

CT画像を用いたキクタニギクの小花配列の推定

松本壮史^{1†} 内海ゆづ子^{2†} 小塚俊明^{3††} 岩村雅一^{2†} 黄瀬浩一^{2†}
中井朋則^{4†††} 山内大輔^{4†††} 唐原一郎^{5††††} 峰雪芳宣^{6†††} 星野真人^{7†††††}
上杉健太郎^{7†††††}

† 大阪公立大学大学院情報学研究科

†† 金沢大学生命理工学系

††† 兵庫県立大学大学院理学研究科

†††† 富山大学理学部

††††† 高輝度光科学研究センター

E-mail: ¹sb22799f@st.omu.ac.jp, ²{yuzuko,masa,kise}@omu.ac.jp, ³kozukat@se.kanazawa-u.ac.jp,
⁴{nakait,dyamauch}@sci.u-hyogo.ac.jp, ⁵karahara@sci.u-toyama.ac.jp, ⁶mineyuki@gc4.so-net.ne.jp,
⁷{hoshino,ueken}@spring8.or.jp

あらまし 植物学の研究において、葉や花の成長する位置や数のような植物の構造を解析することは重要な意味を持つ。本研究では、キクタニギクと呼ばれる植物を対象とし、小花・花床と呼ばれる器官の接点を検出することで、キクタニギクの構造を可視化することを目指す。深層学習を用いて接点の検出および花床のセグメンテーションを行い誤検出を除去した後、クラスタリングにより接点の3次元位置の推定を試みた。実験の結果、花床上の接点の分布が可視化できた。

キーワード CT画像, 植物, 深層学習

1. はじめに

葉・花の長さや器官どうしの立体的な位置関係のような植物の持つ構造の解析は、形態情報による種の特定や分類、数理モデルの構築などに必要とされる。例えば、Shaiju らの研究 [1] では、野生の植物のサンプルを採取し、枝についている花の数や花のつく位置など、花序に関する特徴からサンプルの種の特定と分類を試みている。Yonekura らの研究 [2] では、葉の形成過程に関する幾つかの仮定と構造を表す特徴量をもとに数理モデルを提案し、葉序パターンの生成を試みている。植物の構造解析は、対象の植物を直接観察することにより行われることが多いが、対象の植物の3次元構造や内部構造が観察対象である場合や対象のサンプルが非常に小さい場合、Computed Tomography (CT) により得られたデータを元に観察が行われることがある [3]。

本研究では、キクタニギクを観察対象とし、CT画像を解析することで小花の3次元な配列を推定し可視化することを目標とする。図1はキクタニギクの構造を示したものである。キクタニギクは、中心から花床、小花、総苞と呼ばれる器官から構成される。小花の配列を推定するためには、花床と小花の接点を検出する必要がある。接点はサンプルの内部に存在し、またサンプル自体が非常に小さいことから、本研究ではCTボリュームデータを撮影し、ボリュームデータから切り出した断面のCT

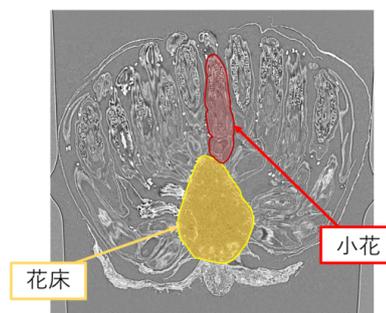


図1 キクタニギクの構造図

画像を解析することで小花の3次元な配列の推定および花床上における小花配列の可視化を試みる。

学習に基づく方法で接点を検出し3次元的に可視化するには、学習データとして3次元的な接点の正解データがあると望ましい。しかし、一般に3次元の正解データを作成するのは非常に困難である。また、植物のCTデータの公開データセットは少なく、さらに植物の種類により構造は大きく異なるため、公開データセットの利用も難しい。

そこで、本研究では3次元的な正解データではなく2次元的な正解データを利用し学習・検出する方法を提案する。提案手法ではまず、3次元CTデータからキクの中心軸を通るように断面のCT画像を切り出す。その後、断面画像のうち花床周り

の領域をクロップし、物体検出用のモデルに入力することで接点をバウンディングボックスとして検出する。また、花床上における小花配列の可視化のため、合わせて花床のセグメンテーションも行う。誤検出は主に花床の外側で起こるため、セグメンテーションにより花床のマスク画像を得たのち、花床との重なりを判定することで誤検出を除去する。最後に、検出結果を断面を切り出した位置をもとに3次元空間に復元し、クラスタリングによって異なる断面間の検出結果の統合を行う。実験の結果、花床上に接点が分布する様子を可視化できた。

2. 関連研究

CT画像を用いて植物の構造を調査した研究として、Liuらの研究[4]、Mathers[5]らの研究がある。Liuらは、果物の種子のCT画像を取得するシステムを構築し、種子の大きさや皮の厚さの取得を試みている。Mathersらは、CT画像を用いて植物の葉の内部の気孔率を算出し、空洞の可視化を試みた。これらの研究は本研究で扱う植物の器官領域を自動的に検出するタスクとは異なる。

植物のうち特に花を対象とし、CT画像を用いて3次元可視化のためのモデリング手法を提案したものにIjiriらの研究[6]がある。しかし、この手法は開いた構造を持つ花を対象としている。本研究で扱うキクタニギクのサンプルは総苞によって包まれており閉じた構造を持つため、Ijiriらの研究で提案された手法は利用することができない。

CT画像を対象に画像認識技術を用い、構造を解析した研究には、Wuらの研究[7]、Teramotoらの研究[8]がある。Wuらは、植木鉢に植えたイネのCT画像からイネの領域を3次元的に抽出し、倒伏に対する強度を定量的に評価する方法を提案している。Teramotoらは植木鉢に植えた植物の根のCT画像から根を抽出し、3次元的に可視化することを試みている。これらの研究は画像認識技術を用いているものの、周囲の育成環境を含む画像から植物のみを前景として抽出することを試みている。そのため、植物のうち特定の器官のみを抽出する本研究とは異なる。

3. 提案手法

3.1 CTボリュームデータからの画像の切り出し

CTボリュームデータを解析するために、ボリュームデータから断面の画像を切り出す必要がある。しかし、切り出し方によっては、花床や小花が写っていない、花床と小花の境界が明瞭でないなど、検出に望ましくない画像が得られる場合がある。また、切り出す位置によっては画像の見た目が大きく異なるために、検出精度の低下を引き起こしうる。本研究ではキクタニギクが花床を中心として回転対象な構造をしていることを利用し、花床と小花の接点が明瞭かつ、画像の見た目の変化が小さくなるような切り出し方法を提案する。

図2に切り出し方の概略を示す。図2(a)のキクタニギクの3次元CTデータの緑の円は、キクタニギクを囲む円柱の底面を表す。提案手法の切り出し方法を3次元データの上から見た様子が図2(b)であり、赤線が断面を切り出す方向を示す。提案手

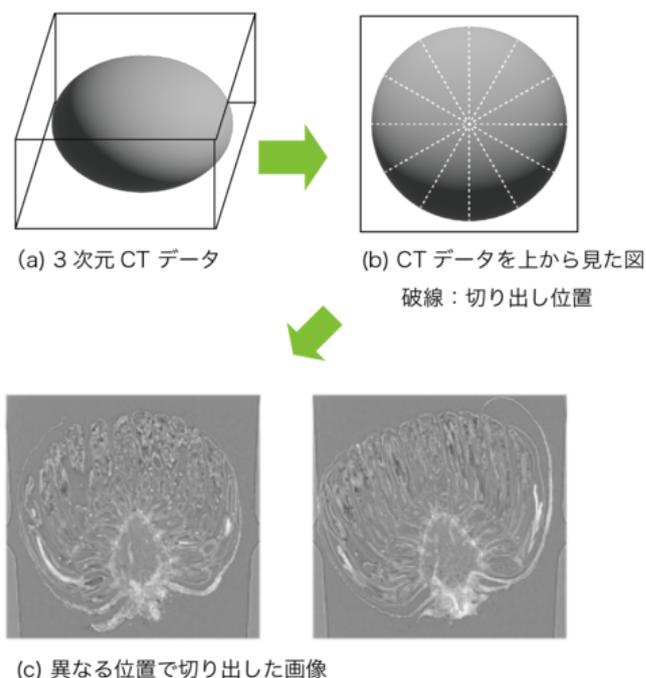


図2 提案手法による断面の切り出し

法で切り出された断面画像を図2(c)に示す。提案手法で切り出された画像中には花床と小花の両方が写っており、花床と小花の境界が明瞭である。切り出す位置が異なっても画像の見た目の変化が小さいことが分かる。

3.2 接点の検出

本研究では、CTボリュームデータから切り出した画像に対し物体検出手法を適用することで、花床と小花の接点をバウンディングボックスとして検出させる。適用する物体検出手法は、代表的な手法であるYOLOv5[9]である。接点の領域の大きさは花床と比べて小さいため、花床周りの領域で画像をクロップした後、YOLOv5に画像を入力する。なお、検出結果には誤検出が含まれる場合があるため、後述の花床のセグメンテーション結果と合わせることで、花床の外に生じた誤検出を除去する。

3.3 花床のセグメンテーション

花床上に接点が分布する様子を可視化するため、接点の検出と合わせて花床領域のセグメンテーションを行う。本研究で扱うタスクは各ピクセルを背景クラスと花床クラスの2クラスに分類するセマンティックセグメンテーションに該当する。セグメンテーションに用いる手法は、セマンティックセグメンテーションの代表的な手法であるU-Net[10]である。得られた花床の領域から、断面を切り出した位置を元に、花床を3次元的に可視化する。

3.4 誤検出の除去

接点の検出結果にはfalse positiveが含まれる場合がある。false positiveは主に花床の外側の領域で生じるため、花床のセグメンテーションで得られた花床領域と重なっていない検出結果を誤検出として除去する。

3.5 接点の3次元位置の推定

接点の3次元位置を推定するには、個々の断面について得ら

れた2次元的な検出結果を3次元空間に移す必要がある。提案手法の画像の切り出し方法において、ボリュームデータにおける断面を切り出した位置はわかっているため、これをもとに接点の検出結果を3次元空間に移す。それぞれの断面における検出結果のうち、3次元的には同じ接点に対応するグループがある。本研究では、クラスタリングにより同じ接点に対応する検出結果を各クラスタに分け、同じクラスタに含まれる検出結果の重心を接点の3次元位置の推定結果とする。

クラスタリングには、階層クラスタリング手法の1つである群平均法を利用する。階層クラスタリングは、はじめに各データ点をそれぞれ1つのクラスタとし、クラスタ間の距離をもとに、最も距離の近いクラスタどうしを併合することを繰り返す。群平均法では、クラスタ間の距離として、クラスタに含まれるデータ点間の距離の平均を用いる。群平均法において、併合を一定の基準に基づいて停止することで、クラスタリング結果が得られる。本研究では、クラスタ間の最小距離が閾値以上になった場合に停止するものとした。なお、この閾値は手動で設定する。

4. 実験

本研究では、学習サンプルとテストサンプルが同じであり、サンプルの一部の断面を学習し残りの断面を予測する場合と学習サンプルとテストサンプルが異なる場合の2つのシナリオについて接点の検出精度、花床のセグメンテーション精度を算出した。また、真の接点の個数とクラスタリング後のクラスタ数とを比較することで、クラスタリングの妥当性について検証した。

4.1 データセット

本研究では、11個のキクタニギクのサンプルのCTボリュームデータを用いた。CTボリュームデータは大型放射光施設SPring-8のビームラインBL20B2のハッチ1で撮影された。撮影原理とシステムはUesugiらの手法[11]に基づく。撮影の際、Yamauchiらの研究[12]において、X線エネルギーをサンプルごとに変化させた。サンプルはすべて凍結・乾燥処理済みである。また、各サンプルの断面を図3に示す。ChrGjS600およびChrGjS601は成長段階前期のサンプルであり小花が他のサンプルと比べて短く、他のサンプルは成長段階後期のサンプルである。ボリュームデータから、提案手法の切り出し方法でスライス画像を作成した。まず、IMOD[13]を用いてボリュームデータからスタック画像を作成した。Chrgojo02以外のサンプルは花床がおおよそボリュームデータの鉛直上方向を向いており、中心に位置していた。そのため、画像中心を軸として、スタック画像から最近傍補完により切り出す角度を0.05度変えながら3,600枚のスライス画像を作成した。Chrgojo02は花床が鉛直上方向を向くようにボリュームデータを回転させたのち、他のサンプルと同様にして画像中心を軸とし3,600枚のスライス画像を作成した。

ChrGjS600, ChrGjS601, ChrGjL600, ChrGjL601の4サンプルそれぞれについて、切り出す角度が7.5度ずつ異なるようにそれぞれ24枚のスライス画像について花床領域および接点

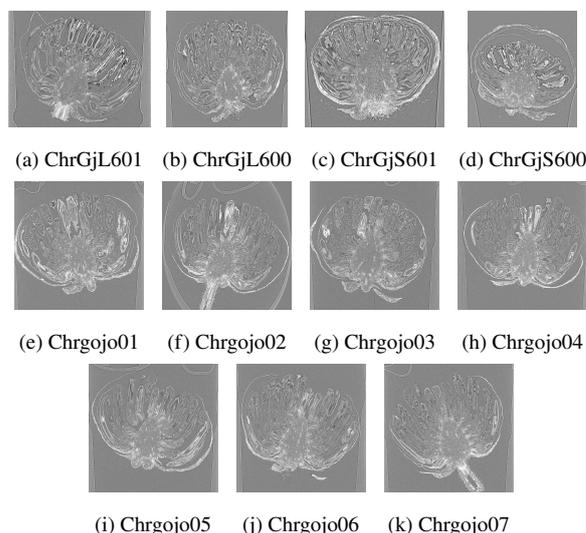


図3 キクタニギクのサンプル

の正解データを作成した。同様にしてChrgojo01, Chrgojo02, Chrgojo03, Chrgojo04, Chrgojo05, Chrgojo06, Chrgojo07については45度ずつ異なるようにそれぞれ4枚ずつ正解データを作成した。また、接点の検出のため、各サンプルごとに作成した画像を花床周りでクロップした。クロップする領域はサンプルごとに手動で決定した。

4.2 学習サンプルとテストサンプルが同じ場合

ChrGjL600, ChrGjL601, ChrGjS600, ChrGjS601を対象として、学習サンプルとテストサンプルが同じ場合における接点の検出精度、花床のセグメンテーション精度、およびクラスタリングの妥当性について検証した。

4.2.1 接点の検出

4.1においてサンプルごとに作成した24枚の画像を花床周りでクロップした画像を用い、Leave-One-Out (LOO) 交差検証により、接点の検出精度を算出した。使用したモデルはCOCOデータセット[14]で学習済みのYOLOv5である。クロップ後の24枚の画像のうち、23枚を反転させることで、反転前・反転後合わせて46枚の画像を作成したのち、データ拡張により2,300枚の画像を作成した。これらの2,300枚の画像を学習に用い、24枚のうち残りの1枚の画像で精度を算出することを24通り繰り返し、平均精度を算出した。学習において、エポック数は25、バッチサイズは16とし、学習率は 10^{-3} から 10^{-4} まで、25エポックかけて線形に減少させた。また、最適化アルゴリズムにはAdamを用いた。ネットワークに画像を入力する際には、画像を640×640ピクセルにリサイズした。

表1にLOO交差検証の平均精度を示す。精度の指標はCOCOデータセットにて用いられているAPである。APは、検出結果を確信度順にソートし得られた累積のprecisionとrecallを元に以下で算出される。ここで、 $p(r)$ はrecallが r のときのprecisionの値を表す。

$$AP = \int_0^1 p(r) dr$$

また、APを算出するために、IoUを元に検出結果が正解かどうか

表 1 LOO 交差検証における接点の検出精度

サンプル名	AP(0.5:0.95)	AP50	AP75
ChrGjL601	0.4218	0.8898	0.3341
ChrGjL600	0.5167	0.9382	0.4908
ChrGjS601	0.5552	0.9510	0.5872
ChrGjS600	0.3441	0.7791	0.2283

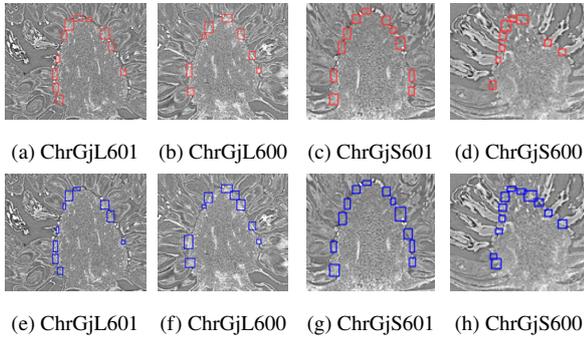


図 4 接点の検出結果と正解ラベルとの比較

か決定する必要がある。IoU は 2 つの領域の重なり具合を表す指標であり、領域 P と G に対して以下で計算される。ここで、記号 $|\cdot|$ は領域内に含まれるピクセル数を表す。

$$IoU(P, G) = \frac{|P \cap G|}{|P \cup G|}$$

AP50, AP75 は、正解ラベルと検出結果のバウンディングボックスの IoU の値が 0.5 以上、0.75 以上の場合に正解としたときの AP を表す。また、AP(0.5:0.95) と示したものは、正解とみなす IoU の値を 0.5 から 0.95 まで、0.05 刻みで変化させたときの AP の平均値を表す。図 4 に予測結果の例と正解ラベルとの比較を示す。上段が予測結果であり、下段が正解ラベルである。

4.2.2 花床のセグメンテーション

4.2.1 と同様にして LOO 交差検証により花床のセグメンテーション精度を算出した。なお、LOO 交差検証に使用する 24 枚の画像はクロップしていない画像である。ネットワークには U-Net を用いた。Encoder 部分は ImageNet [15] で学習済みの VGG16 [16] とした。学習するエポック数は 25 とし、バッチサイズは 32、学習率は 10^{-4} で固定とした。また、学習における最適化アルゴリズムには Adam を用いた。ネットワークに画像を入力する際には、画像を 512×512 ピクセルのサイズにリサイズした。精度の評価指標は Dice 係数とした。Dice 係数は 2 つの領域の重なり具合を表す指標であり、領域 P と G に対する Dice 係数は以下で定義される。

$$Dice(P, G) = \frac{2|P \cap G|}{|P| + |G|}$$

LOO 交差検証における平均 Dice 係数を表 2 に示す。また、図 5 に予測結果の例と正解ラベルとの比較を示す。上段が予測結果であり、下段が正解ラベルである。

4.2.3 誤検出の除去

4.1 にて作成した 24 枚の画像から、クロップ後、クロップ前のそれぞれについてデータ拡張により 2,400 枚の画像を作成し、YOLOv5, U-Net を学習させた。その後、花床のセグメン

表 2 LOO 交差検証における花床のセグメンテーション精度

サンプル名	Dice 係数
ChrGjL601	0.9761
ChrGjL600	0.9810
ChrGjS601	0.9745
ChrGjS600	0.9640

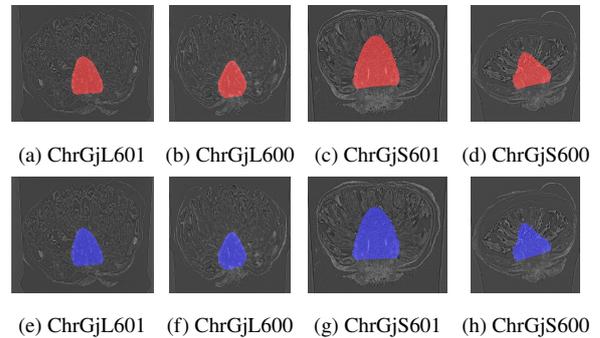
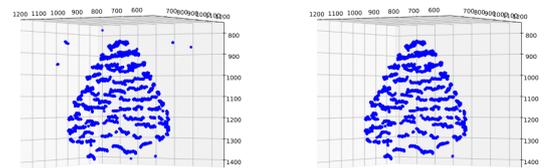


図 5 LOO 交差検証における花床のセグメンテーション結果



(a) 誤検出の除去前 (b) 誤検出の除去後

図 6 ChrGjL600 の誤検出の除去

表 3 学習サンプルとテストサンプルが同じ場合のクラスタ数と真の接点の個数

サンプル名	閾値						真の接点の数
	1	10	20	30	40	50	
ChrGjL601	6006	428	205	132	103	101	108
ChrGjL600	6589	444	208	126	97	96	95
ChrGjS601	4955	329	145	99	95	91	93
ChrGjS600	4098	307	134	104	95	64	100

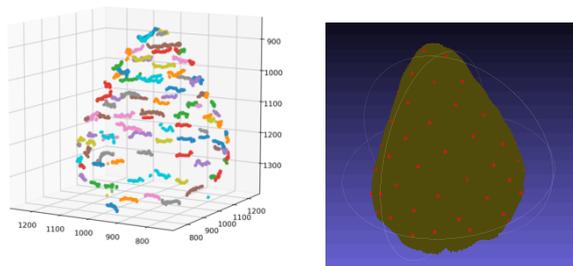
テーション結果を用いて接点の誤検出を除去した。ChrGjL600 について、誤検出の除去前後の検出結果を 3 次元空間にプロットした様子を図 6 に示す。

4.2.4 クラスタリングの妥当性の評価

4.2.3 で誤検出を除去したのち、ChrGjL600, ChrGjL601, ChrGjS600, ChrGjS601 の 4 つのサンプルの検出結果を 3 次元空間に復元し群平均法によるクラスタリングを適用した。表 3 に、クラスタリングにおける閾値を変化させた時のクラスタ数と真の接点の数を示す。また、図 7(a) に ChrGjL600 の閾値を 50 に設定した場合におけるクラスタリング結果、図 7(b) に (a) のクラスタ中心を小花の配列の推定結果として花床上にプロットした様子を示す。

4.3 学習サンプルとテストサンプルが異なる場合

学習サンプルとして、ChrGjL600, ChrGjL601, ChrGjS600,



(a) 各クラスタの分布 (b) 推定した小花配列

図7 ChrGjL600のクラスタリング結果

ChrGjS601の4つを用い、Chrgojo01, Chrgojo02, Chrgojo03を学習の過程で用いる検証用データとして、Chrgojo04, Chrgojo05, Chrgojo06, Chrgojo07を精度計測用のテストデータとして用いたときの接点の検出精度および花床のセグメンテーション精度を算出し、テストデータに用いるサンプルを対象としてクラスタリング結果の妥当性について検証した。

4.3.1 接点の検出

4.2.1 で用いた ChrGjL600, ChrGjL601, ChrGjS600, ChrGjS601の4つのサンプルのそれぞれ24枚の画像から左右反転により48枚の画像を作成し、データ拡張により合計9,600枚の画像を作成した。作成した9,600枚の画像を学習に用い、Chrgojo04, Chrgojo05, Chrgojo06, Chrgojo07に対する接点の検出精度を算出した。学習における学習係数と最適化アルゴリズム、エポック数は4.2.1と同様である。検証用のサンプルおよびテストサンプルの接点の検出精度を表4に示す。なお、精度の算出には、すべての学習エポックのうち、最も検証用データに対する検出精度が高いエポックでのネットワーク重みを使用した。

4.3.2 花床のセグメンテーション

4.3.1と同様にして、Chrgojo04, Chrgojo05, Chrgojo06, Chrgojo07に対し花床のセグメンテーション精度を算出した。学習における学習係数と最適化アルゴリズム、エポック数は4.2.2と同様である。Chrgojo04, Chrgojo05, Chrgojo06, Chrgojo07の花床のセグメンテーション精度を表5に示す。なお、精度の算出には、すべての学習エポックのうち、最も検証用データにおける検出精度が高いエポックでのネットワーク重みを使用した。

4.3.3 クラスタリングの妥当性の評価

テスト用のサンプルであるChrgojo04, Chrgojo05, Chrgojo06, Chrgojo07を用い、誤検出除去後の検出結果を対象に群平均法によるクラスタリングを適用した。表6に閾値を変化させたときの各サンプルのクラスタ数と真の接点の数を示す。

5. 考 察

接点の検出は、AP(0.5:0.95), AP50, AP75の3つの指標で精度の検証を行った。本研究においては、AP50の値が高ければ十分である。これは、クラスタリングにおいて接点は大きさ

表4 学習サンプルとテストサンプルが異なる場合の接点の検出精度

	サンプル名	AP(0.5:0.95)	AP50	AP75
val	Chrgojo01	0.4746	0.9557	0.3754
	Chrgojo02	0.3993	0.8946	0.3073
	Chrgojo03	0.4671	0.9374	0.3945
test	Chrgojo04	0.5151	0.8992	0.5998
	Chrgojo05	0.5344	0.9442	0.5705
	Chrgojo06	0.5487	0.9647	0.5437
	Chrgojo07	0.2937	0.7957	0.1473

表5 学習サンプルとテストサンプルが異なる場合の花床のセグメンテーション精度

	サンプル名	Dice 係数
val	Chrgojo01	0.9551
	Chrgojo02	0.9577
	Chrgojo03	0.9671
test	Chrgojo04	0.9664
	Chrgojo05	0.9616
	Chrgojo06	0.9662
	Chrgojo07	0.9618

表6 学習サンプルとテストサンプルが異なる場合のクラスタ数と真の接点の個数

サンプル名	閾値						真の接点の数
	1	10	20	30	40	50	
Chrgojo04	10334	621	282	187	127	116	115
Chrgojo05	8080	494	226	153	106	96	106
Chrgojo06	10769	620	274	186	120	111	114
Chrgojo07	8620	540	263	178	126	111	111

を持つデータではなく点としての表現で十分であり、検出におけるバウンディングボックスの大小は重要でなく、少なくとも接点がバウンディングボックス内部にあることが重要であることによる。LOO交差検証においては、AP50について比較的高い精度での検出を達成した。しかし、成長段階前期のサンプルであるChrGjS600の検出精度は成長後期のサンプルであるChrGjL600, ChrGjL601と比較して低かった。これは、ChrGjS600の花床と小花の境界があいまいであることによると考えられる。学習サンプルとテストサンプルが異なる場合においても、AP50について高い精度で接点が検出できた。

花床のセグメンテーションは、LOO交差検証、および学習サンプルとテストサンプルが異なる場合の両方において、正解のマスク画像とほとんど変わらないセグメンテーション結果が得られた。解析対象のCT画像において花床の領域が比較的大きいため、サンプルごとに花床の形状が多少異なっても高い精度でのセグメンテーションが可能だったと考えられる。

得られた花床のマスク画像をもとに、提案手法の方法で花床から離れた検出結果を除去することができた。接点の検出精度が向上すれば誤検出は少なくなるものの、後処理として誤検出を減らせるため有効であると考えられる。

クラスタリングの結果の妥当性は, ChrGjL600, ChrGjL601, ChrGjS600, ChrGjS601, Chrgojo04, Chrgojo05, Chrgojo06, Chrgojo07 の 8 サンプルについて, 真の接点の数とクラスタ数を比較することで行った. 3次元空間に検出結果をプロットした結果, いくつかの検出結果が1つの帯状に分布していた. これらは3次元的に1つの接点に対応すると考えられる. 実際, 帯状の分布が1つのクラスタになるように群平均法の閾値を調整することで, 真の接点の個数に近いクラスタ数が得られた. 閾値を設定せず自動で推定するためには, 帯状の分布の形状に適した基準を設計する必要がある.

6. 結 論

本研究では, キクタニギクの花の3次元的な配列を可視化することを目標とした. キクタニギク内部の構造が可視化対象であるため, CT データを撮影し, 花床と小花の接点の検出および花床のセグメンテーションを試みた. 3次元的な正解データの作成が困難であるため, 2次元的に CT 画像を処理し, クラスタリング後のクラスタ中心によって3次元位置を推定した. 実験の結果, 接点の検出は, 学習サンプルとテストサンプルが同じ場合においても, 学習サンプルとテストサンプルが異なる場合においても比較的高い精度で行えた. また, 花床のセグメンテーションについては, 花床領域が比較的画像中で大きいことから, 正解データとほとんど完璧に一致する精度で可能であった. さらに, 3次元空間に帯状に分布する検出結果が1つのクラスタとなるように群平均法における閾値を調整することで, 真の接点の個数に近い値のクラスタ数が得られ, クラスタリングの妥当性が検証できた.

本研究の提案手法で可視化したデータを用い, キクタニギクの成長段階における小花の分布の変化の過程や, 小花の分布の規則性の有無, および数理モデルの構築が可能となると考えられる.

謝辞 本研究は JSPS 科研費 JP22H04732 の助成を受けたものである. X線 CT 観察は JASRI 利用課題 2018B1182, 2022B1143 で行った.

文 献

- [1] Shaiju Pushpangadan and N Omanakumari. Inflorescence morphology. *Systematics and Biodiversity*, Vol. 7, pp. 445–451, 2010.
- [2] Takaaki Yonekura, Akitoshi Iwamoto, Hironori Fujita, and Munetaka Sugiyama. Mathematical model studies of the comprehensive generation of major and minor phyllotactic patterns in plants with a predominant focus on orixate phyllotaxis. *PLoS computational biology*, Vol. 15, No. 6, 2019.
- [3] Saoirse R. Tracy, José Fernández Gómez, Craig J. Sturrock, Zoe A. Wilson, and Alison C. Ferguson. Non-destructive determination of floral staging in cereals using X-ray micro computed tomography (μ CT). *Plant Methods*, Vol. 13, No. 1, 2017.
- [4] Weizhen Liu, Chang Liu, Jingyi Jin, Dongye Li, Yongping Fu, and Xiaohui Yuan. High-throughput phenotyping of morphological seed and fruit characteristics using x-ray computed tomography. *Frontiers in Plant Science*, Vol. 11, , 2020.
- [5] Andrew W. Mathers, Christopher Hepworth, Alice L. Baillie, Jen Sloan, Hannah Jones, Marjorie Lundgren, Andrew J. Fleming, Sacha J. Mooney, and Craig J. Sturrock. Investigating the microstructure of plant leaves in 3D with lab-based X-ray computed tomography. *Plant Methods*, Vol. 14, No. 1, 2018.
- [6] Takashi Ijiri, Shin Yoshizawa, Hideo Yokota, and Takeo Igarashi. Flower modeling via x-ray computed tomography. *ACM Trans. Graph.*, Vol. 33, No. 4, pp. 48:1–48:10, July 2014.
- [7] Di Wu, Dan Wu, Hui Feng, Lingfeng Duan, Guoxing Dai, Xiao Liu, Kang Wang, Peng Yang, Guoxing Chen, Alan P. Gay, John H. Doonan, Zhiyou Niu, Lizhong Xiong, and Wanneng Yang. A deep learning-integrated micro-CT image analysis pipeline for quantifying rice lodging resistance-related traits. *Plant Communications*, Vol. 2, No. 2, 2021.
- [8] Shota Teramoto, Satoko Takayasu, Yuka Kitomi, Yumiko Arai-Sanoh, Takanari Tanabata, and Yusaku Uga. High-throughput three-dimensional visualization of root system architecture of rice using X-ray computed tomography. *Plant Methods*, Vol. 16, No. 1, 2020.
- [9] Glenn Jocher, Ayush Chaurasia, Alex Stoken, Jirka Borovec, NanoCode012, Yonghye Kwon, Kalen Michael, TaoXie, Jiacong Fang, imyhxy, Lorna, 曾逸夫 (ZengYifu), Colin Wong, Abhiram V, Diego Montes, Zhiqiang Wang, Cristi Fati, Jebastin Nadar, Laughing, UnglvKitDe, Victor Sonck, tkianai, yxNONG, Piotr Skalski, Adam Hogan, Dhruv Nair, Max Strobel, Mrinal Jain. ultralytics/yolov5: v7.0 - YOLOv5 SOTA Realtime Instance Segmentation, November 2022.
- [10] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-Net: Convolutional Networks for Biomedical Image Segmentation. In *Proceedings of Medical Image Computing and Computer-Assisted Intervention*, pp. 234–241, 2016.
- [11] Kentaro Uesugi, Masato Hoshino, Akihisa Takeuchi, Yoshio Suzuki, Naoto Yagi, and Tsukasa Nakano. Development of fast (sub-minute) micro-tomography. *AIP Conference Proceedings*, Vol. 1266, No. 1, pp. 47–50, 2010.
- [12] Daisuke Yamauchi, Daisuke Tamaoki, Masato Hayami, Miyuki Takeuchi, Ichirou Karahara, Mayuko Sato, Kiminori Toyooka, Hiroshi Nishioka, Yasuko Terada, Kentaro Uesugi, Hidekazu Takano, Yasushi Kagoshima, and Yoshinobu Mineyuki. Micro-CT observations of the 3D distribution of calcium oxalate crystals in cotyledons during maturation and germination in *Lotus miyokojimae* seeds. *Microsscopy*, Vol. 62, No. 3, pp. 353–361, 2013.
- [13] J R Kremer, D N Mastronarde, and J R McIntosh. Computer visualization of three-dimensional image data using IMOD. *J. Struct. Biol.*, Vol. 116, No. 1, pp. 71–76, January 1996.
- [14] Tsung-Yi Lin, Michael Maire, Serge Belongie, Lubomir Bourdev, Ross Girshick, James Hays, Pietro Perona, Deva Ramanan, C. Lawrence Zitnick, and Piotr Dollár. Microsoft coco: Common objects in context, 2015.
- [15] Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. Imagenet: A large-scale hierarchical image database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 248–255, 2009.
- [16] Karen Simonyan and Andrew Zisserman. Very Deep Convolutional Networks for Large-Scale Image Recognition. In *Proceedings of International Conference on Learning Representations*, 2015.