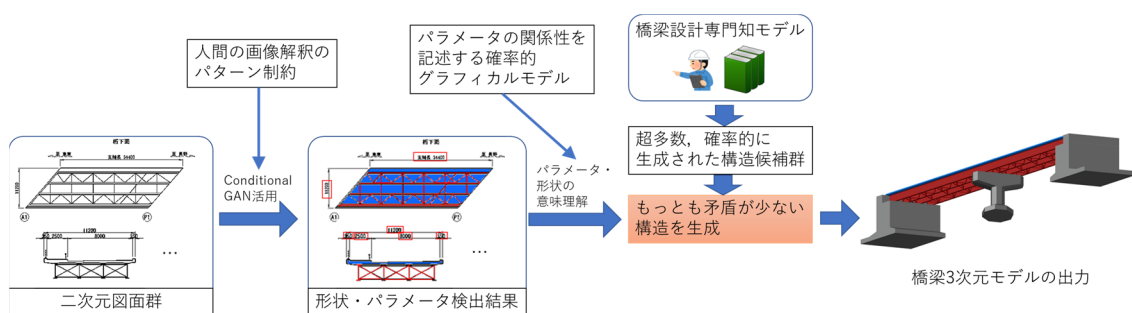


図ー1 PLATEAUで台東区と墨田区を表示した様子

2. 研究内容

2. 1. 概要

本研究の全体像を以下の図ー2に示す。



図ー2 図面からの三次元形状復元手法の全体像

まず二次元図面群から、形状およびパラメータの抽出を行う手法を構築する。本研究が最終的に目指すのは中小橋梁を含む全国の橋梁の3次元形状復元という点を踏まえ、もっともデータが揃っている、点検調書内に含まれる図面を活用することとした。図面の例を図ー3に示す。

この図面は非常にシンプルであるが、ここから形状を抜き出すのは容易な話ではない。例えば古典的な画像解析技術であるハフ変換などを活用した抽出を最初に試みたがうまくいかなかった。ハフ変換は直線を抽出する技術であるが、例えば形状抽出のために最も重要な最外縁の直線を抜き出そうとしても、判別には複雑なルール設定が必要であり、しかもそれでも例外が発生してしまう。例えば寸法線などを最外縁として拾ってしまうケースなどが挙げられる。

図面は極端な話、人間に理解できればよいため、必ずしも厳密な作成ルールには則っておらず、専門知を基本とした経験則で理解出来るように作成されている。それを踏まえれば、上記のハフ変換を中心とした手法のような、ルールベースの方法論とは相性がよくない。そこで本研究では、Deep learning 手法を活用した形状抽出を行うこととした。Deep learning の、教師データをもとにして学習するという性質は、あたかも人間が経験を積んでいく過程と類似であり、上記のような図面には相性がよいということを見出した。特に本研究では、pix2pixHD という画像生成手法をもとにした新たな Deep neural net を開発し、その適用を行うことで形状を抽出した。

また、図面から寸法などの数字を読み取ることも重要となる。これは基本的には OCR の範疇となるが、寸法線と数字が重なっていることも多いなど、簡単な話ではない。本研究では、オープンソースの OCR エンジンである Tesseract OCR を導入し、自前のデータを加え学習することで、着実に数字を抽出できることを見出した。

ここまで述べた図面からの形状・パラメータ抽出の詳細については、2.2 で詳しく述べる。


次いで、抽出したパラメータの理解が必要である。例えば仮に上記の OCR により 10250 という数字が抽出されても、この数字が意味するところが何かわからなければ役に立たない。本研究では、RDF を活用した、パラメータ理解アルゴリズムを新たに提案する。これにより、人間が定めたルールをもとに、パラメータの理解ができるようになった。これについては 2.3 で述べる。

ただ、形状が抽出でき、またパラメータの意味を理解できても、3次元形状の復元は容易ではない。それは、もともと扱う図面が、基本的に点検結果の理解に必要な情報のみが抽出されているため、3次元モデルの復元という観点では情報が不完備であるためである。これらについて補完する必要がある。本研究では、橋長などの基本諸元や橋梁形式情報（これらは構造化されたデータとして入手可能と想定される）から、想定される3次元モデルを超多数生成し、その中から抽出した形状・パラメータにもっとも合うのはどれか？という観点から3次元モデルを選択するという方法論を提示する。当然、必ずしも正確なものになることは想定されにくいだが、無理のない、自然な3次元モデルが出来ることは期待される。また、この方法論であれば、例えば新たなパラメータを得ることが出来ればそれとマッチするように更新することも可能である。あるいは、人間により、どうしても修正したいパラメータを後続で与えれば、それに従い更新される。この方法論については、RC-T を対象として復

元を試みた。また、IFC モデルへの変換や FEM モデルへの変換も行い、そして実際に解析をした。その事例について 2.4 で示す。

2. 2. 形状復元

本手法では、点検調書に記載されるような橋梁の簡易図面からの形状復元を行う。目標とするのは以下のような変換である。



図－3 目標とする形状抽出

それぞれ、側面図からは橋台と桁をそれぞれ水色と青色で、平面図からは床版上面と下面をそれぞれ赤色（図－3には存在していない）と緑色に、断面図からは床版と横桁をそれぞれ黄色と紫色で抽出する。こうすることで、3次元モデルの候補を絞ることが可能となる。

このような変換に、本研究では pix2pixHD をベースとし、モデル改良することで実現を目指した。pix2pixHD¹⁾は、Ting-Chun Wang et al.によって2018年に提案された画像変換モデルである。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ラベルのペアを十分に用意し、それらを教師データとして pix2pixHD に学習させることで、入力画像に対して似た特徴をもつ新たな画像が出力される。ベースとなる pix2pix²⁾は汎用的かつシンプルな画像変換モデルであるが、256px×256px の画像しか扱えないため、本解析では 2048px×1024px までの高解像度な画像を扱える pix2pixHD をベースとして使用した。本章ではまず、画像変換モデルの元となった GANs³⁾の仕組みについて説明し、その後 pix2pixHD の仕組みと本研究における使用方法について説明する。

GANs

GANs は、Ian J Goodfellow et al.によって 2014 年に提案された画像変換モデルの一種である。入力された画像の特徴を学習することで、その特徴に沿った新たな画像を出力することができる。このモデルが提唱されるまでは、画像変換に深層学習を用いていい成果を上げた例はなかった。しかし、このモデルは画像生成モデルと画像識別モデルを競わせて交互に学習させる仕組みを導入したことで、画像分類などの他のタスクと同様に、モデルを誤差逆伝播法とドロップアウトのみで学習させることを可能にした。また、その結果として本物らしい画像が出力されるようになった。現在、この手法を参考に様々な画像変換モデルが提唱されており、今後の発展が期待されている。

ここで、モデルの大まかな学習の流れについて説明する。生成モデル G (Generator) 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。それに対して識別モデル D (Discriminator) 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。

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

pix2pix

pix2pix は、Phillip Isola et al.によって 2017 年に提案された画像変換モデルの一種である。GANs を参考にしたモデルだが、入力画像の他に正解ラベルを入力しており、出力画像は正解ラベルに近い特徴を持った画像であることが期待される。また、構造を改良したことで、様々な画像変換に対応できる汎用的なモデルとなっている。pix2pix の学習の流れは図-4 の通りである。図中の y は正解ラベルを示している。

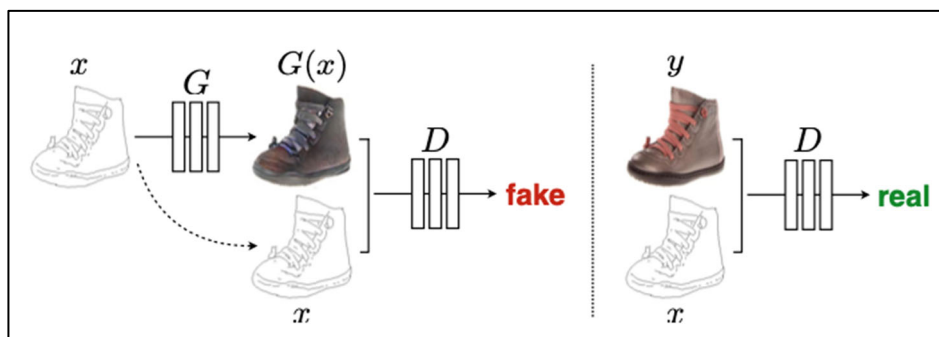


図-4 pix2pix の学習の流れ

また、本研究の図面に合わせたものを図-5 に示す。

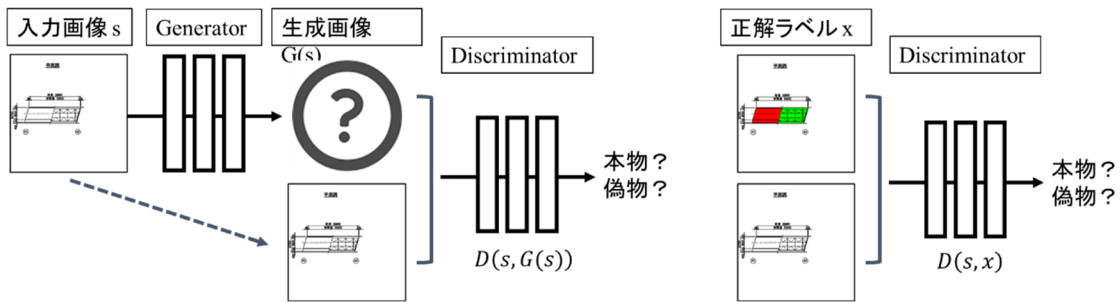


図-5 本研究の図面での pix2pix の学習の流れ

学習の流れ自体は、正解ラベルが追加されたことを除き GANs と変わらない。まこのモデルを用いても本解析を短時間で実行可能であることは実証済みだが、このモデルは $256\text{px} \times 256\text{px}$ の画像しか扱うことが出来ない。設計図は大きいもので 3000px ほどあることを考慮し、本解析では改良版である pix2pixHD を使用することとした。

pix2pixHD

pix2pixHD は pix2pix をベースとしており、 G や D 、損失関数を改善したことで $2048\text{px} \times 1024\text{px}$ までの高解像度な画像を扱うことが可能となっている。pix2pixHD の学習の流れは図-6 の通りである。pix2pixHD では、pix2pix から以下の3点の改良がなされている。

(a) Coarse-to-fine generator

図-6 に示すように、生成モデル G を G_1 ("global generator network") と G_2 ("local enhanced network") に分割している。学習の流れとしては、まず G_1 のみを入力画像の解像度で学習する。その後、 G_2 を G_1 の両端に連結させ、解像度を両辺2倍にしてモデル全体を再び学習させる。この際、 G_1 のみの学習で得られた特徴マップも使用する。なお、この構造は $512\text{px} \times 512\text{px}$ までの画像変換において良い精度を残した Johnson et al.の研究を参考にしている⁴⁾。

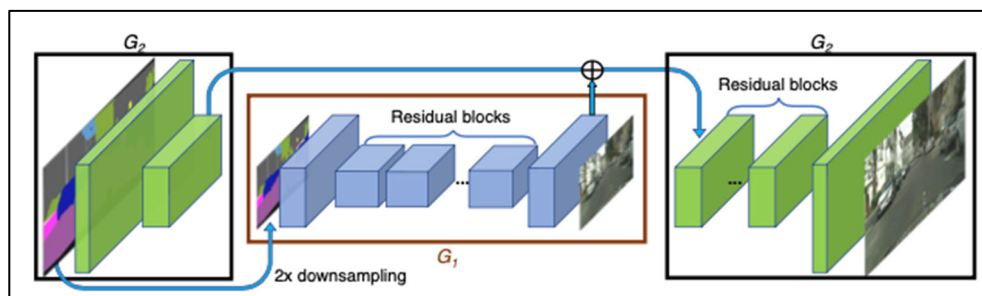


図-6 pix2pixHD の学習の流れ

(b) Multi-scale discriminator

高解像度な生成画像と本物画像を小さいネットワークで識別するために、3つの識別モデルを用意し、それぞれが異なる解像度で画像を識別する。具体的には、入力画像の解像度で識別する $D_1 \cdot 1/2$ 倍の解像度で識別する $D_2 \cdot 1/4$ の解像度で識別する D_3 に分割される。そのため、式(1)を \mathcal{L}_{GAN} と表記した時に、pix2pixHDにおける G と D の学習は式(2)のように表される。

$$\min_G \max_{D_1, D_2, D_3} \sum_{k=1,2,3} \mathcal{L}_{GAN}(G, D_k) \quad (2)$$

(c) 損失関数の改善

式(2)も損失関数の改善の一環であるが、それに加えて **feature matching loss**⁴⁾を導入している。これは、生成モデルが様々な解像度において本物らしい画像を生成することを目的とした関数で、識別モデルの複数の層から特徴マップを抽出し、本物の画像の特徴マップと生成画像の特徴マップがなるべく一致するようにする関数である。これを式で示したのが式(3)である。なお、 $D_k^{(i)}$ は識別モデル D_k の i 層から抽出された特徴マップ、 T は識別モデルの層の数、 N_i は各層の要素数の合計を示している。

$$\mathcal{L}_{FM}(G, D_k) = \mathbb{E}_{(s,x)} \sum_{i=1}^T \frac{1}{N_i} \left[\left\| D_k^{(i)}(s, x) - D_k^{(i)}(s, G(s)) \right\|_1 \right] \quad (3)$$

本研究で加えた改良

pix2pixHDのコードはGitHubにおいて公開されている⁵⁾。しかし、特に変更せずに本解析に使用すると、おそらくは生成モデルの解像度が高すぎるため、意図したような出力画像は生成されなかった。そこで前項の改善点に対して、以下のような変更を行った。

まず、生成モデルを分割しないこととした。また、識別モデルに関しても2分割とし、 $D_1 \cdot D_2$ のみで識別させた。最後に、pix2pixHDはセマンティックラベルを用いた画像変換を主に対象にしており、そのための工夫もいくつか準備されている。しかし、本解析には関係がないため全て機能させないように改良した。その結果としての本研究のネットワーク図を図-7に示す。ただし、巨大なモデルのため、4ページに渡って掲載する。

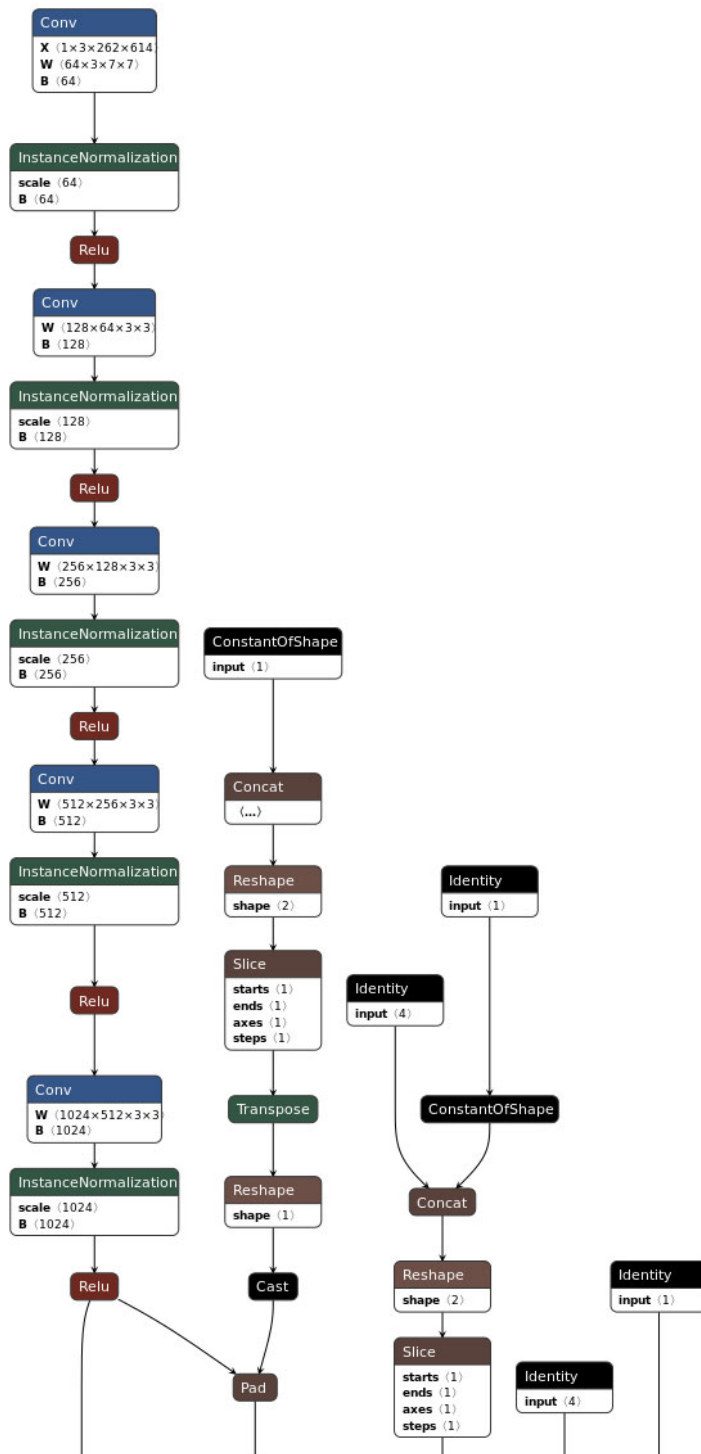


図-7 構築したモデルのネットワーク図 (下に続く)

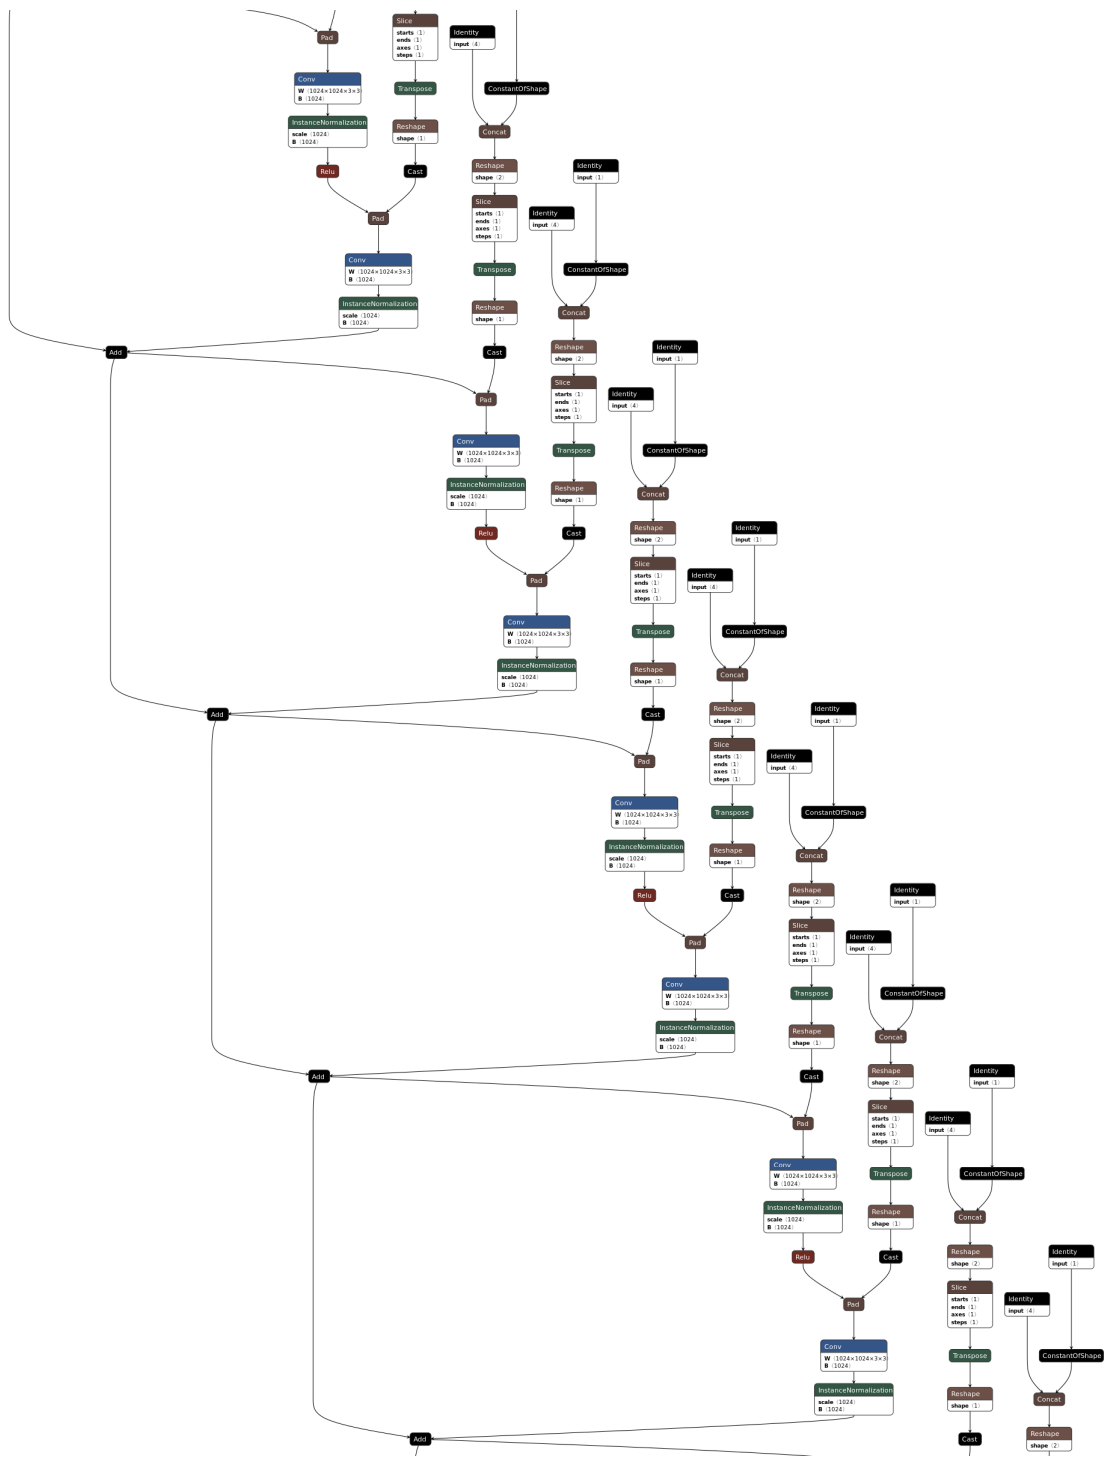


図-7 構築したモデルのネットワーク図（上から続いており、また下に続く）

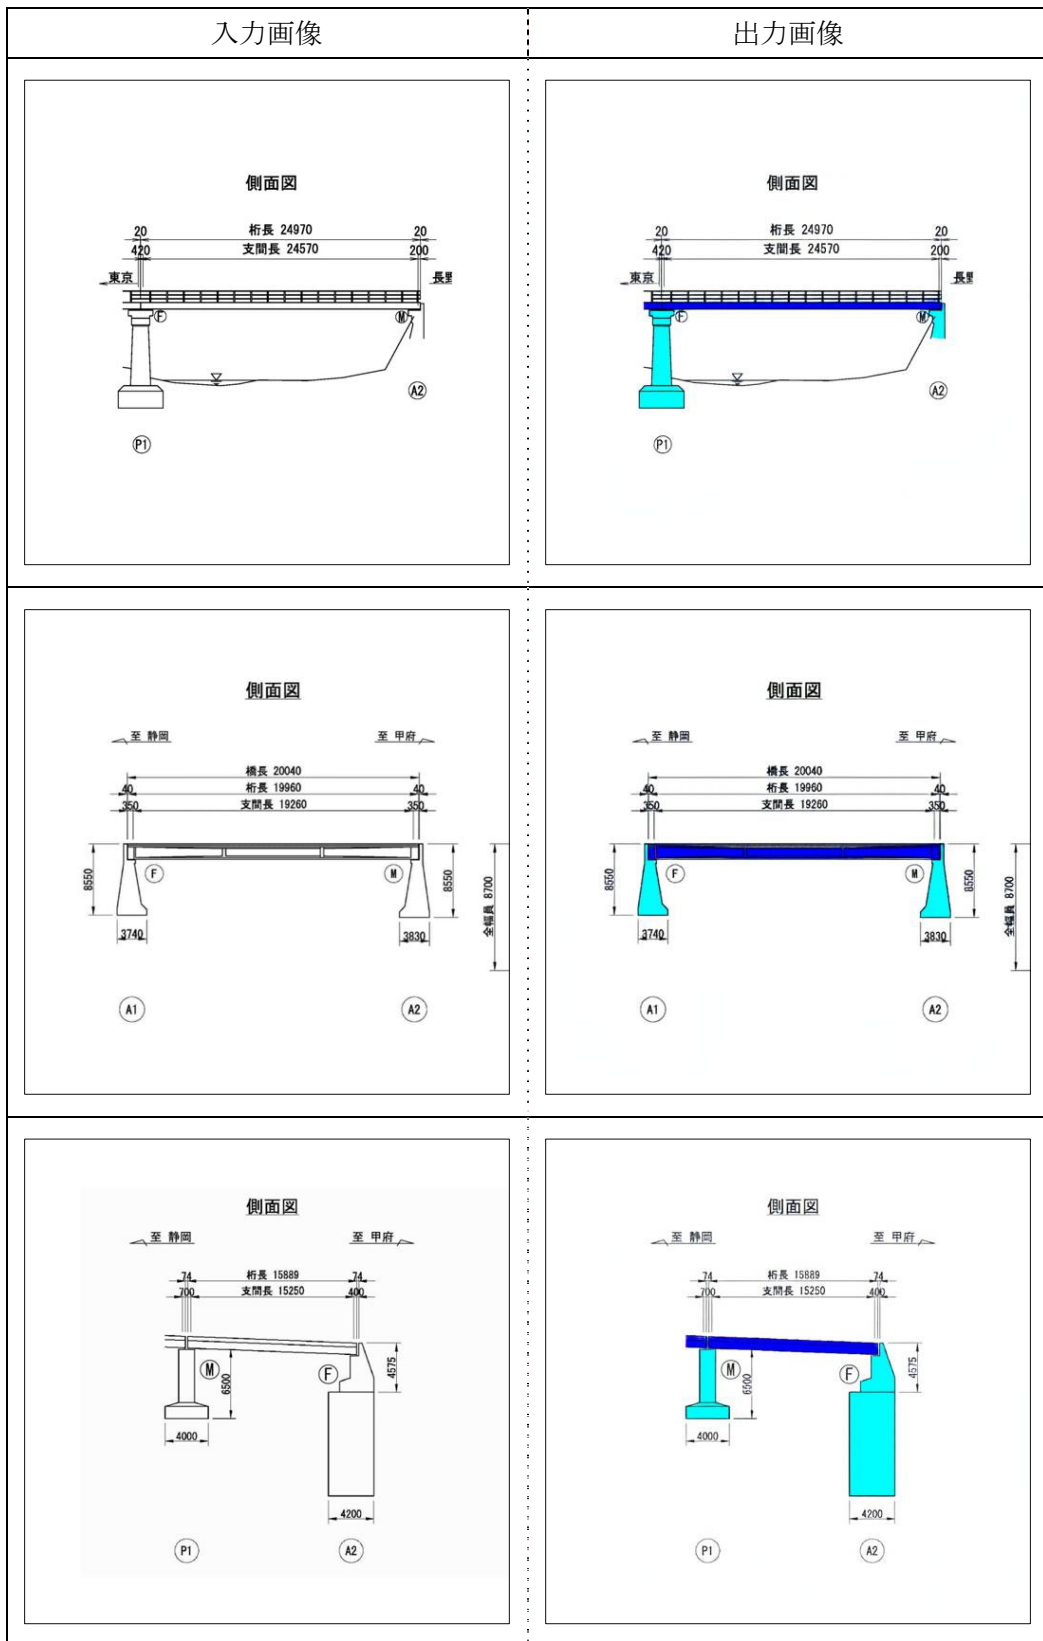
学習と解析

このモデルの学習を進めることとした。学習にあたっては、train & validation に用いる画像と、精度検証のための test に用いる画像に分けることとした。これは、学習に用いた画像を用いてテストをすると精度が必要以上に向上してしまうためである。側面図、平面図、断面図のそれぞれについて、学習に用いた枚数とその内訳を以下に示す。また、計算時間についても示してある。計算速度は GPU に強く依存するが、本研究では NVIDIA Tesla T4 を用い、500 epoch 計算した。

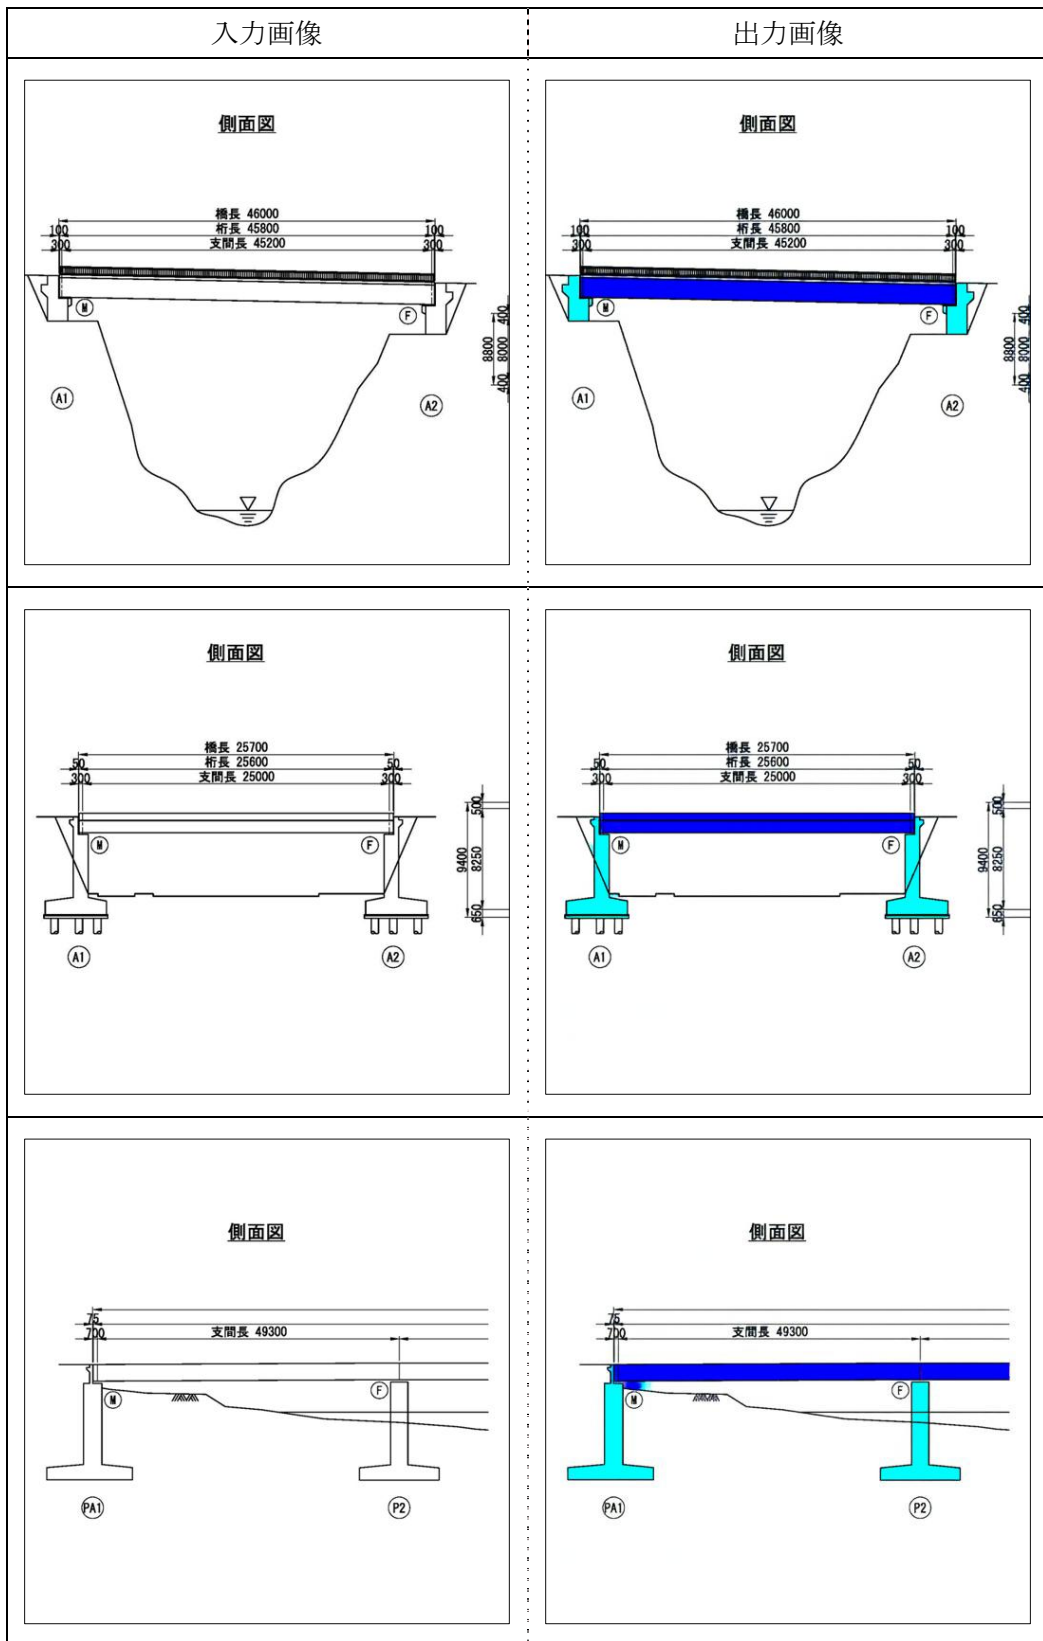
表-1 学習に用いた枚数と、その内訳

	側面図:342枚	平面図:834枚	断面図:585枚
trainの枚数	273枚	667枚	468枚
testの枚数	69枚	167枚	117枚
1epochsあたりの時間	70秒前後	165秒前後	115秒前後
変換成功数*(割合)	41枚/69枚(59.4%)	126枚/167枚(75.4%)	78枚/117枚(66.7%)

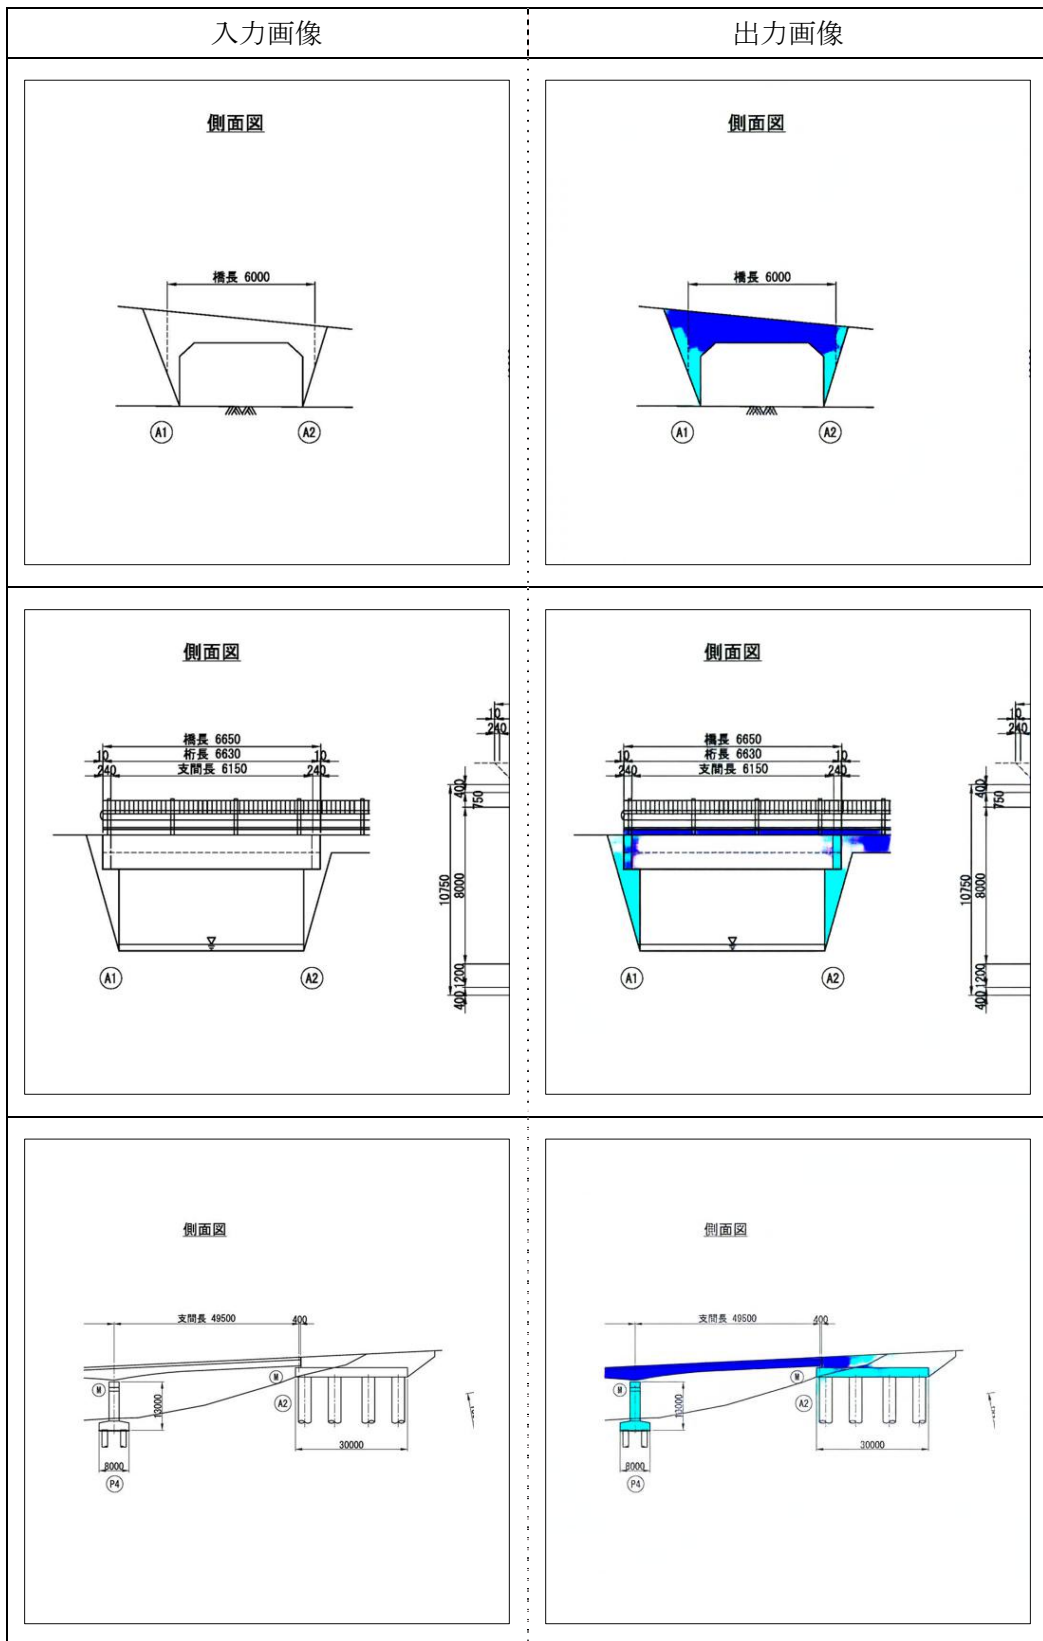
そして、完成したモデルをもとに解析を行った。側面図、平面図、断面図のそれぞれについて、正解例と不正解例を以下の図に示す。



(a) 側面図の解析結果 (正解例その1)

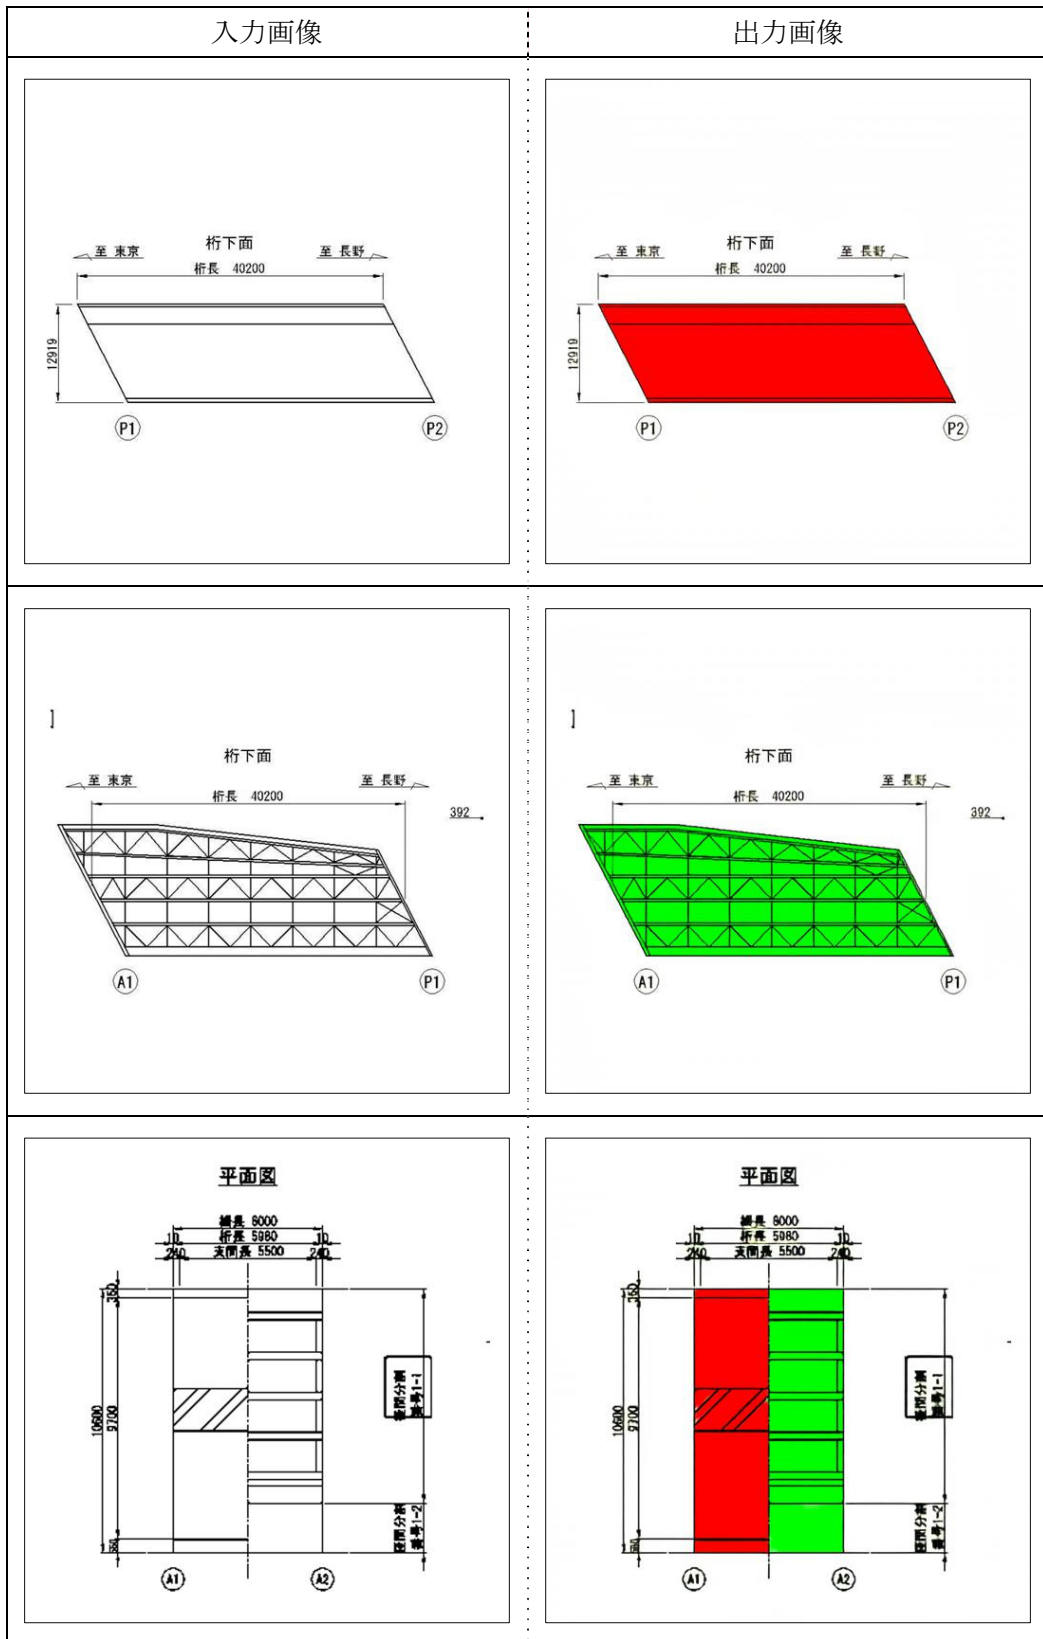


(b) 側面図の解析結果 (正解例その2)

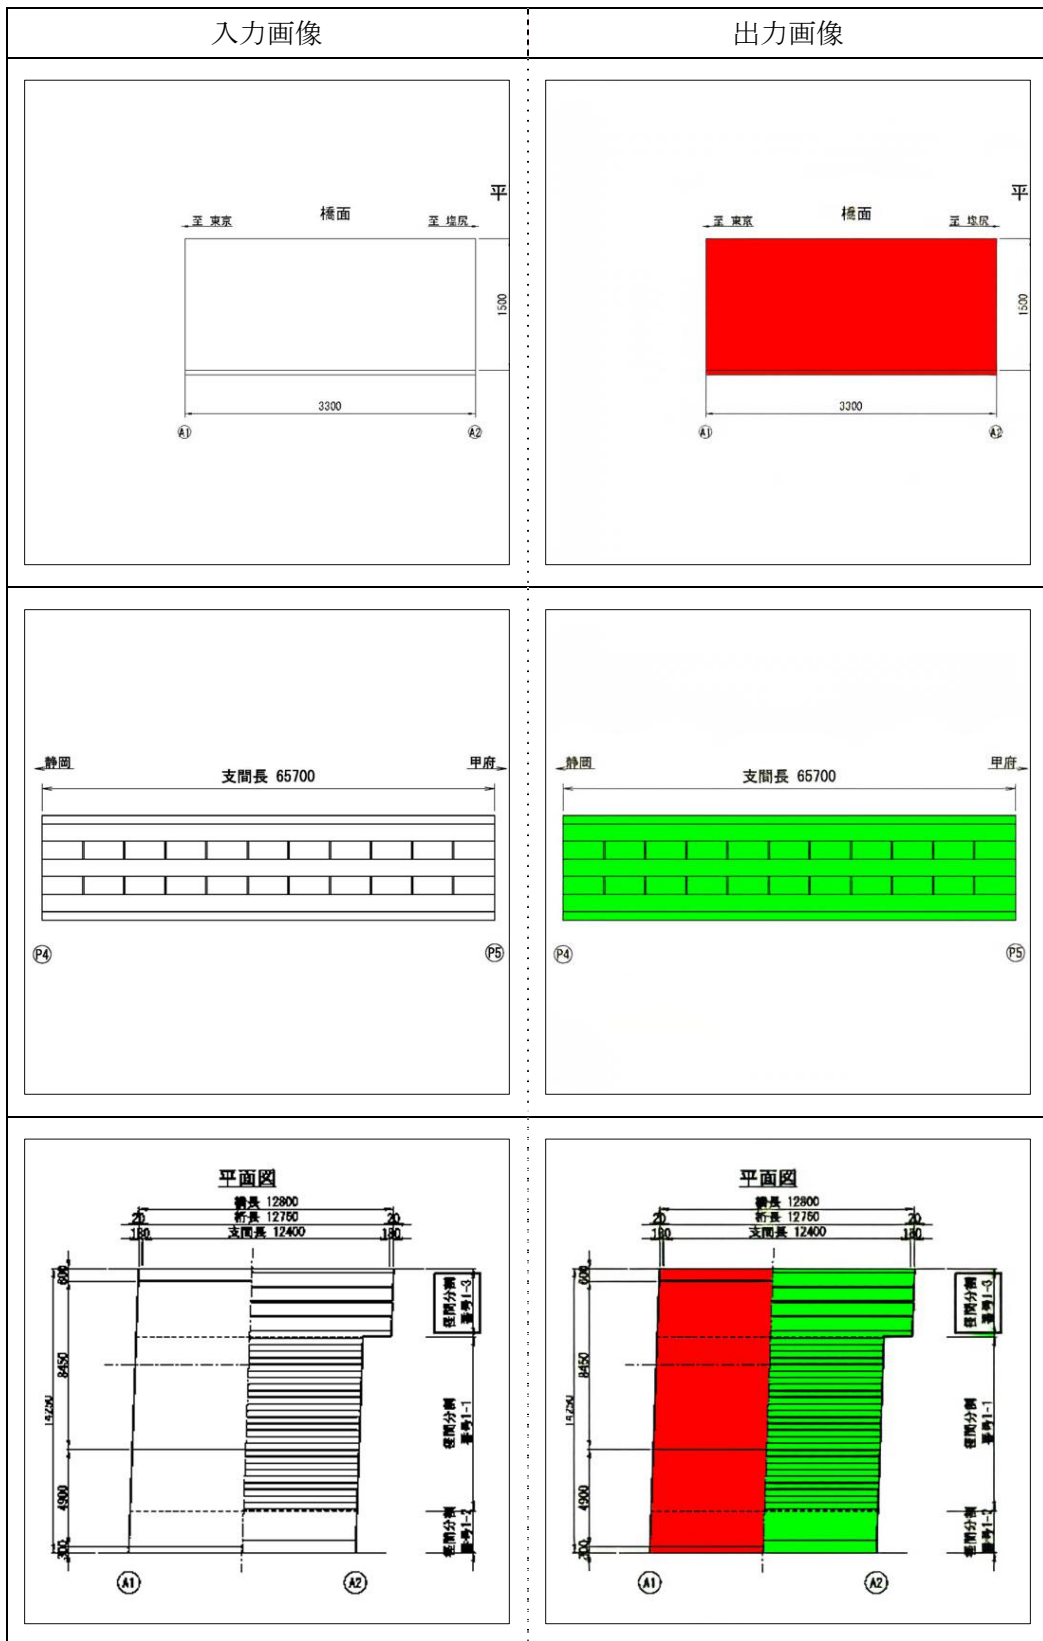


(c) 側面図の解析結果 (不正解例)

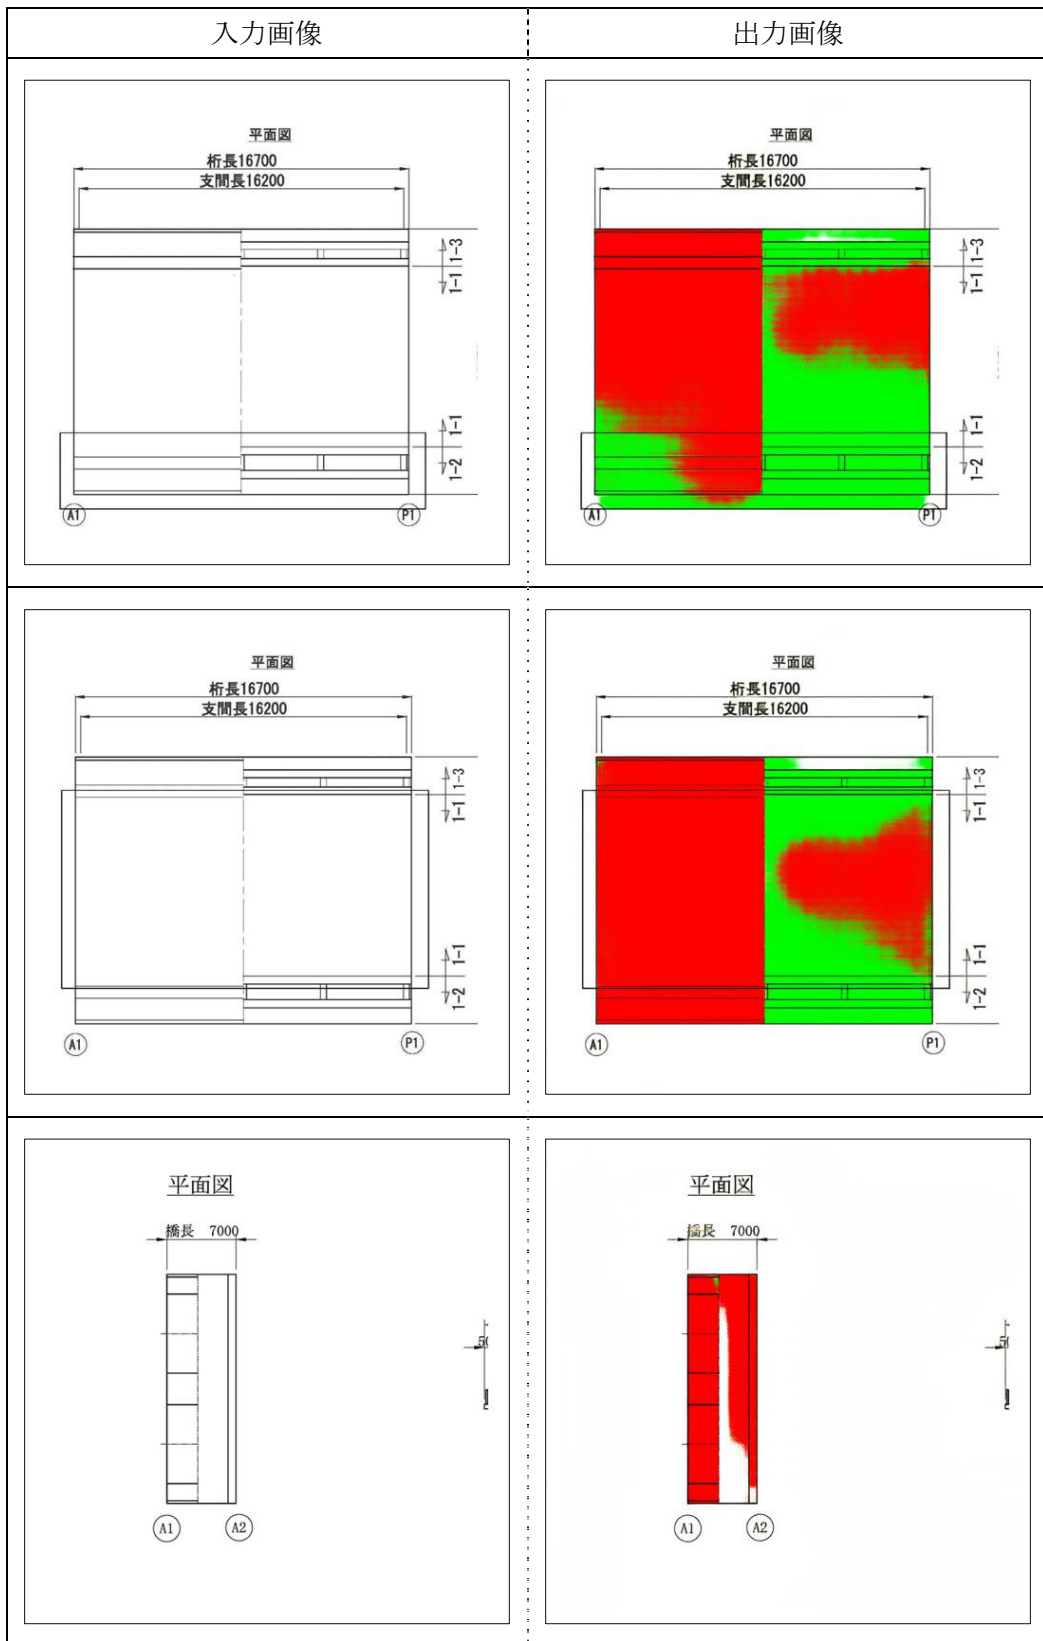
図-8 側面図の解析結果



(a) 平面図の解析結果 (正解例その1)

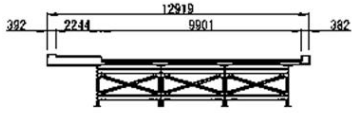
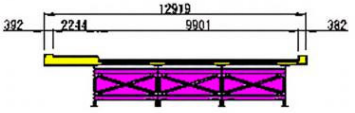
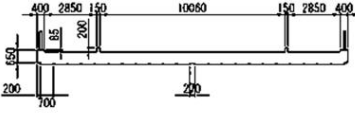
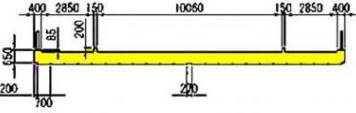
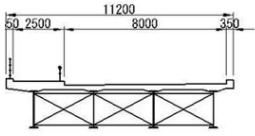
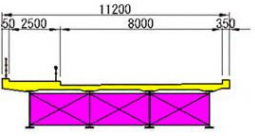


(b) 平面図の解析結果 (正解例その2)



(c) 平面図の解析結果 (不正解例)

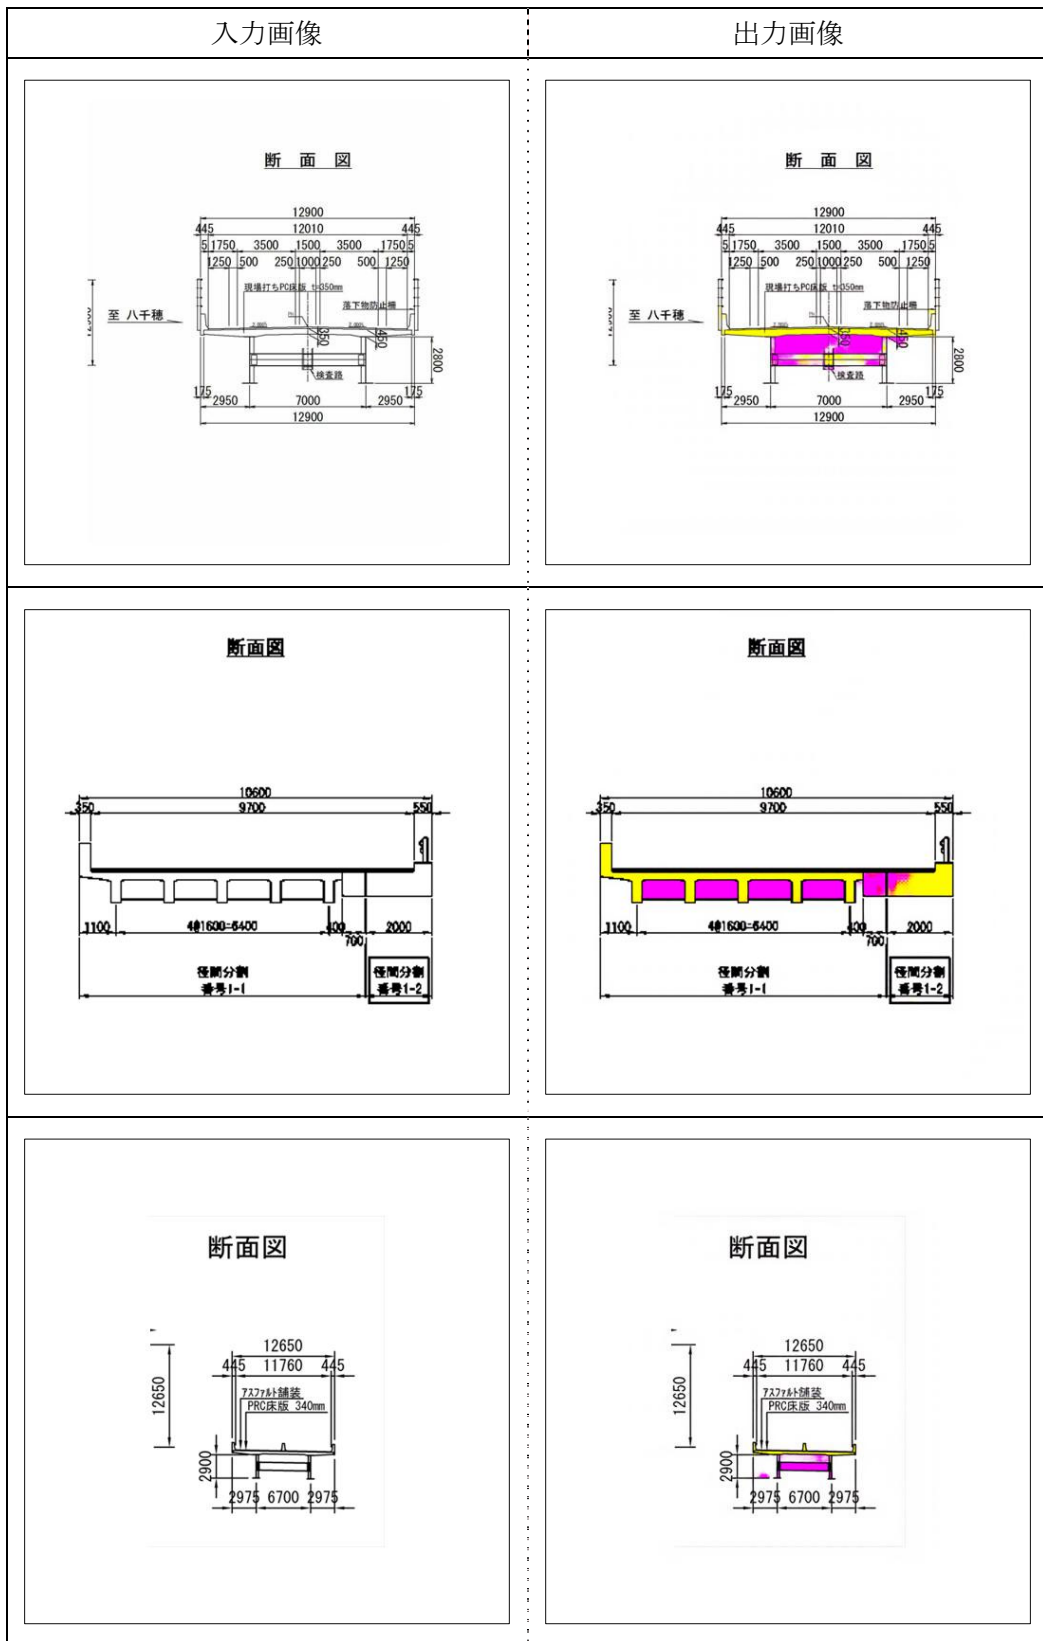
図-9 平面図の解析結果

入力画像	出力画像
<p style="text-align: center;">断面図</p> 	<p style="text-align: center;">断面図</p> 
<p style="text-align: center;">断面図</p> 	<p style="text-align: center;">断面図</p> 
<p style="text-align: center;">断面図</p> 	<p style="text-align: center;">断面図</p> 

(a) 断面図の解析結果 (正解例その1)

入力画像	出力画像
<p style="text-align: center;">断面図</p>	<p style="text-align: center;">断面図</p>
<p style="text-align: center;">断面図</p>	<p style="text-align: center;">断面図</p>
<p style="text-align: center;">断面図</p>	<p style="text-align: center;">断面図</p>

(b) 断面図の解析結果 (正解例その2)



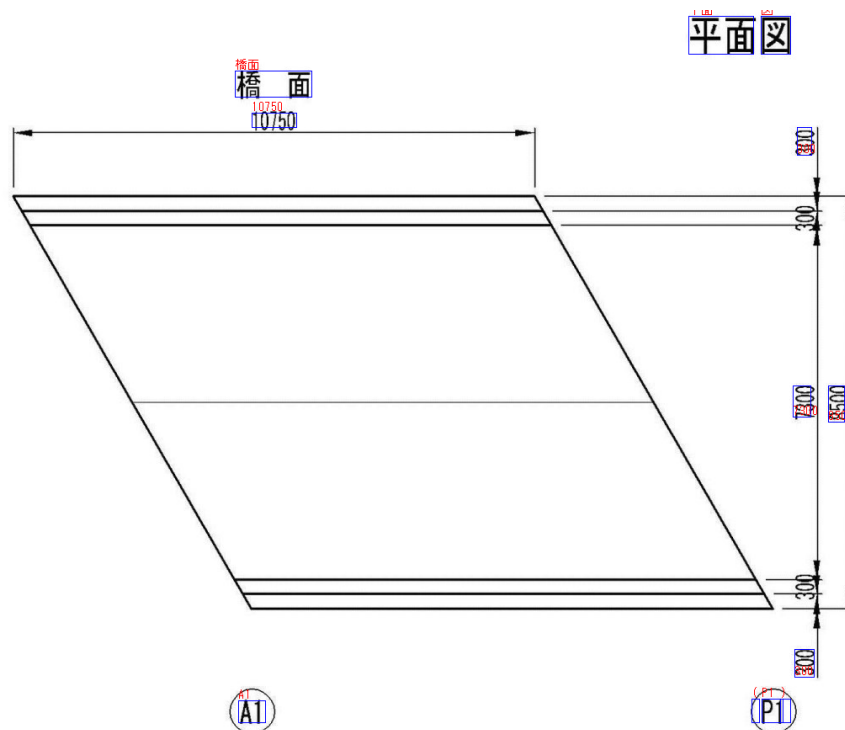
(c) 断面図の解析結果 (不正解例)


図-10 断面図の解析結果

ここまで示したように、6割～7割前後の割合で適切に復元できている。よく出るタイプの図面は容易に復元できているが、パターンが少ないものは不正解となっている。つまり今後、そういったパターンの少ない図面タイプについてもカバーできるように、学習データを増加させれば精度は飛躍的に向上すると考えている。そのための方法論として、図面データと教師データを自動生成することを視野に入れている。

2. 3. 寸法の読み取りと理解

前節では形状の抽出を行ったが、図面内に書かれた数字の抽出と理解も、3次元モデル構築のためには同時に必要となる。基本的に、図面内に文字情報が画像として埋め込まれているだけなので、OCR (Optical Character Recognition) 処理が必要となる。そこで本研究では、オープンソース OCR エンジンの1つである Tesseract OCR を用いた。Tesseract OCR は日本語にも対応しており、また更に点検調書記載の数字を使って追加学習も行った。また、横倒し文字は精度が低下するので、90度、-90度回転を行い検出できた結果も融合した。結果例を以下の図-11に示す。一部検出できていない数字があるものの、概ね検出できている。また、例えば Google Cloud Platform や Amazon web service などでも高性能 OCR を提供しており、これらとアンサンブル的に組み合わせることでより精度を高めることも考えられる。





断面図




図-11 OCRの読み取り結果

しかし、ここで数字や文字を読み込んでも、それらが持つ意味を明らかにする必要がある。ただし、数字をどう書くかというのは形状同様ルール化されているわけではなく、人間の経験知、専門知をもとに理解するという前提である。そこで、ここでは人間の常識をルールとして含めることで自動でAIに理解させる。例えば、以下のようなルールを与えている。

- 平面図
 - 幅員方向の寸法はほぼ縦書き
 - 橋軸方向の寸法はほぼ横書き
 - 幅員は〇〇以上（他情報からの取得）
 - 橋長は〇〇以上（他情報からの取得）

- 断面図
 - 幅員方向の寸法はほぼ横書き
 - 平面図の幅員と同じ数字であれば幅員である可能性が高い

このように、人間の常識を組み込む手法を提示した。このルールをアルゴリズムに与えるために、RDF(Resource Description Framework)をベースとした手法を提示する。RDFは情報についての情報（メタ情報/メタデータ）を表記するための汎用的な手法を定めたデータ形式の一つである。RDFで基本となるデータ構造は「トリプル」(triple)と呼ばれる3つのデータの組で、主語 (subject)、述語 (predicate)、目的語 (object) を組み合わせて「○○ (主語) の×× (述語) は△△ (目的語) である」という関係性を記述する（自然言語文法における主語・述語・目的語とは若干異なる）⁶⁾。Web ページの情報を表現することによく用いられている手法である。例えば例を図-12に示す。



図-12 RDF グラフの例⁷⁾

ここでもそのように、トリプルを与える。例えば以下のような形である。

- 主語-述語-目的語の triple
 - 橋長-値範囲-{2000, 30000}
 - 床版厚-文字方向-縦書き
 - 橋長-大きい-幅員

これを必要な数だけ提示することで、もっともこのルールに当てはまる組み合わせを出すような枠組みを提案した。その結果、現状では橋長や幅員、桁の幅については読めるようになった。

2. 4. 変換および解析

ここでは、上記の2.2, 2.3で得られた形状やパラメータから、3次元モデルを復元する方法論を提示する。ここで、形状が抽出でき、またパラメータの意味を理解できても、3次元形状の復元は容易ではないという課題を解決する必要がある。もともとの図面が、人間が専門知や経験知をもとに点検結果を理解するのに必要な情報のみが記載されているため、3次元モデルの自動構築という観点では情報が不完備であるためである。そこで、自動

構築のためには、これらについて補完する方法論を開発する必要がある。

本研究では、橋長などの基本諸元や橋梁形式情報から、想定される3次元モデルを超多数生成し、その中から抽出した形状・パラメータにもっとも合う3次元モデルを選択するという方法論を提示する。当然、必ずしも正確なものになることは想定されにくい、無理のない、自然な3次元モデルが出来ることは期待される。また、この方法論であれば、例えば新たなパラメータを得ることが出来ればそれとマッチするように更新することも可能である。あるいは、人間により、どうしても修正したいパラメータを後続で与えれば、それに従い更新される。この方法論については、RC-Tを対象として復元を試みた。

例えば幅員5.5mの2等橋でRC-Tの場合、支間長や主桁本数などの代表的なパラメータは以下の図-13のように整理される。

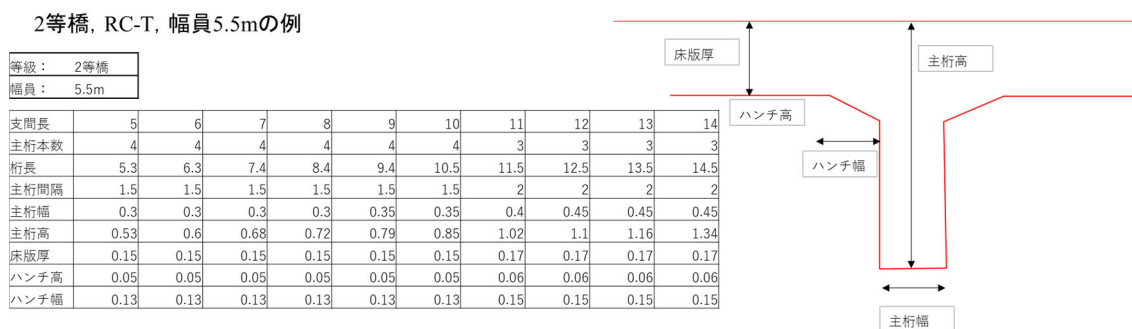


図-13 2等橋, RC-T, 幅員5.5mを例とした形状の例

図-11の図面について、RC-Tのモデルを参考に、商用有限要素解析パッケージであるAbaqusのinputファイルを自動生成した結果を以下の図-14に示す。





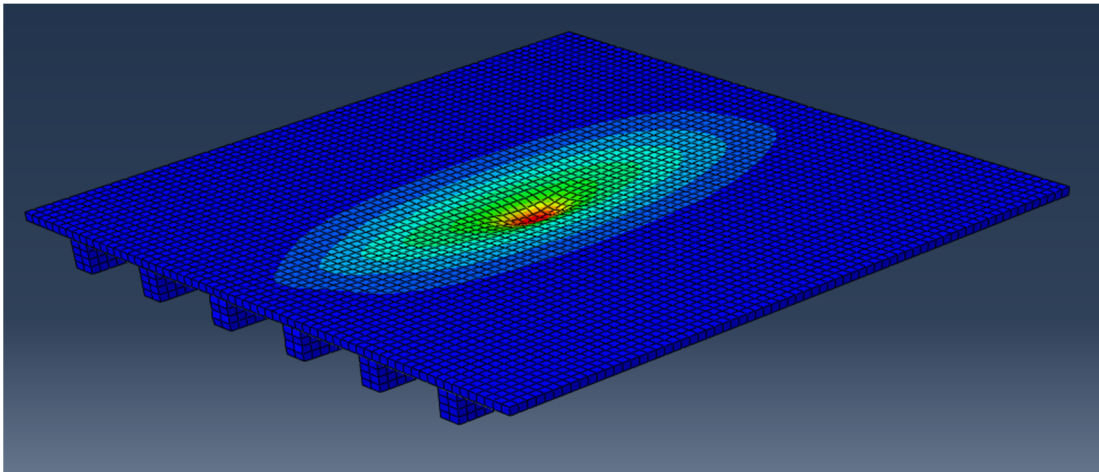
図-14 FEMモデル作成例

ただし、材料定数は一般的なコンクリートの材料定数である、ヤング率 $E=23\text{GPa}$ 、ポアソン比 $\nu=0.17$ を与えている。要素は、一般的な六面体要素である C3D8R (8 節点低減積分要素) を用いた。また、境界条件は今回のモデル化では行っておらず、とりあえず単純支持とした。

そして、外力のモデル化も今回の研究の対象外であるが、実際に FEM 解析が回ることを示すために、橋梁中央に集中荷重を与えて解析を行った。その結果を以下の図-15 に示す。



(a) 応力のコンター図



(b) 変位のコンター図

図-15 FEM 解析例 (解析が回ることを示すだけが目的なので凡例は除いている)

このように、FEM モデルの構築がシームレスに可能となっている。また、IFC モデルについても同様に構築を行った。あくまでも 3 次元情報を与えるだけなので、材料定数などは (当然ながら) 一般的な値でしか与えられないが、3 次元形状の復元を行い、一般的な IFC リーダーの一つである Open IFC Viewer で表示した結果を以下の図-16 に示す。




図-16 IFCモデルをOpen IFC Viewerで表示した結果

このように、適切に復元できる事例を示した。まだ現状は萌芽的な段階であり、例えば横桁の再現などはできていないが、この方向で研究を進めれば検出可能と見込まれることを示すことができた。

3. まとめ

本研究では、橋梁構造物を対象とし、その2次元図面を読み込み、記載されている詳細な

寸法や形状、表、単語の意味を理解した上で、3次元FEMモデルやCIMモデルを自動で構築するAIの研究開発を目的とし、以下の研究開発を進めた。

- ・ Deep learning による図面からの形状復元手法
- ・ OCRによる寸法読み取りと、RDFを活用した理解
- ・ 得られた形状・寸法から3次元復元を行う方法論

その結果、形状復元手法や寸法読み取りについては一定程度実現でき、理解や3次元復元についてはまだコンセプトを示して復元事例を1つ示しただけなもの、今後の方向性や実現可能性を示すことができた。

今後の研究の展開は種々挙げられるが、例えば以下の4点が挙げられる。

- ・ 形状復元手法の精度向上。現在は実際の図面にアノテーションを行っているが、図面作成からアノテーションまでを自動化することで、数桁違うオーダーの学習が可能となり、精度の大幅な向上が期待できる。
- ・ RC-T以外への拡張（例えば橋梁数が多いものであれば、鋼橋やPCホロー橋、床版橋などが挙げられる）
- ・ 点群の活用。近年点群の3次元セグメンテーション技術などが進化しており、図面だけでなく点群からも結果が得られるようになることが期待される。
- ・ AI復元設計により、鉄筋位置を推定することで、外部形状だけでなく鉄筋量や位置の尤もらしい推定が可能となることが期待できる。

これらの実現により、簡単な図面からの橋梁3次元モデルの復元が可能となれば、日本全国の3次元デジタルツインの実現に大きく寄与できると考えられ、また本研究でそのための方法論を示すことができた。

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, 2018.
- 2) Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, Alexei A. Efros : Image-to-Image Translation with Conditional Adversarial Networks, CVPR, 2017.
- 3) Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, Yoshua Bengio : Generative Adversarial Nets, NIPS'2014, pp. 2672-2680, 2014.
- 4) J. Johnson, A. Alahi, and L. Fei-Fei. Perceptual losses for real-time style transfer and super-resolution. In *European Conference on Computer Vision (ECCV)*, 2016.
- 5) GitHub, <https://github.com/NVIDIA/pix2pixHD>, 2022/11/13.
- 6) IT用語時点, <https://e-words.jp/w/RDF.html>, 2022/11/13.
- 7) Wikipedia, https://ja.wikipedia.org/wiki/Resource_Description_Framework, 2022/11/13.