

# 分割統治戦略に基づく花のCT画像の花弁セグメンテーション

仲 勇樹<sup>†</sup> 内海ゆづ子<sup>†</sup> 岩村 雅一<sup>†</sup> 塚谷 裕一<sup>††</sup> 黄瀬 浩一<sup>†</sup>

<sup>†</sup>大阪公立大学 大学院情報学研究科 〒599-8531 大阪府堺市中区学園町 1-1

<sup>††</sup>東京大学 大学院理学系研究科 〒113-0033 東京都文京区本郷 7-3-1

E-mail: <sup>†</sup>sb22622q@st.omu.ac.jp, {yuzuko,masa,i,kise}@omu.ac.jp, <sup>††</sup>tsukaya@bs.s.u-tokyo.ac.jp


**あらまし** CTで撮影された花から花弁の3次元的な形態情報を得るためには、CT画像の解析による各花弁の詳細なセグメンテーションが必要となる。本研究では深層学習を用いた花弁のセグメンテーションによって、花の3次元的な構造を可視化することを目指す。花のCT画像は一般的なインスタンスセグメンテーションタスクの対象物とは異なり、花弁が湾曲し複雑に入り組んだ構造をしている。そのため、その特有の性質によって花弁のセグメンテーションが他の種類のデータに比べて特に困難である。そこで、横断面のスライス画像から花の放射軸を中心とした横に長い長方形の小領域を回転させながら切り出し、その各画像に対して深層学習を用いてセグメンテーションを行う。そして、それらの結果から重複する割合によって統合することで花弁の3次元形状の推定を試みた。実験の結果、花弁領域のセグメンテーションに成功し、花弁の3次元形状を可視化することができた。

**キーワード** 植物計測, インスタンスセグメンテーション, CT画像, 深層学習, 分割統治法

## 1. はじめに

花の全体的な外観は、花托の形や大きさ、花器官の配置、数、種類、形、色などの多くの要因によって決定される [1]。そのため、これらの要素の複雑な組み合わせによって花は多様で複雑な構造を持つことが多い。複雑な構造をしている花においては特に器官と器官の相互作用が形態形成に重要になる [2]。花器官の中でも花弁（花びら）は大きさや形、色が花の種類によって大きく異なるが [3]、植物の成長と繁殖に不可欠であることから細胞分裂の制御、細胞の拡大、細胞や組織型の分化、器官全体のパターン形成などの花器官形成の過程を解明することに適している [4]。そのため、花弁を中心とした花の形態情報を収集と、それに基づく形態形成のメカニズムの解明が期待されている。

花の形態情報の調査は花弁を1枚1枚分解するなどの破壊調査が多い [5]~[7]。この方法では花弁の大きさや形、遺伝子による形態形成への影響などが解明されている。しかし、花弁を分解してしまうことで花弁が空間的にどのように配置され、どのように発生しているのかということは調査することができない。また、顕微鏡を用いた観察によって花弁の一部断面を観察することが可能であるが、この方法も3次元空間における花の構造特性を正確に解析することは困難である [8]。そこで、花の空間的な形態情報を得る方法としてコンピュータ断層撮影 (Computed Tomography: CT) 装置で花の非破壊撮影が試みられている [2], [9]。図 1(a) に ImageJ [10] に基づいたオープンソースの画像処理パッケージである Fiji is Just ImageJ (Fiji) [11] のプラグインの1つである Volume Viewer を用いて作成された花のCT画像から得られる3Dレンダリング画像の例を示す。図 1(a)



(a) 3D レンダリング画像.

(b) 横断面の CT 画像.

図 1: 解析に使用したツバキのCT画像とレンダリング画像の例。

から分かるように、CTで撮影されたデータは花の概形は分かるものの花弁などの各花器官がどの部分に当たるかといった識別がされているわけではない。そのため、花器官の3次元的な形態情報を得るためには得られたCT画像を解析し、花弁1枚1枚の詳細なセグメンテーションをすることが必要となる。しかし、花のCT画像から手動で1枚1枚の花弁のセグメンテーションするのは花弁の枚数が多く、時間を要することから困難である。

これまでに花のCT画像を用いた花器官の識別をした研究には、井尻らの研究 [12] がある。この手法では、花のモデリングを目的としてCT画像での花弁のセグメンテーションをしている。これは我々が知る限り唯一、花のCT画像のセグメンテーションをしている研究である。しかし、CTボリュームの断面における細長い形をした1つの花弁に対して、ユーザが花弁領域の中心線付近に沿って、数カ所に点を指定していくことを必要とする対話型のモデリングシステムであるため、手作業が多

く時間を要する。また、花以外の CT 画像におけるインスタンスセグメンテーションの研究の多くに大量の学習データを必要とする深層学習ベースの手法が用いられている [13],[14]。しかし、花の CT 画像のデータは少なく、データセットは我々の知る限り存在しないため、少ない CT 画像のデータでも自動でセグメンテーションできる手法が相応しい。また、花卉の形状は一般的なセグメンテーションタスクの対象物に比べ、細長く湾曲した複雑な構造をしているため、そのような構造でも正確なセグメンテーションができる手法が相応しい。

そこで本研究では、図 1(b) のような花の CT 画像から小領域を切り出すことでデータを増やし、少ない正解データでの深層学習モデルの学習と花卉の検出をする方法を提案する。提案手法ではまず、CT 画像から細長い長方形を花の中心軸を基準に回転させながら切り出し、インスタンスセグメンテーション用のモデルに入力することで切り出した領域における花卉のセグメンテーションをする。そして、それらのセグメンテーション結果を統合し、花の CT ボリュームに反映する。実験の結果、花卉領域のセグメンテーションに成功し、花卉の 3 次元形状を可視化することができた。

## 2. 関連研究

本章では CT 画像を用いた花卉のセグメンテーションの関連研究として、花を対象としたセグメンテーション、モデリングの例を紹介する。また、CT 画像を対象としたセグメンテーションの関連研究についても紹介する。

### 2.1 花のセグメンテーション

従来からカメラで撮影された 2 次元画像上における花や花卉に対するセグメンテーションを実現するために様々なアプローチが試みられてきた。花を検出するための手法として、グラフカットを用いたマルコフ確率場 (MRF) に基づく手法 [15],[16] や Lab 色空間での閾値処理による手法 [17], HSI 空間色閾値設定と局所領域クラスタリングを組み合わせた手法 [18] がある。また、農業分野への応用が期待されている手法も多くあり、イチゴ [19] やリンゴ [20]~[22], トマト [23] の花を検出する手法などが存在する。しかし、これらの手法は本研究のような花の内部も含めた空間的な形態情報の収集とは異なる。

### 2.2 花のモデリング

花はその複雑な構造と自己オクルージョンのため、花の形状を 3 次元でモデリングする研究は限られている [24]。その中でも、Zhang らは RGB 画像と 3 次元点群データを用いて花卉を分割し、あらかじめ作成されたモーフィング可能な花卉形状モデルに適合させる手法 [24] を提案している。また、井尻らは花を構成する要素の種類、数、配置などを表現した模式図である花式図を用いて、花を 3 次元モデリングするシステム [25] を提案している。これらの手法は空間的な花の形態情報収集という点で本研究と共通しているが、外から見える範囲での情報を用いたモデリング手法であり、外からは見えない内部の情報を含んだ CT 画像を用いて花卉のセグメンテーションをするような解析には向かない。

また、CT 画像から花をモデリングした手法は我々が知る限

り、井尻らの半自動の花のモデリングシステム [12] のみである。このシステムは花を茎などの軸と花卉などのシートの 2 つで構成されていると仮定し、動的曲線と動的面のエネルギー関数をそれぞれ定義する。そして、ユーザが指定した点を基に茎や花卉を自動でフィッティングする。しかし、このシステムは手動で行う部分が多いため時間がかかってしまう。そのため、手動で行う操作をなくし全て自動化する手法について検討しなければならない。

以前提案したスペクトラルクラスタリングを用いた花の CT 画像における花卉のセグメンテーション手法 [26] では、細長く密な花卉をグラフ構造として扱いクラスタリングすることで花卉同士の接触部分を除いた花卉領域のセグメンテーションをした。花卉の接触部分を取り除いていることから、花卉配置がより密になっている花の下部のスライス画像では多くの花卉が取り除かれてしまいセグメンテーションの精度が大幅に低下してしまう問題があった。そのため、花卉の接触部分も含めたセグメンテーション手法を検討する必要がある。

### 2.3 CT 画像のセグメンテーション

医療分野では CT 画像を用いたセグメンテーションの研究が活発に研究されている。現在の主な医療 CT 画像のセグメンテーション研究の手法は、アノテーションされた CT 画像のデータセットから畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) を学習する手法が主流となっている。冠動脈 [27] や胸部臓器 [28], 血管や臍臓管などの管状臓器や組織 [29], 椎骨 [30], 歯 [13] など様々な人体臓器や組織に対してセグメンテーションが行われている。また、患部に対してのセグメンテーション手法 [31]~[34] も存在している。医療分野以外にも、短繊維強化プラスチック (Short-Fiber Reinforced Polymers: SFRP) を低解像度 CT 画像から自動的に抽出する手法 [14] が存在している。近年では CNN 以外にも、Vision Transformer (ViT) [35] を用いて、臓器や脳腫瘍に対してセグメンテーションを行う手法 [36] も提案されている。

これらの人体臓器や組織、SFRP に対するセグメンテーションでは、ある程度似た形のものに対してセグメンテーションや識別を行っている。しかし、花卉に対するセグメンテーションでは花卉によって形は様々であり、形状も細長く湾曲し多くの花卉が入り組んでいることから形状に基づいた識別がしにくい。また、花の CT 画像のデータが充実しておらず、大量の学習データを用いた学習が行うことが難しい。そのため、医療分野における人体 CT 画像のセグメンテーション手法を直接用いることは困難である。

## 3. 提案手法

手法の概要を図 2 に示す。提案手法では、花を鉛直上向きに対して垂直にスライスした 2 次元画像において、細長い長方形に CT 画像を切り出し、CNN を用いて花卉のセグメンテーションをする。そして、切り出した領域における花卉のセグメンテーション結果を統合することで、スライス画像の花のセグメンテーションを実現する。また、それらの統合結果から 3 次元方向に統合し 3 次元可視化をする。本章では画像の切り出し

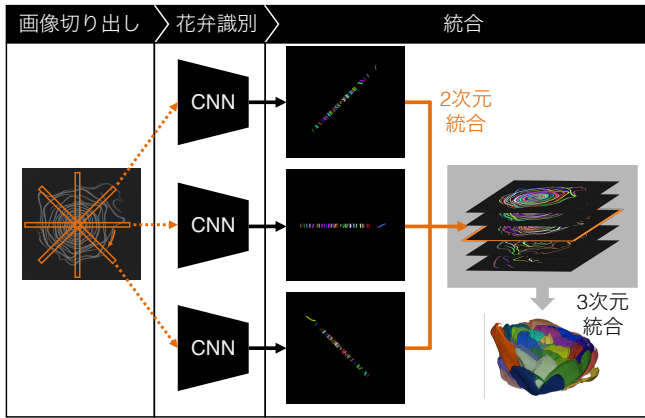


図 2: 提案手法の概要.

方法と CNN を用いた小領域に対する花卉のセグメンテーションについて述べた後、セグメンテーション結果の統合手法について述べる。


### 3.1 画像の切り出し方法

図 3 に示すように、本研究の花卉のセグメンテーションで対象とする花の CT 画像は、一般的なインスタンスセグメンテーションでの対象物とは大きく異なる。花卉は図 3(a) に示すように細長く、弧を描いている形状をしている。また、花卉同士は画像上で重なって位置している。一般的な物体検出で対象とされる画像は図 3(b) に示すように、セグメンテーション対象の 1 つの物体をバウンディングボックスで囲むと、バウンディングボックスの中に他のオブジェクトが含まれることはなく、1 つの矩形に 1 つの物体のみが存在する。そのため、Mask R-CNN [37] などの多くの CNN ベースのセグメンテーション手法では、画像中から特徴量を用いてオブジェクトの存在している可能性が高いバウンディングボックスを取り出し、その中には 1 つの物体が含まれていることを仮定してセグメンテーションマスクを推定する。しかし、本研究で扱う花の CT 画像ではセグメンテーション対象である花卉の特有の形状と配置のため、図 3(a) に示すように、バウンディングボックス内に複数のオブジェクトが存在する。そのため、CNN ベースのセグメンテーション手法をそのまま適用しても、複数のオブジェクトが存在することで上手く花卉を推定できずにセグメンテーションに失敗してしまう。

そこで本研究では、図 4 のように  $900 \times 32$  pixels の細長い長方形を花の中心を軸として  $1^\circ$  ずつ回転させながら画像を切り出し、切り出した画像に対して CNN ベースのセグメンテーション手法を適用する。切り出した画像では花卉の一部が切り出された状態となり、花卉同士は重なって存在しているものの、1 つのバウンディングボックス内に 1 つの花卉のみが含まれるようになる。このことで、セグメンテーション対象の物体の形状的な特徴を一般的な物体認識に近づけ、精度の向上を図る。

### 3.2 小領域の花卉セグメンテーション

3.1 節で述べた手法で切り出した領域をインスタンスセグメンテーション用の CNN に入力することで花卉を検出する。本研究で適用したインスタンスセグメンテーションの CNN は



(a) 花の CT 画像の一部.

(b) 一般的なタスク [38].

図 3: 一般的なインスタンスセグメンテーションの対象物と花の CT 画像の違い. (a) 花の CT 画像の例. 花卉とその花卉に対応するバウンディングボックスを同じ色で示している. (b) 一般的なインスタンスセグメンテーションの対象物の例.




図 4: 画像の切り出し方法.

Hybrid Task Cascade (HTC) [38] である。HTC はインスタンスセグメンテーションでベースラインとして用いられることの多い Mask R-CNN [37] とカスケード構造により高精度な物体検出を実現した Cascade R-CNN [39] を組み合わせることによって、より高精度なインスタンスセグメンテーションを実現したモデルである。

そして、CNN の出力結果を切り出し前の CT 画像の位置に戻し、同様のことを  $360^\circ$  分繰り返した後、それらのセグメンテーション結果を統合する。

### 3.3 セグメンテーション結果の統合

3.2 節での小領域におけるセグメンテーション結果を統合し、2次元画像のセグメンテーションをする。ある切り出し画像と、その画像から小領域を  $1^\circ$  回転させて切り出した画像には、重複する部分が多く存在する。図 5 に 2 つの隣合う小領域の重複する部分と異なる部分を示す。図 5 から分かるように  $1^\circ$  の差においては大半の領域が重複している。その重複部分の重なり度合いによってセグメンテーション結果の統合する。

まず、切り出した領域でのセグメンテーション結果には誤りが含まれているため、不正確なセグメンテーション結果を除去する。図 6 に重複部分を持つ 2 つの小領域  $A_1, A_2$  でのそれぞれの統合前のセグメンテーション結果の一部を示す。  $S_{1,1}, S_{1,2}$  は  $A_1$  の、  $S_{2,1}, S_{2,2}, S_{2,3}$  は  $A_2$  のセグメンテーション結果の一部であり、  $S_{1,2}$  は誤って本来 2 つの領域を 1 つにセグメンテーションしている。正しくセグメンテーションされた場合、  $S_{1,1}$  と  $S_{2,1}$  のように異なる小領域でも 1 つの領域としてセグメンテーションされる。セグメンテーション結果に誤りがある  $S_{1,2}$  の場合は、  $S_{2,2}, S_{2,3}$  と 2 つの領域としてセグメンテーションされる。この場合、共通のセグメンテーション領域がより多くの領域に分割されているものが正しい結果とみなす。そして、  $S_{1,2}$  を誤りとして除去する。



図 5: 1°の回転による変化. 赤で示された領域が一致する画素であり, 緑で示された領域が異なる画素である.




図 6: 重複部分を持つ2つの小領域の例. 実線のオレンジの実線で囲まれている矩形が  $A_1$  の, 緑の点線で囲まれている矩形が  $A_2$  の小領域を表す.  $S_{1,1}$  と  $S_{1,2}$  は  $A_1$  での,  $S_{2,1}$ ,  $S_{2,2}$ ,  $S_{2,3}$  は  $A_2$  でのセグメンテーション結果の一部であり, 実線が  $A_1$ , 点線が  $A_2$  の結果に対応している.

表 1: CT 撮影時の設定値

X 線管電圧	120 kV
X 線管電流	437 $\mu$ A
フィルタ	なし
各投影の露光時間	1,000 ms
投影画像	1,000 $\times$ 1,000 pixels
ピクセルサイズ	0.4 mm
1 回転の投影数	1,000 枚
拡大率	8.65 倍

前処理後のマスクごとに他のマスクとの Intersection over Union (IoU) を計算し, IoU が 0.8 以上の場合同じ花卉であると判定する. ここで求める IoU は図 5 の赤の領域のように重複した領域内での IoU を計算する. これにより同じ花卉として判定されたマスク同士をつなげていくことでセグメンテーション結果を統合する.

また, 3次元形状の可視化のために横断面に対する統合後に3次元方向にも統合する必要がある. ある横断面のスライス画像の前後2枚の統合結果から各マスク領域同士の IoU を計算し, 最も大きい IoU のマスク同士を繋げることで統合をする.

## 4. 実験


### 4.1 データセット

実験に用いた花の CT 画像のデータは, ツバキ (*Camellia japonica*) の CT 画像である. ツバキの品種は図 7(a) のようなオランダ紅と呼ばれるものである. 解析したツバキのオランダ紅は Carl Zeiss 社製の工業用 Dimensional X 線 CT 装置 METRO-TOM 1500 Gen.1<sup>1</sup> を使用して図 7(b) のように 41 分かけて撮影された. また, 撮影時の設定は表 1 の通りである.

解析に用いた CT 画像 1 枚の解像度は 915  $\times$  858 pixels で, 枚



(a) オランダ紅の花.



(b) 撮影方法.

図 7: 実験データ [26].

数は 888 枚である. また, 体軸方向における断層画像の厚みであるスライス厚は 46.252  $\mu$ m である. CT 画像の 1 枚を図 1(b) に示す. 画像上に描画されている細い形状をした線が識別対象の花卉である.

高解像度な CT 撮影をするには長時間の撮影が必要である. しかし, 花の CT 撮影では長時間の撮影になると花が乾燥し, 形が変わってしまう. そのため, 長時間撮影が難しく高解像度で撮影することが困難になっている. それにより発生する画像のノイズを除去するため, 前処理としてパラメータを  $h=6$  に設定したノンローカルミーニフィルタ [40] を CT 画像に適用した後小領域を切り出した.

学習に用いたデータは手動でアノテーションされた 25 枚のスライス画像である. これらの画像から提案手法の切り出し方法で 900  $\times$  32 pixels の長方形を 1° ずつ回転させながら切り出すことより, 360 枚ずつ小領域を各画像で作成し, 合計 9,000 枚用意した. また, 検証に用いたデータは学習用に用いたデータとは別の手動でアノテーションされた 14 枚のスライス画像である. これらの画像から提案手法の切り出し方法で 900  $\times$  32 pixels の長方形を 1° ずつ回転させながら切り出すことにより, 360 枚ずつ作成し小領域を各画像で作成し, 合計 5,040 枚用意した.

小領域の切り出し時に画素値の補間が必要になる. 本研究では最近傍補間により画素の補間をした. また, 切り出す角度によっては元の CT 画像の領域外を切り出す場合がある. その場合, 背景の輝度値の平均値  $\pm 5$  でランダムに補間した.

### 4.2 花卉のセグメンテーション

小領域の花卉のセグメンテーションには MMDetection [41] により実装した Hybrid Task Cascade (HTC) [38] を用いた. MMDetection は OpenMMLab プロジェクトが 2018 年から開発している物体検出に特化したツールボックスである. 一般的なモデルから最新のモデルまで様々なモデルを簡単に構築することが可能であり, 最新モデルにおいても MMDetection ベースで実装されることが増えている.

モデルの Backbone には ImageNet [42] で学習済みの ResNeXt-101 [43] 64x4d と Feature Pyramid Network (FPN) [44] を用いた. モデルの学習の際のエポック数は 20, バッチサイズは 32 とした. また, モデルの学習における最適化アルゴリズムは Adam [45] を用い, 学習率は  $10^{-4}$  から  $10^{-7}$  まで Cosine Annealing [46] のスケジューラーを用いて減衰させた.

(注 1) : <https://www.zeiss.co.jp/metrology/seihin/shisutemu/ct/metrotom.html>

表 2: 切り出した小領域における花卉セグメンテーションの定量評価

評価指標	mAP	AP <sub>50</sub>	AP <sub>75</sub>	mAR	AR <sub>50</sub>	AR <sub>75</sub>
スコア	0.585	0.898	0.683	0.624	0.906	0.727




図 8: ある角度のセグメンテーション結果と正解の比較.

精度の評価には COCOAPI<sup>2</sup>を用いた。評価指標として、花卉のセグメンテーションの正確性を示す適合率 (Precision) と花卉の見逃しの少なさを示す再現率 (Recall) を用いた。予測されたセグメンテーション領域と正解のマスク領域の IoU が閾値以上で正解として扱う。IoU の閾値が 0.5 の場合の平均適合率 (Average Precision: AP) を AP<sub>50</sub>, 平均再現率 (Average Recall: AR) を AR<sub>50</sub> とし, IoU の閾値を 0.75 とした場合の AP を AP<sub>75</sub>, AR を AR<sub>75</sub> として計算した。また, IoU の閾値を 0.5 から 0.95 まで 0.05 刻みで変化させた場合の AP を mAP, AR を mAR として計算した。

### 4.3 実験結果

#### 4.3.1 小領域の花弁セグメンテーション

切り出した小領域に対するセグメンテーション結果について, 表 2 に平均適合率と平均再現率を示す。また, 図 8 にセグメンテーション結果の 1 枚を示す。

小領域のセグメンテーション結果に関する定量評価では, 検証データに含まれる花卉のマスクの面積は中央値が 223 pixel であり, 大半が 400 pixel 以下であることから, 1 画素程度のずれが検出された花卉の輪郭全体に生じた場合 IoU が大きく下がってしまう。そのため IoU が 0.5 以上の場合でも, 花卉の形状は正解とほぼ一致することから, IoU が 0.5 の閾値の指標が高ければ十分な精度が出ていると考えることができる。

表 2 の結果から, AP<sub>50</sub> が 0.898, AR<sub>50</sub> が 0.906 と高い精度でのセグメンテーションが可能であることが示された。図 8 の中心部分のように他の部分に比べ面積が小さく, 複雑な部分の花弁において, 花卉の検出漏れや不正確なセグメンテーションが一部見られた。そのため, 適合率と再現率においてどちらも 9 割程度の精度になったと考えられる。また, 図 8 で示されるように定性評価においても良好にセグメンテーションができていたことが確認できた。


#### 4.3.2 セグメンテーション結果の統合

表 3 にセグメンテーション結果を 3 次元統合した際の平均適合率と平均再現率を示す。また, 図 9 に 3 次元統合後セグメンテーション結果の 1 枚を示す。

表 3 の定量評価の結果から適合率, 再現率ともに高い精度であることが示された。小領域のセグメンテーション結果と同

表 3: 統合後のセグメンテーションの定量評価


評価指標	mAP	AP <sub>50</sub>	AP <sub>75</sub>	mAR	AR <sub>50</sub>	AR <sub>75</sub>
スコア	0.714	0.900	0.804	0.781	0.928	0.871



(a) 統合結果.

(b) 正解データ.

図 9: 小領域の統合によるセグメンテーション結果



(a) 俯瞰図.

(b) 断面図.

図 10: 3 次元の統合結果.

様に図 9(b) の中心部から分かるように花の中心部分に関しては一部花卉の検出漏れや不正確なセグメンテーションが見られた。また, 図 9(b) においてオレンジの矢印が示す, 花卉同士の接触部分のような輝度値の変化が乏しい部分ではセグメンテーションが不正確になる部分が存在した。以上のことから mAP や mAR の精度が下がってしまったと考えられる。

また, 得られたセグメンテーション結果をもとに Fiji [11] の Volume Viewer を用いて 3 次元可視化した画像を図 10 に示す。図 10(b) において, オレンジの矢印が示す中心部分や緑の矢印が示すノイズの多い花の端の花弁のように一部不正確な部分も見受けられるものの各花弁をほぼ識別できていることが確認できた。

## 5. おわりに

花の CT 画像から手動で花弁をセグメンテーションするのは花弁の枚数が多く, 時間を要することから困難である。そのため, 本研究では横断面のスライス画像を小領域に切り出した上で, CNN による花弁のセグメンテーションをする手法を提案した。横断面のスライス画像から花の放射軸を中心とした横に長い長方形の小領域を回転させながら切り出し, 深層学習モデルに入力することで小領域におけるセグメンテーションをした。その次にそれらの結果を統合した上で, 3 次元データとしてセグメンテーション結果を統合した。実験の結果, 2 次元スライス画像のセグメンテーション結果は AP<sub>50</sub> が 0.900, AP<sub>75</sub>

(注2) : <https://github.com/cocodataset/cocoapi>

が 0.804 と高精度に花卉のセグメンテーションを実現した。また、3次元可視化結果ではほぼ花卉の識別ができていたことが確認できた。

**謝辞** 本研究を遂行するにあたり、データを提供して頂いた東京大学工学系研究科 鈴木・大竹研究室に感謝の意を表す。本研究は JSPS 科研費 JP22H04732 の助成を受けたものである。

## 文 献

- [1] H. Shan, et al., “Developmental mechanisms involved in the diversification of flowers,” *Nature Plants*, vol.5, pp.917–923, 2019.
- [2] A. Shimoki, et al., “Reduction in organ–organ friction is critical for corolla elongation in morning glory,” *Communications Biology*, vol.4, pp.1–8, 2021.
- [3] T. Huang, et al., “Gene networks controlling petal organogenesis,” *Journal of Experimental Botany*, vol.67, no.1, pp.61–68, 2015.
- [4] V.F. Irish, “The Arabidopsis petal: a model for plant organogenesis,” *Trends in Plant Science*, vol.13, no.8, pp.430–436, 2008.
- [5] D. Szlachetko, et al., “Telipogon szmiti (Orchidaceae, Telipogoneae), a new species from Southern Ecuador,” *Biodiversity: Research and Conservation*, vol.15, pp.9–12, 2009.
- [6] Y. Han, et al., “Identification of Candidate Adaxial–Abaxial-Related Genes Regulating Petal Expansion During Flower Opening in *Rosa chinensis* ‘Old Blush’,” *Frontiers in Plant Science*, vol.10, pp.1–16, 2019.
- [7] R.A. Hayes, et al., “Spatially explicit depiction of a floral epiphytic bacterial community reveals role for environmental filtering within petals,” *MicrobiologyOpen*, vol.10, no.1, pp.1–19, 2021.
- [8] Z. Gao, “Three-dimensional virtual flower bud of walnut tree based on micro-computed tomography,” *Agronomy Journal*, vol.114, no.4, pp.1935–1943, 2022.
- [9] H.-C. Hsu, et al., “Association between Petal Form Variation and CYC2-like Genotype in a Hybrid Line of *Sinningia speciosa*,” *Frontiers in Plant Science*, vol.8, pp.1–13, 2017.
- [10] C. Schneider, et al., “NIH Image to ImageJ: 25 years of image analysis,” *Nature Methods*, vol.9, pp.671–675, 2012.
- [11] J. Schindelin, et al., “Fiji: An Open-Source Platform for Biological-Image Analysis,” *Nature Methods*, vol.9, pp.676–682, 2012.
- [12] T. Ijiri, et al., “Flower Modeling via X-ray Computed Tomography,” *ACM TOG*, vol.33, pp.1–10, 2014.
- [13] Z. Cui, et al., “Toothnet: Automatic Tooth Instance Segmentation and Identification From Cone Beam CT Images,” *Proc. of CVPR*, pp.6368–6377, 2019.
- [14] T.K. Konopczynski, et al., “Instance Segmentation of Fibers from Low Resolution CT Scans via 3D Deep Embedding Learning,” *Proc. of BMVC*, pp.1–12, 2018.
- [15] M.-E. Nilsback, et al., “Delving Deeper into the Whorl of Flower Segmentation,” *Image Vision Computing*, vol.28, no.6, pp.1049–1062, 2010.
- [16] E. Zagrouba, et al., “Model-Based Graph-Cut Method for Automatic Flower Segmentation with Spatial Constraints,” *Image Vision Computing*, vol.32, no.12, pp.1007–1020, 2014.
- [17] A. Najjar, et al., “Flower image segmentation based on color analysis and a supervised evaluation,” *Proc. of ICCIT*, pp.397–401, 2012.
- [18] J. Zeng, et al., “Segmentation of Oilseed Rape Flowers Based on HSI Color Space and Local Region Clustering,” *Proc. of the Intl. Conf. on New Developments of IT, IoT and ICT Applied to Agriculture*, pp.227–232, 2021.
- [19] P. Lin, et al., “Detection of Strawberry Flowers in Outdoor Field by Deep Neural Network,” *Proc. of ICIVC*, pp.482–486, 2018.
- [20] Y. Tian, et al., “Instance segmentation of apple flowers using the improved mask R-CNN model,” *Biosystems Engineering*, vol.193, pp.264–278, 2020.
- [21] K. Sun, et al., “Apple, peach, and pear flower detection using semantic segmentation network and shape constraint level set,” *Computers and Electronics in Agriculture*, vol.185, pp.1–7, 2021.
- [22] X. Mu, et al., “Mask R-CNN based apple flower detection and king flower identification for precision pollination,” *Smart Agricultural Technology*, vol.4, no.100151, pp.1–10, 2023.
- [23] M. Afonso, et al., “Detection of Tomato Flowers from Greenhouse Images Using Colorspace Transformations,” *Proceedings of the EPIA Conference on Artificial Intelligence (AI)*, pp.146–155, 2019.
- [24] C. Zhang, et al., “Data-Driven Flower Petal Modeling with Botany Priors,” *Proc. of CVPR*, pp.636–643, 2014.
- [25] T. Ijiri, et al., “Floral diagrams and inflorescences: Interactive flower modeling using botanical structural constraints,” *ACM TOG*, vol.24, pp.720–726, 2005.
- [26] 仲 勇樹他, “花の 3 次元形状推定のための CT 画像を用いた花卉セグメンテーション,” *情報処理学会研究報告コンピュータビジョンとイメージメディア*, vol.2022-CVIM-230, no.13, pp.1–8, 2022.
- [27] H. Yang, et al., “CPR-GCN: Conditional Partial-Residual Graph Convolutional Network in Automated Anatomical Labeling of Coronary Arteries,” *Proc. of CVPR*, pp.3803–3811, 2020.
- [28] Y. Zhou, et al., “Prior-aware neural network for partially-supervised multi-organ segmentation,” *Proc. of ICCV*, pp.10672–10681, 2019.
- [29] Y. Wang, et al., “Deep Distance Transform for Tubular Structure Segmentation in CT Scans,” *Proc. of CVPR*, pp.3833–3842, 2020.
- [30] N. Masuzawa, et al., “Automatic Segmentation, Localization, and Identification of Vertebrae in 3D CT Images Using Cascaded Convolutional Neural Networks,” *Proc. of MICCAI*, pp.681–690, 2020.
- [31] H.J. Lee, et al., “Structure Boundary Preserving Segmentation for Medical Image With Ambiguous Boundary,” *Proc. of CVPR*, pp.4817–4826, 2020.
- [32] Q. Yu, et al., “C2FNAS: Coarse-to-Fine Neural Architecture Search for 3D Medical Image Segmentation,” *Proc. of CVPR*, pp.4126–4135, 2020.
- [33] I. Laradji, et al., “A Weakly Supervised Consistency-Based Learning Method for COVID-19 Segmentation in CT Images,” *Proc. of WACV*, pp.2453–2462, 2021.
- [34] Y. Zhou, et al., “CCT-Net: Category-Invariant Cross-Domain Transfer for Medical Single-to-Multiple Disease Diagnosis,” *Proc. of ICCV*, pp.8260–8270, 2021.
- [35] A. Kolesnikov, et al., “An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale,” *Proc. of ICLR*, pp.1–24, 2021.
- [36] A. Hatamizadeh, et al., “UNETR: Transformers for 3D Medical Image Segmentation,” *Proc. of WACV*, pp.574–584, 2022.
- [37] K. He, et al., “Mask R-CNN,” *Proc. of ICCV*, pp.2961–2969, 2017.
- [38] K. Chen, et al., “Hybrid Task Cascade for Instance Segmentation,” *Proc. of CVPR*, pp.4974–4983, 2019.
- [39] Z. Cai, et al., “Cascade R-CNN: Delving Into High Quality Object Detection,” *Proc. of CVPR*, pp.6154–6162, 2018.
- [40] A. Buades, et al., “A non-local algorithm for image denoising,” *Proc. of CVPR*, pp.60–65, 2005.
- [41] K. Chen, et al., “MMDetection: Open MMLab Detection Toolbox and Benchmark,” *arXiv preprint arXiv:1906.07155*, pp.1–13, 2019.
- [42] J. Deng, et al., “ImageNet: A large-scale hierarchical image database,” *Proc. of CVPR*, pp.248–255, 2009.
- [43] S. Xie, et al., “Aggregated Residual Transformations for Deep Neural Networks,” *Proc. of CVPR*, pp.1492–1500, 2017.
- [44] T.-Y. Lin, et al., “Feature Pyramid Networks for Object Detection,” *Proc. of CVPR*, pp.2117–2125, 2017.
- [45] D. Kingma, et al., “Adam: A Method for Stochastic Optimization,” *Proc. of ICLR*, pp.1–13, 2015.
- [46] I. Loshchilov, et al., “SGDR: Stochastic Gradient Descent with Warm Restarts,” *Proc. of ICLR*, pp.1–16, 2017.