

# 組合せ最適化と機械学習の併用による曖昧さを含む三面図からの三次元再構成の基礎検討

○林祐作 小野智司 (鹿児島大学)

## A Preliminary Study on 3D Reconstruction from Orthographic Views including Ambiguity Using Combinatorial Optimization and Machine Learning

\*Yusaku Hayashi and Satoshi Ono (Kagoshima University)

**Abstract**— 3D Computer Aided Design (CAD) system is mainly used in the field of manufacturing, production and design, 2D drawing is still necessary as a guide for manufacture and assembly of products. Many studies have been conducted for a 3D model reconstruction problem from 2D engineering drawings; however, due to ambiguity of 2D drawings, it has not been completely solved, and many companies still outsource the reconstruction to CAD operators. This study proposes a 3D reconstruction method using combinatorial optimization and machine learning with the aim of resolving the ambiguity. Experiments with some example models have shown the possibility of the proposed method to resolve the ambiguity in 3D reconstruction.

**Key Words:** 3D reconstruction, Understanding engineering drawings, Combinatorial optimization, Machine learning, Satisfiability problem

### 1 はじめに

3DCAD の普及や、国土交通省による CIM (Construction Information Modeling/Management) の導入推進により、現在、建設業や製造業では主に 3 次元モデルが使用されている。一方、2 次元図面は製品の製造や組み立てを指導するための設計文書として用いられており、2 次元図面の 3 次元化作業が未だ必要とされている。三面図等の 2 次元図面を 3 次元化 (Fig. 1) するため、市場には多くのソフトウェアがリリースされている。しかし、これらのツールは多くのユーザーインターアクションを必要とし、3 次元化作業をわずかに短縮するだけであるため、多くの企業が 2 次元図面の 3 次元再構成を CAD オペレータに委託している。

2 次元図面の 3 次元化は再構成問題として知られ、1973 年から 2005 年にかけて多くの研究が行われた<sup>1)</sup>。しかし、2 次元図面に集積された寸法や注釈などの情報を再構成後の 3 次元モデルへ適用することは困難であり、これらの情報を除いた正投影図から再構成を行うと曖昧さが生じ、構成する立体が一意に定まらないことがある。これまでに多くのアプローチが提案されているが、再構成問題は完全には解決していない<sup>2, 3, 4)</sup>。

本研究では、2 次元図面から 3 次元モデルへの再構成における曖昧さの解消を目的とし、組合せ最適化と機械学習を併用した再構成手法を提案する。提案手法では、最適化ベースの手法を用いて 2 次元図面から複数の 3 次元モデル候補に再構成し、その後、学習ベースの手法を用いて 3 次元モデルを 1 つに絞り込むことで、再構成における曖昧さを解消する。

### 2 2 次元図面の 3 次元再構成

#### 2.1 概要

再構成問題に対するアプローチの多くは Boundary Representation (B-rep) と Constructive Solid Geom-




Fig. 1: A problem of 3D reconstruction from 2D engineering drawings.

etry (CSG) の 2 つに分類される。B-rep アプローチは Idesawa<sup>5)</sup> によって最初に提案され、その後多くの再構成手法の基礎となった手法である<sup>6)</sup>。この手法は、2 次元図面から頂点、辺、面に対する幾何情報 (座標や数式) と位相情報 (接続関係) を取得し、これらのデータ構造をもとに立体を表現する。CSG アプローチは数式で表現されたプリミティブとよばれる基本形状の集合演算により立体を表現する手法であり、各プリミティブのブール演算とその出力立体を階層的に表すことによって、最終的に再構成される立体を表現する。

#### 2.2 再構成における曖昧さ

2 次元図面を用いて開発、設計を行う現場では、主に第三角法とよばれる投影法を用いて 3 次元形状を 2 次元図面で表現する。しかし、第三角法で作図された 2 次元図面のみでは表現できる 3 次元形状に制限があるため<sup>7)</sup>、寸法や注釈などの情報を 2 次元図面に追加することで曖昧さを排除している。

一方で、集積された寸法や注釈などの情報を機械に自動的に解釈させ、再構成後の 3 次元モデルへ適用することは困難であり、また、これらの情報を除いた正投影図であっても再構成では曖昧さが生じ、構成する

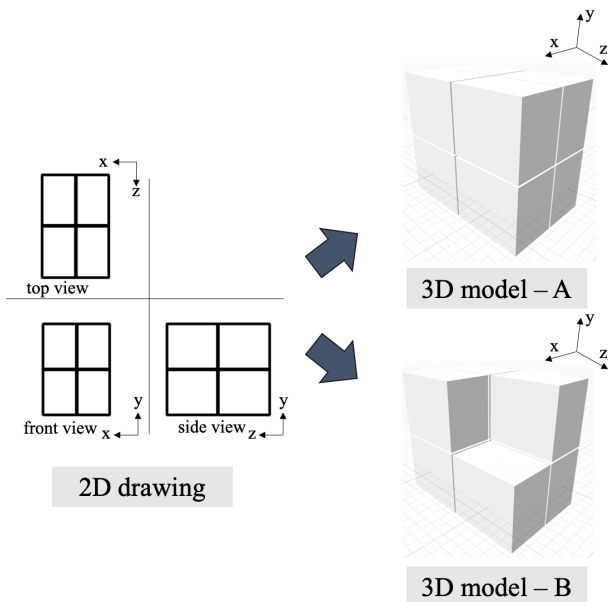


Fig. 2: Examples of 2D drawings with ambiguity.

立体が一意に定まらないことがある。

Fig. 2 に再構成における曖昧さの例を示す。再構成における曖昧さとは、2次元図面に複数通りの解釈が存在するケースであり、どの解釈が正しいかは分野や職種に依存する可能性がある。本研究では、再構成における曖昧さに着目し、学習ベースの手法を用いてこの曖昧さの解消を目指す。

### 2.3 関連研究

再構成問題に対するアプローチの中には、曖昧さの解消に焦点を当てた手法が提案されている。Lafue<sup>8),9)</sup> は B-rep ベースの手法にヒューリスティクスを導入し、頂点や辺、面の構築にルールを適用することで曖昧さの一部を解消する手法を提案した。

また、Furferi ら<sup>10)</sup> は 2次元図面からワイヤーフレームへの再構成を行う手法を提案した。この手法では、2次元図面から辺の中間頂点や共線性の検出を行うことで再構成時の曖昧さの解消を試みたが、再構成した立体を 1 つに絞り込めないという問題があった。

Governi ら<sup>11)</sup> は 2次元スキャン画像からソリッドモデルへの再構成を行う手法を提案した。この手法では、スキャンした手書き図面から点群データを生成することで自由形状にも対応した再構成を実現した。しかし、複雑な 2次元図面の曖昧さを解消するためには手動での単純化作業が必要であるという問題があった。

## 3 提案手法

### 3.1 概要

本研究では、組合せ最適化と機械学習を併用した再構成手法を提案する。提案手法の概要を Fig. 3 に示す。提案手法は、組合せ最適化を用いてサーフェスモデルを再構成し、複数の再構成案が存在する場合には学習ベースの手法を用いて 3次元モデルを絞り込むことで、再構成における曖昧さを解消する。

提案手法の特徴を以下に示す。

- 三面図に含まれる頂点や辺、面の幾何学的特徴を損なわないため、3DCAD データとして利用できる厳密なサーフェスモデルを再構成できる。
- 分野や職種による曖昧さが生じる 2次元図面であっても妥当な 3次元モデルを絞り込むことができる。

### 3.2 処理手順

#### 3.2.1 [Step 1] 2次元図面の頂点と辺の抽出

はじめに、2DCAD データ (DXF ファイル) から頂点や辺などの幾何学的特徴を抽出する。2次元図面の 3つの正投影ビュー ( $n=1,2,3$ ) は頂点の集合  $V^n$  と辺の集合  $E^n$  で構成される。各ビューはそれぞれ 2つの座標軸に対して平行であり、1つの座標は常に 0 である。例えば、Fig. 1 の 2次元図面では、正面図は X-Y 平面、側面図は Y-Z 平面、平面図は X-Z 平面上に描画され、正面図は z 座標が 0、側面図は x 座標が 0、平面図は y 座標が 0 となる。

#### 3.2.2 [Step 2] 3次元空間上の頂点と辺の探索

Step 1 で抽出した 2次元図面の幾何学的特徴により、3次元空間上の頂点と辺を探索する。各ビューを 2次元平面とすると、平面上の各頂点の法線ベクトルは 3次元空間で交差し、これらの交点  $v_i^{3D}$  は最終的な 3次元モデルに存在するため容易に発見できる一方、3次元空間上の辺は、交点  $v_i^{3D}$  のみから発見することはできない。すべての辺を探索するためには、交点  $v_i^{3D}$  のペア ( $v_\alpha^{3D}, v_\beta^{3D}$ ) に次のルールを適用する必要がある。ペア ( $v_\alpha^{3D}, v_\beta^{3D}$ ) が次のルールのいずれかを満たす場合、ワイヤーフレームモデルの辺と見なされる。

1. 3つのビューすべてにペア ( $v_\alpha^{3D}, v_\beta^{3D}$ ) で構成される辺  $e_h^{3D}$  が投影されている。
2. 3つのビューのうち 2つにペア ( $v_\alpha^{3D}, v_\beta^{3D}$ ) で構成される辺  $e_h^{3D}$  が投影されており、残りの 1つのビューにはペア ( $v_\alpha^{3D}, v_\beta^{3D}$ ) の頂点  $v_\alpha^{3D}$  または  $v_\beta^{3D}$  が投影されている。

なお、3次元空間から各ビューに投影された辺  $e_h^{3D}$  や頂点  $v_\alpha^{3D}$  または  $v_\beta^{3D}$  を含むような他の辺が存在した場合、2次元図面の各ビューでは、本来重なっていても 1つの辺として描画される。

ここで得られた 3次元空間上の辺は、最終的な 3次元モデルに存在する可能性のある辺候補であり、必ずしも存在するとは限らない。したがって、本研究では上記で得られた 3D 頂点と 3D 辺候補からなる 3次元モデルを疑似ワイヤーフレームモデルとして定義する。

#### 3.2.3 [Step 3] 命題論理式の生成

次に、疑似ワイヤーフレームモデルからサーフェスモデルへの再構築を行う。疑似ワイヤーフレームモデルは 3D 頂点と 3D 辺候補で構成される曖昧な表現であるため、面候補は多数存在し、サーフェスモデルへの再構成には、適切な面の集合を選択する必要がある。ここでは、疑似ワイヤーフレームモデルから適切な面

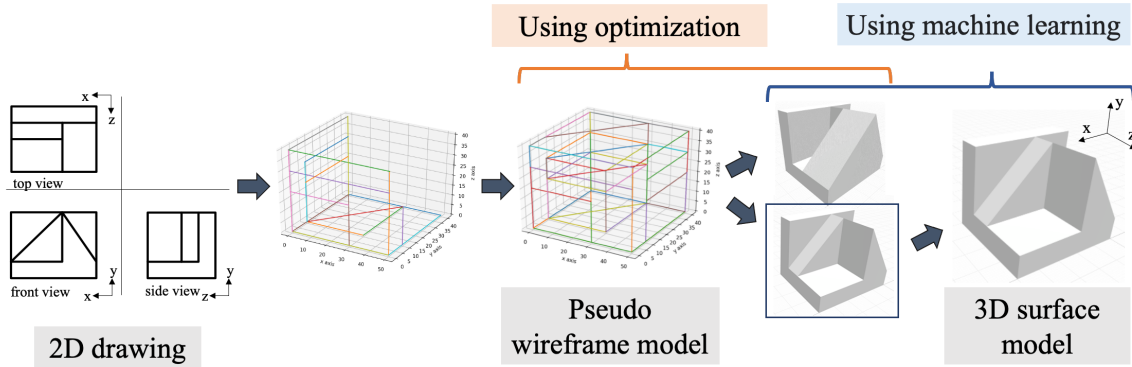


Fig. 3: Overview of the proposed method.

の集合を探す問題を充足可能性問題に定式化するために、次のルール<sup>12)</sup>をもとに命題論理式を生成する。

1. 辺を共有する面の数は0または2でなければならない。
2. 三面図上の領域に対応する候補面のうち、存在する面の数は偶数である必要がある。
3. 複数の面が交差する場合、存在できる面は最大1つである。
4. 辺の線種が外形線であり、辺を共有する2つの最前面が滑接する場合、存在できる面は最大1つである。

生成された命題論理式は、命題変数によって面が存在する (True: T) もしくは存在しない (False: F) を表し、論理演算子によって存在し得るサーフェスモデルの条件を表す。この命題論理式を満たす命題変数の割り当てが充足可能性問題の解となり、存在し得るサーフェスモデルに変換される。

### 3.2.4 [Step 4] SAT ソルバの適用

Step 3 で得られた命題論理式を用いて充足可能性問題の解を探索するために、ここでは、一般的な SAT (Satisfiability) ソルバを適用して適切な面の集合を得る。SAT ソルバは命題論理式を受け取ると、命題論理式を真にする割り当てが存在する (充足可能, SAT) か存在しない (充足不能, UNSAT) かを判別し、命題論理式が充足可能である場合はその解を出力する。なお、単一の解のみを出力する SAT ソルバを利用する場合は、1 度出力された解を新たな制約として追加し、命題論理式が充足不能になるまで繰り返し解の探索を行うことで、すべての解を網羅的に導出する。これにより、疑似ワイヤーフレームモデルに適切な面を割り当てたすべてのパターンを出力し、存在し得るすべてのサーフェスモデルを再構成することができる。

### 3.2.5 [Step 5] 前処理および 3 次元モデルの学習

Step 1 から 4 で生成されるサーフェスモデルが 1 つである場合、その立体を本提案手法の再構成結果とする。一方、2 次元図面が曖昧さを含む場合、Step 1 から 4 で生成される複数のモデル候補から、学習ベースの手法を用いて妥当な 3 次元モデルを絞り込む。本研究では、

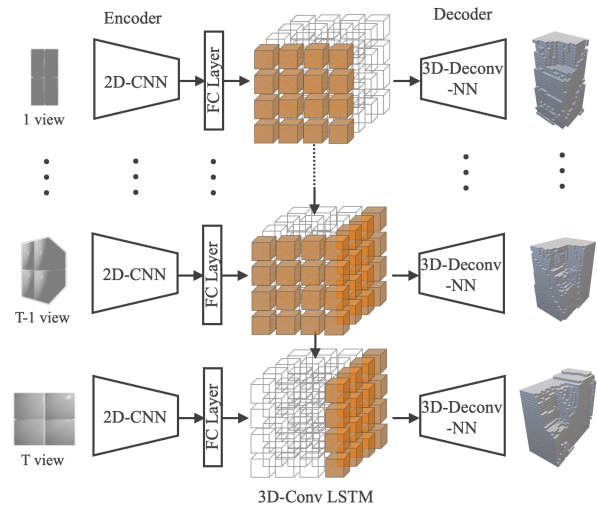


Fig. 4: 3D-R2N2 architecture.

Choy ら<sup>13)</sup> が提案した 3D Recurrent Reconstruction Neural Network (3D-R2N2) を用いる。

3D-R2N2 は、単一または複数の画像を入力として受け取り、ボクセルマップを出力するネットワークであり、入力画像のビューの数が増えるにつれてより厳密なボクセルマップを予測することができる (Fig. 4). エンコーダとして用いられる 2D-CNN と、複数のビューから得られた特徴を学習する 3D Convolutional LSTM、デコーダである 3D Deconvolutional Neural Network から構成されており、すべての畳み込み層の後に活性化関数である LeakyReLU (Leaky Rectified Linear Unit: LReLU) を用いる。なお、LeakyReLU は ReLU (Rectified Linear Unit) と比べ、入力値が 0 より下であっても勾配が発生するという特徴がある。

**[Encoder] 2D-CNN:** 単一または複数のビューを持つ画像が入力されると、3D-R2N2 は CNN を用いて入力画像を低次元特徴に圧縮する。3D-R2N2 では、通常の CNN と残差ブロックを導入した Deep Residual Network (ResNet)<sup>14)</sup> のいずれかを選択可能である。各エンコーダの出力は平滑化され、全結合層に渡された後、1,024 次元の特徴ベクトルに圧縮される。

**[Recurrence] 3D Convolutional LSTM:** 3D-R2N2 では、ネットワークに入力された画像の特徴を保存し、新たな画像が入力された際にメモリを更新す

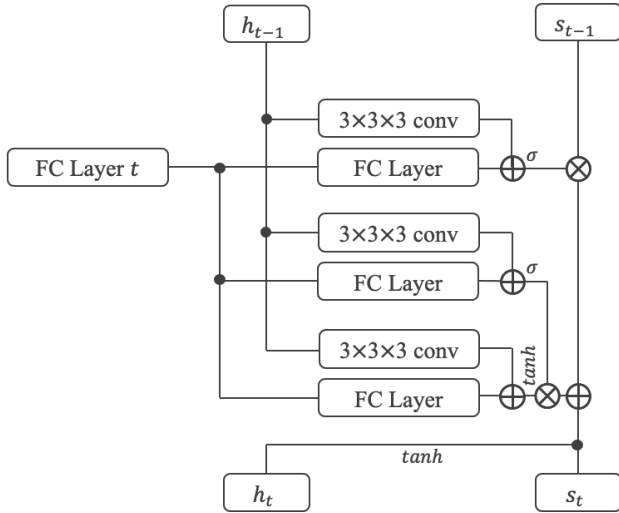


Fig. 5: 3D Convolutional LSTMs.

る 3D Convolutional LSTM (3D-LSTM) とよばれるアーキテクチャを提案している (Fig. 5). 3D-LSTM は接続が制限された複数の LSTM のユニットで構成されており, 各 LSTM ユニットのボクセル空間の一部を再構成する役割を果たす. 空間分解能  $N \times N \times N$  と同数の LSTM ユニットの存在し, インデックス  $(i, j, k)$  の LSTM ユニットの隠れ状態  $h_{t(i,j,k)} \in \mathbb{R}^{N_h}$  と, 情報の取捨選択を行う機構である 2 つのゲート (入力ゲート, 忘却ゲート) を内包する. 入力ゲート  $i_t$ , 忘却ゲート  $f_t$ , メモリセル  $c_t$ , 隠れ状態  $h_t$  を 4 次元テンソル (サイズ  $N_h$  の  $N \times N \times N$  ベクトル) として扱い, 畳み込み演算を  $*$  表記すると, 3D-LSTM の順伝播計算は以下の式で表される.

$$\begin{aligned}
 f_t &= \sigma(x_t \tau W_f + h_{t-1} * U_f + b_f) \\
 i_t &= \sigma(x_t \tau W_i + h_{t-1} * U_i + b_i) \\
 \tilde{h}_t &= \tanh(x_t \tau W_{\tilde{h}} + h_{t-1} * U_{\tilde{h}} + b_{\tilde{h}}) \\
 c_t &= f_t \otimes c_{t-1} + i_t \otimes \tilde{h}_t \\
 h_t &= \tanh(c_t)
 \end{aligned} \quad (1)$$

ここで,  $\sigma$  はシグモイド関数,  $\tanh$  は双曲線正接関数であり,  $\otimes$  はアダマール演算子である.  $W_f, W_i, W_{\tilde{h}}, U_f, U_i, U_{\tilde{h}}, b_f, b_i, b_{\tilde{h}}$  は, 重みとバイアス項を表す. 3D-LSTM ユニットの通常の LSTM とは異なり, 現在の隠れ状態  $h_t$  をデコーダに渡すため出力ゲートを内包せず, パラメータ削減に寄与している. また, 通常の LSTM はすべての隠れ状態  $h_{t-1}$  が現在の隠れ状態  $h_t$  への接続を有するのに対し, 3D-LSTM は隠れ状態  $h_{t-1}$  と現在の隠れ状態  $h_t$  の接続を制限し, 隣接する接続は畳み込みカーネルサイズによって決まる. 例えば,  $3 \times 3 \times 3$  カーネルを使用する場合, 空間  $(i, j, k)$  に配置された LSTM ユニットの隣接するユニットへの接続のみを有する.

**[Decoder] 3D Deconvolutional Neural Network:** 入力画像のシーケンス  $x_1, x_2, \dots, x_T$  を受け取った 3D-LSTM は, 隠れ状態  $h_t$  をデコーダである 3D Deconvolutional Neural Network に渡す. デコーダは 3 次元逆畳み込み, 活性化関数, 3 次元アンプリーングを適

用することで隠れ状態の解像度を出力解像度に達するまで向上させる<sup>15)</sup>. 最後の 3 次元逆畳み込み層の出力は, 出力層の活性化関数 3D Voxel-wise Softmax によってボクセル  $(i, j, k)$  での占有率  $p_{(i,j,k)}$  に変換される.

**[Loss] 3D Voxel-wise Softmax:** ネットワークの損失関数は, ボクセル単位の交差エントロピー誤差の合計として定義される. 各ボクセル  $(i, j, k)$  での予測結果をベルヌーイ分布  $[1 - p_{(i,j,k)}, p_{(i,j,k)}]$  とし, 真値である正解ボクセルマップの占有率を  $y_{(i,j,k)} \in \{0, 1\}$ , 入力を  $\mathbf{X} = \{x_t\}_{t \in \{1, \dots, T\}}$  とすると損失関数は以下の式で定義される.

$$\begin{aligned}
 L(\mathbf{X}, y) &= \sum_{i,j,k} y_{(i,j,k)} \log(p_{(i,j,k)}) \\
 &\quad + (1 - y_{(i,j,k)}) \log(1 - p_{(i,j,k)})
 \end{aligned} \quad (2)$$

なお, 学習データに 2 次元図面を使用せず, 3 次元モデルのレンダリング画像を用いる理由は, 3D-R2N2 における 3D-LSTM レイヤの学習方法が関係する. 3D-LSTM を構成する LSTM ユニットの空間分解能  $N \times N \times N$  だけ存在し, 入力画像が与えられると, 撮影角度に対応する位置に配置された LSTM ユニットの入力ゲートのみが開く (Fig. 4).

この機構により, ネットワークは画像の特徴を正しい位置に配置することができ, 画像から立体形状を学習することが可能となる. 2 次元図面を学習データの撮影画像として使用した場合, 正面, 側面, 平面の 3 方向の位置に対応する LSTM セルのみ入力ゲートが開くため, 立体の背面, 底面, 左側面をうまく学習できず, 学習データから 3 次元モデルの特徴を正しく学習できない. よって学習データには, 複数方向からレンダリングされた画像を用いて学習を行い, 推論時には正面, 側面, 平面, 背面, 底面および, 左側面の計 6 方向から 3 次元モデルをレンダリングした画像を用いる.

### 3.2.6 [Step 6] 推論およびサーフェスモデルの選択

推論段階では, 入力画像からボクセルマップの推論を行う. ここでは, サーフェスモデルを正面, 側面, 平面, 背面, 底面および, 左側面の計 6 方向からレンダリングした画像をテストデータとして用いる.

再構成されるボクセルマップは厳密な 3 次元モデルではないため, 最適化ベースの再構成で得られた複数のサーフェスモデルとボクセルマップの一致具合を評価する. 評価は, 予測結果と真値 (正解ボクセルマップ) の領域の一致具合を示す評価指標 (Intersection-over-Union: IoU) を用いて行い, IoU の値が最も高いサーフェスモデルを本提案手法の再構成結果とする.

$$\begin{aligned}
 IoU &= \frac{\sum_{i,j,k} [I(p_{(i,j,k)} > t) I(y_{(i,j,k)})]}{\sum_{i,j,k} [I(p_{(i,j,k)} > t) + I(y_{(i,j,k)})]}
 \end{aligned} \quad (3)$$

ここで,  $I(\cdot)$  は指示関数,  $t$  はボクセルの閾値を表す.

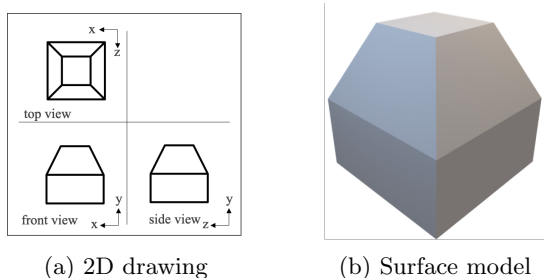


Fig. 6: Reconstruction example of Case 1.




Fig. 7: Reconstruction example of Case 2.

## 4 評価実験

提案手法の有用性を検証するために、単純な形状を持つ2次元図面を用いて2つの実験を行った。実験1では、簡単な立体を再構成できるか検証を行った。実験2では、曖昧な2次元図面から再構成された複数の立体に対して学習ベースの手法を適用し、曖昧さの解消を試みた。

### 4.1 実験設定

本実験では、6つのプロセスで構成される提案手法で実際に2次元図面の再構成を行った。提案手法における設定を以下に示す。2次元図面は注釈や寸法を含まない第三角法で描かれた正投影図とし、実線と破線は区別しないものとした。充足可能性問題の解の探索にMicrosoft Researchによって開発されたSATソルバであるZ3<sup>16)</sup>を使用した。3D-R2N2のネットワークにおけるEncoderにはResNetを選択した。正解ボクセルマップのサイズは $32 \times 32 \times 32$ とした。学習データには $137 \times 137$ のRGBA画像を使用し、立体の位置とカメラの距離を固定して方位角を $0^\circ \sim 360^\circ$ 、仰角を $-90^\circ \sim 90^\circ$ の間で30度ずつ変更した84視点から透視投影で撮影を行ったレンダリング画像を使用した。推論には $127 \times 127$ のRGB画像を使用し、立体の位置とカメラの距離を固定して正面、側面、平面、背面、底面および、左側面の計6視点から平行投影で撮影を行ったレンダリング画像を使用した。バッチサイズ24で20,000イテレーション学習を行い、学習率は $1e-4$ に設定し、最適化手法にはAdam<sup>17)</sup>を使用した。IoUにおけるボクセルの閾値 $t$ は0.4に設定した。

### 4.2 実験1

実験1では、単純な形状を持つ3種類の2次元図面から再構成を試みた。この実験では、提案手法のStep1から4までを使用した。Fig. 6~8に2次元図面と再構成したサーフェスモデルを示す。提案手法が3種類の2次元図面(Fig. 6(a)~Fig. 8(a))をモデルに再構成できることを確認した。Fig. 6やFig. 7の例では再構成後のモデルは1つであったが、Fig. 8(a)は複数通りに解釈される曖昧さを含む2次元図面であるため、Fig. 8(c),(d)に示すような複数のモデルに再構成された。

### 4.3 実験2

実験2では、Fig. 9(a)に示す曖昧さを含む2次元図面から再構成されたサーフェスモデル候補(Fig. 9(c))

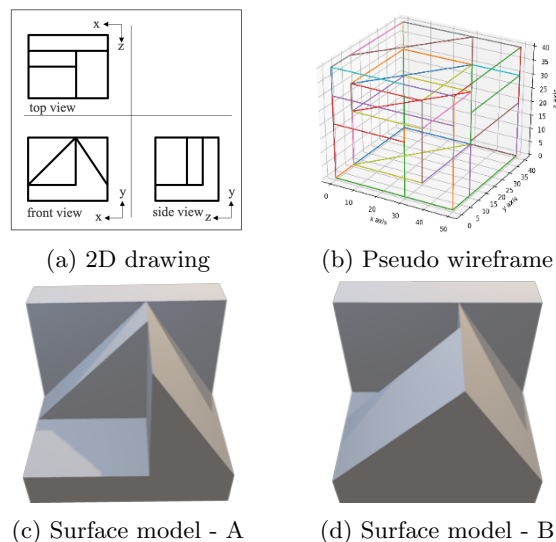


Fig. 8: Reconstruction example of Case 3.

に対して、提案手法のStep5および6を行うことで正しモデルを選択できるかを検証した。ここでは正解を、Fig. 9(c)の2番目の立体(赤枠で示された、直方体から角の1ブロックを除去した立体)とした。

学習データとして、 $n_x \times n_y \times n_z$  ( $n_x, n_y, n_z \in \{2, 3, 4\}$ ,  $7 \leq n_x + n_y + n_z \leq 9$ )個のブロックの組合せで作られた直方体から角の直方体を1個除いた立体形状(11種類, 1,100立体)のレンダリング画像を使用した。テストデータには、学習データに存在しない $2 \times 2 \times 2$ ブロックで構成される、各辺の長さをランダムに変更した計100立体を、平行投影で6視点から撮

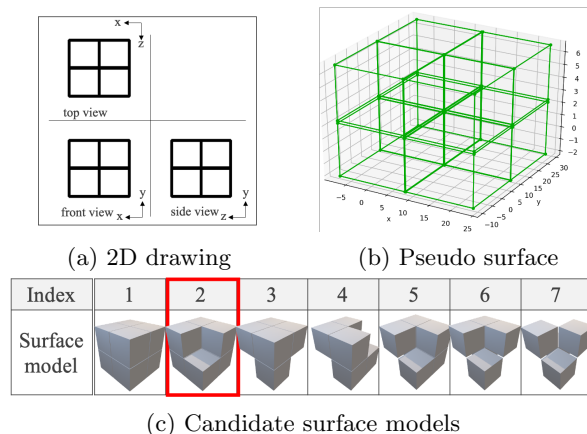



Fig. 9: Reconstruction example of Case 4.



(a) Predicted voxel map (b) Ground-truth voxel map

Fig. 10: Prediction result example of Case 4.

Table 1: Average IoU of 100 trials.

Index	1	2	3	4
IoU(average)	0.8610	0.8713	0.6499	0.6487
Index	5	6	7	
IoU(average)	0.7626	0.6444	0.5204	

影したレンダリング画像を用いて推論を行った。ここで、Fig. 9(c)の平行投影レンダリング画像は正面、側面、平面、背面、底面および、左側面の計6視点から撮影した場合、すべて同じとなる。

また、推論によって得られた予測ボクセルマップを用いた評価では、提案手法のStep 4までによってFig. 9(a)から再構成された46種類のサーフェスモデル候補のうち、対称性を廃した7種類の立体 (Fig. 9(c)) を候補とした。

3D-R2N2による予測ボクセルマップと正解ボクセルマップの例をFig. 10に、推論100試行の平均IoUをTable 1に示す。実験の結果、100試行中58試行において、正解となるサーフェスモデル (Index 2) が選択されたことを確認した。また、Table 1に示すように、Index 1とIndex 2における平均IoUの差が小さいことから、学習ベースの手法は構造が大きく異なる立体を除外することができる一方で、候補となる立体を1個のみに絞り込むことが困難である可能性がある。

## 5 まとめと今後の課題

本研究では、組合せ最適化と機械学習を併用した再構成手法を用いることで、再構成における曖昧さを解消する手法を提案した。評価実験の結果、単純な形状を持つ2次元図面の再構成には成功し、学習ベースによるサーフェスモデルの選択において、大きく構造の異なる解釈は再構成結果から除外することができたが、似た構造を持つ立体は絞り込めない可能性があることが確認された。今後、学習データや正解ラベルである真値ボクセルマップの形式や与え方、評価指標の工夫を検討し、多様な2次元図面の例を用いて検証を行うことは本研究の重要な課題である。

## 参考文献

- 1) Pedro Company, Ana Piquer, Manuel Contero, and Ferran Naya. A survey on geometrical reconstruction as a core technology to sketch-based modeling. *Computers & Graphics*, Vol. 29, No. 6, pp. 892–904, 2005.
- 2) George Markowsky and Michael A Wesley. Fleshing

out wire frames. *IBM Journal of Research and Development*, Vol. 24, No. 5, pp. 582–597, 1980.

- 3) RE Marston and MH Kuo. Reconstruction of 3d objects from three orthographic projections using a decision chaining method. In *MVA*, pp. 423–426, 1994.
- 4) Byeong-Seok Shin and Yeong Gil Shin. Fast 3d solid model reconstruction from orthographic views. *Computer-Aided Design*, Vol. 30, No. 1, pp. 63–76, 1998.
- 5) M. Idesawa. A system to generate a solid figure from three view. *Bulletin of JSME*, Vol. 16, No. 92, pp. 216–225, 1973.
- 6) 青村茂. 図面から立体を作成するシステムの研究動向とその実用化: 図面からソリッドモデルの自動作成. 日本機械学会論文集 C 編, Vol. 61, No. 586, pp. 2180–2189, 1995.
- 7) 青村茂, 石原肇. 図面の認識と立体作成: 画面理解および一般: 画像処理・コンピュータビジョン. テレビジョン学会技術報告, Vol. 17, No. 43, pp. 33–40, 1993.
- 8) Gilles Lafue. Recognition of three-dimensional objects from orthographic views. *ACM SIGGRAPH Computer Graphics*, Vol. 10, No. 2, pp. 103–108, 1976.
- 9) Gilles Lafue. A theorem prover for recognizing 2-d representations of 3-d objects. *Artif. Intell. and Pattern Recognition in CAD (Latombe ed.)*, Vol. 391, , 1981.
- 10) Rocco Furferi, Lapo Governi, Matteo Palai, and Yary Volpe. From 2D orthographic views to 3D pseudo-wireframe: An automatic procedure. *International Journal of Computer Applications*, Vol. 975, p. 8887, 2010.
- 11) L. Governi, R. Furferi, et al. 3D geometry reconstruction from orthographic views: A method based on 3D image processing and data fitting. *Comput. Ind.*, 2013.
- 12) 内野寛治, 狩野均, 西原清一. 制約知識ベースに基づく三面図理解. *人工知能*, Vol. 11, No. 4, pp. 653–661, 1996.
- 13) Christopher B Choy, Danfei Xu, JunYoung Gwak, Kevin Chen, and Silvio Savarese. 3d-r2n2: A unified approach for single and multi-view 3d object reconstruction. In *European conference on computer vision*, pp. 628–644, 2016.
- 14) Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778, 2016.
- 15) Alexey Dosovitskiy, Jost Tobias Springenberg, and Thomas Brox. Learning to generate chairs with convolutional neural networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1538–1546, 2015.
- 16) L. De Moura and N. Björner. Z3: An efficient smt solver. In *International conference on Tools and Algorithms for the Construction and Analysis of Systems*, pp. 337–340, 2008.
- 17) Diederik P Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.