画像認識によるウキクサ科植物の表面積と総枚数の推定

奥田 萌莉† 石澤 秀紘†† 大島 裕明†

† 兵庫県立大学大学院情報科学研究科 〒 651-2197 兵庫県神戸市西区学園西町 8-2-1
†† 兵庫県立大学大学院工学研究科 〒 671-2280 兵庫県姫路市書写 2167
E-mail: †moeriena.abc@gmail.com, ††ishizawa@eng.u-hyogo.ac.jp, †††ohshima@ai.u-hyogo.ac.jp

あらまし 本研究では、ウキクサ科植物の一種であるコウキクサに対して、葉の表面積と総枚数を出力する手法を提 案する.入力はコウキクサの画像であり、出力は葉の表面積と総枚数である.表面積を出力するために、連結した葉 群であるコロニーを領域認識し、認識された領域内の面積を計算した.総枚数を出力するために、コロニーに対して 各枚数を推定し、合計した.本研究では、コロニーの形と色から、画像認識モデルを用いて、各枚数を推定した.本研 究の貢献は、表面積推定の正確性を向上させた点と、葉の形と色の特徴を組み合わせることで、総枚数推定の MAE が 0.172 となり、特徴 1 つのみを用いて認識するよりも結果が良くなることを示した点である.

キーワード 画像認識, インスタンスセグメンテーション, 深層学習

1 はじめに

植物を用いた水質浄化はファイトレメディエーション [19] と 呼ばれ,環境汚染の改善策として広く実施されている.ファイ トレメディエーションは植物を用いない水質浄化手法に比べて, 安価なコストなどのメリットがある.

ウキクサ科植物は水中の有害物質である窒素やリンを吸収 しながら増殖するため、ファイトレメディエーションに役立 つ[12].以下より、ウキクサ科植物をウキクサと記載する.ウ キクサが増殖する際には、葉が出芽し始め、数枚の葉が連結し た状態で水面に浮遊する.この連結した数枚の葉のことをコロ ニーと呼ぶこととする.コロニーの例を図1に示した.

ウキクサを有効活用するためには、適切な量を管理すること が重要である.量を管理できると、植物学者がウキクサの管理 をしやすくなるといえる.ウキクサを扱う研究では、表面積と 枚数を重要な指標として、ウキクサの量や増殖速度を評価して いることが多い [27] [12].

本研究では、ウキクサの量を表す指標として、葉の表面積と 総枚数を推定する問題に取り組んだ.ここで、表面積と総枚数 について例を図2に示した.表面積は図2の左画像において白 色で塗りつぶした領域の面積である.総枚数は図2の右画像に おいては10枚と数えられる.

表面積と総枚数を推定する際には、それぞれに課題がある. 表面積を推定する研究では、既存のソフトウェアを用いて計測 する場合が多いが、正確とは言い難い.たとえば ImageJ と呼 ばれるソフトウェアが用いられる.このようなソフトウェアを 用いてウキクサを認識するときには、葉と葉の間の水面を間違 えて葉と認識しやすい.さらに総枚数を推定する研究では、深 層学習を用いて自動的に推定する方法は確立されていない.

特に総枚数の推定において,隣の葉に部分的に隠れている葉 を認識することは難しい課題である.本研究では,コロニー内 の葉の枚数が多いほど,コロニーの形が複雑になり,色は濃く



図1 コロニーの例



図 2 表面積と総枚数の例

なる傾向にある点に注目した.具体的には、コロニーの形と色 それぞれを表す画像を作成し、組み合わせて機械に学習させ、 総枚数を推定した.

図3に、本研究の全体像を示した.本研究の入力は、図6に 示した、ウキクサ科植物の一種のコウキクサが写っている画像 である.この画像には複数のコロニーが含まれている.出力は、 表面積と総枚数である.まず、図3の桃色箇所で示したように、 コロニーの領域を認識した.認識された領域内を白色で表し、 白色部分のみの面積を求めた.これを表面積として出力した. 次に、図3の水色箇所で示したように、コロニーごとの葉の枚 数を推定した.推定された枚数を合計し、合計枚数を総枚数と して出力した.以上のようにして、表面積と総枚数を出力した. 本研究は、以下の2つの課題で構成される.

- コロニーの領域認識
- コロニー内の枚数推定



図3 表面積と総枚数の推定手法

本研究の貢献は,表面積推定の正確性を向上させた点と,葉 の形と色の特徴を組み合わせることで,総枚数推定の MAE が 0.172 となり,特徴 1 つのみを用いて認識するよりも結果が良 くなることを示した点である.

2 関連研究

本研究では,画像認識を用いたウキクサの表面積と総枚数の 推定を扱う.本節では,葉の領域認識や葉の様々な特徴量を用 いた画像認識について説明する.

2.1 葉の領域認識

まず,領域認識と同義といえるセグメンテーション手法につ いて説明する. セグメンテーション手法は,インスタンスセグ メンテーションとセマンティックセグメンテーションの2種類 に大別される.インスタンスセグメンテーションとは,インス タンスの領域を認識するタスクを解く問題であり,セマンティッ クセグメンテーションとは,クラスの領域を認識するタスクを 解く問題である.本研究では,ウキクサのコロニーそれぞれを インスタンスとして領域認識する必要がある.よって本研究で は,ウキクサのコロニーの領域認識問題を,インスタンスセグ メンテーションとして扱う.

インスタンスセグメンテーションには, Mask R-CNN [6], DeepMask [18], FCIS [13] などが用いられる. Mask R-CNN は, 画像に対して, 決められた種類の物体を認識してその位置 とクラス名を特定し, なおかつ画像中のピクセル単位で物体の 写っている領域を特定するマルチタスクモデルである. ここで, Mask R-CNN は, DeepMask に比べて, 対象物体の領域のみ に対してプーリングするという特徴がある.

セマンティックセグメンテーションには, Fully Convolutional Network [15] や SegNet [2], PSPNet [7] などが用いられる. た とえば PSPNet は, CNN と Pyramid Pooling Module で構成 されている. Pyramid Pooling Module では, CNN から得ら れる特徴ベクトル全体, 1/3, 1/2, 1/6 の 4 つに分け, それぞ れの大きさで特徴を抽出している. これらのベクトルを全て結 合し, 全結合層に入れ, 出力を得る.

葉の領域認識に関する先行研究として, Kabir ら [9] の研究と Liu ら [14] の研究を紹介する. Kabir らは, セグメンテーショ ン手法を用いて葉の病気診断に取り組んだ. 葉の部分と葉以外 の部分をそれぞれ白黒で表した二値画像を作成し,SVM に学 習させた.結果は,AP が 91.89%であったと報告されている. Liu らは,葉の面積を Watershed アルゴリズムと呼ばれる手法 を用いて求める問題に取り組んだ.Watershed アルゴリズムと は,画像の輝度勾配を山と谷の地形図に見立て,そこに水を流 すことを想定した時に,水を貯める分水嶺を対象物体の輪郭と して判定する手法のことである.結果は,大津二値化[4]を用 いた時よりも誤差率が 2.2%減少したと報告されている.

2.2 葉の様々な特徴量を用いた画像認識

葉の様々な特徴量を用いた画像認識に関する文献を紹介する. 以下の研究では,葉の全体や形の特徴に注目して画像認識を 行っている.以下の研究はすべて,樹木種の葉の画像を入力と する研究である.

葉の全体の特徴に注目した画像分類に関する研究としては, 葉の画像から病気を診断する研究が盛んに行われている. 葉の 病気診断に対して,クラスごとにおける枚数の偏り[21],Data Augmentation [5],複雑な背景の除去[23]といった課題が取り 組まれてきた.このような課題はすべて,分類の正解率を向上 させることを目的としている.本研究では,訓練データに画 像認識モデルが過剰に適応してしまう過学習を避けるために, Data Augmentation を行った.

葉の形の特徴に注目した樹木種の同定に関する研究を紹介す る. Kumar ら [11] は葉の形を表す座標を用いることで葉の画 像から樹木種を同定した. 上位 5 位以内に該当樹木が入ってい る割合は 96.8%であった. Kumar らは LeafSnap が公開してい るデータセットを対象に研究を行った. このデータセットを用 いて,葉の形のみでなく葉脈に注目した研究 [17] も行われた. 本研究で用いたデータセットはウキクサであるため,両者の分 類結果を比較することはできない.

さらに,葉の様々な特徴を組み合わせた樹木種の同定に関する 研究も行われてきた.Wuら[26]は,複数の特徴量を組み合わせ て,ブドウの樹木種を同定した.色,HSV[1],葉脈,HOG[22] の4つの特徴量を抽出し,組み合わせた.樹木種の正解率は 92.5%と報告されている.ValliammalとGeethalakshmi[24] は,葉の形,色,葉脈の特徴を組み合わせて樹木種を同定した. この手法をPLIRと呼んでいる.その結果,94.0%の正解率が 得られたと報告されている.Bama[3]は,45種類の樹木種を 同定するための新しい手法を提案した.この手法は,葉の形, 色,葉脈の特徴量を組み合わせた手法である.これらの特徴を 用いることで,正解率は97.9%と報告されている.これらいず れの研究においても,深層学習を用いていない.

以上より,葉の画像を入力とした画像認識技術では,葉の全 体や形などの,葉の様々な特徴量を組み合わせて深層学習モデ ルに学習させることの有用性を示すことが課題といえる.

3 データとその前処理

本節では,本研究で用いたデータとその前処理について述べる.

3.1 コウキクサのデータセット

本研究では、コウキクサを独自で栽培し、画像を大量に取得 した.取得した画像数は全部で 1,085 枚である.図4 にコウキ クサの栽培装置を示した.スチールラック4 段の各段に、くぼ み6 個が付いているシャーレを3 個ずつ置き、各くぼみに 1/2 Schenk and Hildebrandt 培地 [20] を 10ml 入れ、水面にコウ キクサを浮かべて栽培した.各段の上部に光強度約 26 ワット の LED ライトを取付け、照射時間を 20 時間/日、16 時間/日、 12 時間/日、8 時間/日の4 種類にした.

本研究では、図5で示したように、Web カメラでコウキクサ のシャーレのくぼみ1つ分を撮影した.撮影された画像を512 ピクセル×512 ピクセルの正方形に形成し直した.形成方法に ついて以下に説明する.まず、円を検出するハフ変換によって、 Web カメラで撮影した元画像からくぼみに沿った円を作成し た.次に、円の部分を囲ったバウンディングボックスを作成し た.このバウンディングボックスを元画像に適用して切り取り、 512 ピクセル×512 ピクセルにリサイズした.最後に、このリ サイズされた画像の円以外の部分をグレーに変換した.以上の 処理によって、図6のような512 ピクセル×512 ピクセルの 正方形に形成し直した.この画像をシャーレ画像と呼ぶことと する.さらに、シャーレ画像において、コロニーごとに画像を 切り分けた.コロニーごとに切り分けられた画像をコロニー画 像と呼ぶこととする.

シャーレ画像とコロニー画像に対して、ラベル付けを行った. 行ったラベル付けは、以下の2種類である.

- コロニーの領域のラベル付け
- コロニー内の枚数のラベル付け

シャーレ画像に対して上記における前者のラベル付けを、コ ロニー画像に対して後者のラベル付けを行った.まず、コロニー の領域のラベル付けについて説明する.1枚のシャーレ画像に 対し、labelme と呼ばれるラベル付けツールを用いて、葉の領 域のラベル付けを行った. このラベル付けでは、コロニーの輪 郭を点で縁取る作業を行った.次に、コロニー内の枚数のラベ ル付けについて説明する.1枚のコロニー画像に対し、3人そ れぞれでラベル付けを行い、多数決によって、葉の枚数を決定 した.3人によるラベル付けの値が一致しなかったコロニー画 像 124 枚を含む,シャーレ画像 98 枚を取り除いた.たとえば, 3人によるラベル付けの値がそれぞれ 12, 14, 16 であった場 合は、このコロニー画像を含むシャーレ画像を取り除いた. コ ロニー画像内の枚数の分布を図7に示した.すべての画像は1 から 21 までの範囲でラベル付けされた.シャーレ画像内の総 枚数の分布を図 8 に示した. すべての画像は1から 80 までの 範囲となった.

シャーレ画像とラベル付けされた値のペアデータセットを無 作為に訓練データ、検証データ、テストデータに8:1:1に分 割した.表1にそれぞれの画像の枚数を示した.全画像の枚 数は987枚であり、訓練データは790枚、検証データは98枚、 テストデータは99枚となった.



図 4 コウキクサの栽培装置



図 5 コウキクサの撮影装置



図 6 シャーレ画像

3.2 画像の前処理の詳細

本節では、コロニーの形と色に注目した画像の作成方法について述べる.コロニー画像の葉の部分を白色、葉以外の部分を 黒色にした画像を作成した.この画像を**形画像**と呼ぶこととす る.コロニー画像の葉以外の部分を黒色に統一した画像を作成 した.この画像を**背景切り取り画像**と呼ぶこととする.図9に、 画像の前処理の詳細を述べた.

3.2.1 形画像の作成方法

コロニー画像から,形を表す形画像を作成した.形画像の詳 細を以下に示す.

- 葉の部分が白く背景の部分が黒い二値画像
- 1枚のコロニー画像に対して1枚
- 256 ピクセル × 256 ピクセル

まず、コロニー画像の葉の部分を白色、葉以外を黒色にする







図8 シャーレ画像における葉の総枚数の分布





図 9 画像の前処理

ことによって,白黒の二値画像を作成した.次に,この二値画 像が中心箇所となるように,256 ピクセル × 256 ピクセルの 画像を作成した.この画像を形画像と呼ぶこととする.形画像 は,葉の部分が白,葉以外の部分がすべて黒色の256 ピクセル × 256 ピクセルの画像である. 3.2.2 背景切り取り画像の作成方法

コロニー画像の葉以外を黒色に統一し,背景切り取り画像を 作成した.背景切り取り画像の詳細を以下に示す.

- 葉以外が黒色の画像
- 1枚のコロニー画像に対して1枚
- 256 ピクセル × 256 ピクセル

まず,形画像の葉以外の部分と,コロニー画像の葉の部分を 組み合わせた.具体的には,コロニー画像と同じサイズの画像 を新たに用意し,二値画像の黒い部分を貼り付けた.さらにそ の画像に,コロニー画像の葉の部分を貼り付けた.このように して,二値画像の葉以外の部分と,コロニー画像の葉の部分を 組み合わせた画像を作成した.次に,この組み合わせた画像が 中心箇所となるように,256 ピクセル×256 ピクセルの画像を 作成した.この画像を背景切り取り画像と呼ぶこととする.背 景切り取り画像は,葉以外の部分がすべて黒色の256 ピクセル ×256 ピクセルの画像である.

4 コウキクサの表面積と総枚数の推定

本節では、本研究の問題定義と、コウキクサの表面積と総枚 数の推定手法について述べる.表面積の推定の際には、深層学 習モデルである Mask R-CNN を用いた場合と、葉の緑色を抽 出するソフトウェアである ImageJ を用いた場合の結果を比較 した.総枚数の推定の際には、コロニーの形と色それぞれを表 す画像を組み合わせることで、深層学習モデルを用いて推定 した.

4.1 問題定義

本研究ではコウキクサの画像から画像に写っている葉の表面 積と総枚数を推定する問題に取り組む.本研究における入力は シャーレ画像であり,出力はシャーレ画像内の葉の表面積と総 枚数である.

- 入力 シャーレ画像
- 出力 表面積と総枚数

たとえば,図6のシャーレ画像を入力すると,表面積は 14.28cm²,総枚数は10枚となることを目指す.

4.2 表面積の推定手法の構築

コウキクサの表面積を推定するための手法について述べる. 表面積の推定手法を図 10 に示した.入力はシャーレ画像であ り,出力は葉の表面積である.

領域認識モデルには、大量の画像を用いて事前学習されたも のが使われるのが一般的である.この事前学習済みモデルとし て、本研究では Mask R-CNN を用いた. Mask R-CNN に対 して、COCO データセットと呼ばれる大量の画像を用いて事 前学習されたネットワークを用いた.この事前学習では、80 ク ラス約 20 万枚の物体に対して領域認識を行っている.

コウキクサのデータセットを事前学習済み Mask R-CNN に 学習させた.シャーレ画像と、コロニーの領域の座標値のペア データセットを学習させた.学習において、適用させた Data Augmentation は全4種類である.画像を 0.5~1 倍にリサイ



図 10 表面積の推定手法

ズ,画像の輝度を 0.5~1.5 倍に調整,画像のコントラストを 0.5~1.5 倍に調整,平行移動を適用させた.推論では,コウキ クサのコロニーの領域の座標値を推定した.さらに,その領域 を白色,領域以外の部分を黒色で表す二値画像を作成し,白色 部分のみのピクセル数を求めた.ここで,512 ピクセルの正方 形であるシャーレ画像は,3.55cmの正方形と対応している.つ まり,262,14 ピクセルが 15.28cm² と対応付けられる.よって, 計算された合計ピクセルから計算される表面積を出力した.

コウキクサの葉の緑色を抽出することによる領域認識も行った.本研究では、ImageJ¹というソフトウェアを用いた.以下 に、ImageJ における領域認識方法の詳細を述べる.まず画像 を、色空間の一種である Lab 色空間に変換する.次に、Lab 色 空間の a*にあたる、葉とそれ以外を表す二峰性の分布を取得 し、最小値を閾値とすることで二値化した [8].二値化された画 像は、葉の部分が白色、葉以外の部分が黒色である.白い部分 のみの面積を求めた.

4.3 総枚数の推定手法の構築

コウキクサの総枚数を推定するための手法について述べる. 入力はシャーレ画像であり,出力は総枚数である.シャーレ画 像から作られたコロニー画像内の枚数を推定し,その枚数を合 計することで,総枚数を出力した.

4.3.1 背景切り取り画像を用いた手法

コロニー画像から作られた背景切り取り画像を画像認識モデ ルに入力し,画像内のコロニー内の枚数を推定した.図 11 に 全体像を示した.本研究では,4 種類の Data Augmentation を適用させた.ランダム回転(0度~360度),平行移動,シ アー変換,ズーム変換を適用させた.

画像認識モデルには大量の画像をもちいて事前学習されたもの が使われるのが一般的である.この事前学習済みモデルの一部が 特徴抽出器と呼ばれる.この特徴抽出器として,ResNet152 [7] の一部をもちいた.ResNet152 は,CNN と1層の全結合層で 構成されているといえる.CNN の部分を特徴抽出器,全結合 層の部分を分類器と呼ぶこととする.さらにResNet152 に対 して,ImageNetと呼ばれる大量の画像をもちいて事前学習し たネットワークを用いた.この事前学習では,1,000 クラス分 類を行っている.特徴抽出器から得られるベクトルは2,048 次 元である.事前学習では,このベクトルを分類器に通し,1つ の値を推定する. 本研究では,特徴抽出器の重みを更新させることでファイン チューニングを行った [16].特徴抽出器の後に,2層の全結合 層を追加した.全結合層のノード数を,それぞれ 512 と 1 とし た.ノード数が 512 の全結合層は ReLU を活性化関数とした. ノード数が 1 の全結合層は Softmax を活性化関数とした.

構築した画像認識モデルに,コロニー画像を入力し,枚数を 出力した.最終的に,1枚のシャーレ画像に対する,各コロニー 内の枚数を合わせた総枚数を出力した.



図 11 背景切り取り画像を用いた総枚数の推定手法



図 12 形画像を用いた総枚数の推定手法



図 13 背景切り取り画像と形画像を組み合わせた総枚数の推定手法

1: ImageJ: https://imagej.net/ij/index.html

4.3.2 形画像を用いた手法

コロニー画像から作られた形画像を画像認識モデルに入力し, 画像内のコロニー内の枚数をを推定した.図12に全体像を示 した.画像認識モデルの構造は4.3.1節で説明したものと同一 である.ただし,4.3.1節における葉の全体が写っている画像 ではなく,形画像を画像認識モデルに入力する.4.3.1節で説 明した5種類のData Augmentationを適用させた.学習時は, 特徴抽出器の重みを更新させることで,ファインチューニング を行った.

構築した画像認識モデルに,コロニー画像を入力し,枚数を 出力した.最終的に,1枚のシャーレ画像に対する,各コロニー 内の枚数を合わせた総枚数を出力した.

4.3.3 背景切り取り画像と形画像を組み合わせた手法

図 13 に背景切り取り画像と形画像を組み合わせた画像認識 モデルの概略を示した.同図の緑色で示した 2 つの特徴抽出器 は再学習せず,4.3.1 節と4.3.2 節で説明したものをそのまま 用いた.この学習方法は転移学習 [25] と呼ばれる手法である. 提案手法では,3 種類の特徴抽出器を利用することとなる.そ れらの特徴抽出器の学習は個別に行うため,GPU で学習を行 うとして,一度に必要な GPU メモリは個別の特徴抽出器が乗 れば十分である.すなわち,提案手法では,3 つの特徴抽出器 すべてを GPU メモリに一度に乗せることができる GPU が必 要というわけではない.また,推論時は,データ量が入力され た画像 1 枚であるため,計算コストが高くなく,かならずしも GPU を用いた高速な計算を行う必要がない.そのため,低い マシン性能であっても結果を出力することができる.

葉の色と形を組み合わせた手法では、背景切り取り画像と形 画像の特徴を網羅的に考慮して総枚数を推定した.まず、コロ ニー画像から1枚の背景切り取り画像と1枚の形画像を作成し た.次に、図13の緑色の特徴抽出器をもちいてそれぞれの画 像をベクトル化した.よって、背景切り取り画像と形画像それ ぞれにおける特徴ベクトルが合計2つ得られた.最後に、これ ら2つのベクトルを結合させた.

特徴抽出器の後に Dropout 層と全結合層 2 層の合計 3 層を 追加した. Dropout 率は 0.5 とした. 全結合層のノード数をそ れぞれ 512 と 1 とした. ノード数が 512 の全結合層は ReLU を活性化関数とした. ノード数が 1 の全結合層は Softmax を 活性化関数とした.

構築した画像認識モデルに、コロニー画像を入力し、枚数を 出力した.最終的に、1枚のシャーレ画像に対する、各コロニー 内の枚数を合わせた総枚数を出力した.

5 実 験

本節では,学習の実験設定,結果と考察,評価について述 べる.

5.1 実験設定

本研究の実験設定について説明する.本研究では深層学習モデルとして, Mask R-CNN と ResNet152 を用いた.

表 2 コウキクサのデータセットの Mask R-CNN への学習結果

評価指標	スコア(%)		
AP	74.12		
AP50	92.78		
AP75	81.25		
APs	49.14		
APm	76.34		



図 14 Mask R-CNN への学習結果例

Mask R-CNN へのコウキクサのデータセットの学習につい ては、以下のハイパーパラメータで実験を行った.

- 最適化関数: Adam [10]
- 学習率: 0.00025
- イテレーション数: 20,000

ResNet152 へのコウキクサのデータセットの学習について は、以下のハイパーパラメータで実験を行った.

- 最適化関数: Adam
- 学習率: 0.00001
- 損失関数: MSE loss

5.2 結果と考察

まず,コウキクサの表面積の推定における結果と考察を述 べる.図14に、学習の結果例を示した.表2に、学習の評価 結果を示した.AP, AP50, AP75, APs, APm はそれぞれ, 74.12, 92.78, 81.25, 49.14, 76.34 となった.AP50 がもっと もよい結果となった.図15に、正解データにおける表面積と Mask R-CNN によって求めた表面積の相対誤差,正解データ における表面積と ImageJ によって求めた表面積の相対誤差の 分布を示した.相対誤差とは、正解データにおける表面積との ピクセル数の誤差を、正解データにおける表面積のピクセル数 で割った数値である.相対誤差は以下の式で表される.

相対誤差 =
$$\frac{pred - true}{true}$$

Mask R-CNN における相対誤差の平均は 0.024, 標準偏差は 0.061 であった. Mask R-CNN による結果では, 図 15 におけ る青色の分布が左に偏っていることから, 過小評価する傾向 にあるといえる. ImageJ における相対誤差の平均は –0.0021, 標準偏差は 0.175 であった. ImageJ による結果では, 図 15 に おける橙色の分布が右に偏っていることから, 過大評価する傾向にあるといえる. 相対誤差の平均と標準偏差ともに, Mask



図 15 Mask R-CNN と ImageJ における相対誤差の分布



図 16 Mask R-CNN の方が ImageJ よりも結果が良い例



図 17 ImageJ の方が Mask R-CNN よりも結果が良い例

R-CNN における絶対値が ImageJ よりも小さくなったことか ら, Mask R-CNN の方がより良い結果になったといえる. さ らに, Mask R-CNN による推定では,曲線の領域に強い傾向 がある一方で,エッジ部分の推定に弱い傾向がある. ImageJ による推定では,角ばった箇所に強い一方で,正解箇所以外の 細かい部分を誤認識したり,小さな領域を認識しずらかったり, 近くにある正解箇所同士をつなげて誤認識したりする傾向があ る.図16 に, Mask R-CNN の結果が ImageJ よりも良かった 例を示した.図17 に, ImageJ の結果が Mask R-CNN よりも 良かった例を示した.以上より,Mask R-CNN による推定で は,正解データよりも狭い範囲で領域推定している傾向がある といえる.一方で,ImageJ による認識では,正解データより も広い範囲で領域認識している傾向があるといえる.

次に、コウキクサの総枚数の推定における結果と考察を述べ る. 正解データにおける総枚数と予測された総枚数の相対誤差 を比較した. ここでの相対誤差とは、正解データにおける総枚 数と予測された総枚数の誤差を、正解データにおける総枚数で 割った数値である.背景切り取り画像を用いた手法における相

表	3	表面積	の学	と習糸	も わちょう しょうしん ちょうしん ちょうしん ちょうしん しんしょう しんしん ちょうしん ちょうしん しんしょう しんしょ しんしょ
1	•			- H 49	-1/15

	ImageJ	Mask R-CNN
表面積における MAE	0.112	0.083
表面積における RMSE	0.163	0.123

表 4 総枚数の学習結果

	背景切り取り画像	形画像	組み合わせ
コロニー画像における MAE	0.393	0.402	0.373
コロニー画像における RMSE	0.433	0.446	0.401
シャーレ画像における MAE	0.186	0.195	0.172
シャーレ画像における RMSE	0.195	0.204	0.181

対誤差の平均は –0.034, 標準偏差は 0.175 であった. 形画像 を用いた手法における相対誤差の平均は –0.064, 標準偏差は 0.185 であった. 背景切り取り画像と形画像を組み合わせた手 法における相対誤差の平均は –0.005, 標準偏差は 0.171 であっ た. 背景切り取り画像と形画像を組み合わせた手法における相 対誤差の平均と標準偏差ともに, もっとも良い結果となった.

5.3 評 価

本節では,コウキクサの表面積と総枚数それぞれの推定についての評価を説明する.表面積と総枚数の推定のどちらにおいても,相対誤差を用いた MAE と RMSE を求めた.相対誤差を用いた MAE と RMSE は以下の式で表される.

$$MAE = \frac{1}{n} \sum_{i=1}^{n} \left| \frac{pred_i - true_i}{true_i} \right|$$
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{n} \left(\frac{pred_i - true_i}{true_i} \right)^2}$$

まず,コウキクサの表面積の推定における評価を述べる. それぞれの手法における,相対誤差を評価指標とした MAE, RMSE を求めた.表3に表面積の推定における評価結果を示し た. Mask R-CNN を用いた手法において,MAE, RMSE はそ れぞれ 0.083, 0.123 となった.すべての評価において,Mask R-CNN を用いた手法の方が ImageJ を用いた手法よりも結果 が良かった.

次に、コウキクサの総枚数の推定における評価を述べる. それ ぞれの手法における、相対誤差を評価指標とした MAE, RMSE を求めた. 表4に、コロニー画像における枚数、シャーレ画像 に対する総枚数の推定における評価結果を示した. コロニー画 像における MAE と RMSE、シャーレ画像における MAE と RMSE を求めた. 背景切り取り画像と形画像を組み合わせた 手法において、コロニー画像における MAE, RMSE はそれぞ れ 0.373, 0.401 であった. 同じく背景切り取り画像と形画像 を組み合わせた手法において、シャーレ画像における MAE, RMSE はそれぞれ 0.172, 0.181 であった. すべての評価にお いて、背景切り取り画像と形画像を組み合わせた手法がその他 の手法らよりも結果が良かった.

6まとめ

本研究では、ウキクサ科植物の一種であるコウキクサに対し て、葉の表面積と総枚数を推定する手法を提案した.入力はコ ウキクサの画像であり、出力は葉の表面積と総枚数である.

本研究の貢献は、表面積推定の正確性を向上させた点と、葉 の形と色の特徴を組み合わせることで、総枚数推定の MAE が 0.172 となり、特徴 1 つのみを用いて認識するよりも結果が良 くなることを示した点である.本研究で構築した技術は、ウキ クサの量を機械が推定する有用性を示すことへとつながる.今 後、ウキクサの量の管理を機械にも行える可能性が示されたと いえる.

謝 辞

本研究は JSPS 科研費 JP21H03775, JP21H03774,

JP21H03554, JP22H03905 の助成を受けたものです. ここに 記して謝意を表します.

文 献

- A. Ajmal, C. Hollitt, M. Frean, and H. Al-Sahaf. A comparison of rgb and hsv colour spaces for visual attention models. In *Proceedings of the 2018 International Conference on Image and Vision Computing New Zealand*, pp. 1–7, 2018.
- [2] V. Badrinarayanan, A. Kendall, and R. Cipolla. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39:13–27, 2015.
- [3] B. Bama, M. Valli, S. Raju, and V. A. Kumar. Content based leaf image retrieval (cblir) using shape, color and texture features. *Indian Journal of Computer Science and En*gineering, 2:202–211, 2011.
- [4] J. T. Barron. A generalization of otsu's method and minimum error thresholding. In *Proceedings of the 2020 European Conference on Computer Vision*, pp. 455–470, 2020.
- [5] G. Geetharamani and A. J. Pandian. Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Computers and Electrical Engineering*, 76:323– 338, 2019.
- [6] K. He, G. Gkioxari, P. Dollár, and R. Girshick. Mask r-cnn. In Proceedings of the 2018 Conference on Computer Vision and Pattern Recognition, pp. 1–12, 2018.
- [7] K. He, X. Zhang, S. Ren, and J. Sun. Deep residual learning for image recognition. In *Proceedings of the 2016 Conference on Computer Vision and Pattern Recognition*, pp. 770–778, 2016.
- [8] H. Ishizawa, M. Tada, M. Kuroda, D. Inoue, and M. Ike. Performance of plant growth-promoting bacterium of duckweed under different kinds of abiotic stress factors. *Biocatalysis and Agricultural Biotechnology*, 19:1–38, 2019.
- [9] R. Kabir, S. Jahan, M. R. Islam, N. Rahman, and M. R. Islam. Discriminant feature extraction using disease segmentation for automatic leaf disease diagnosis. In *Proceed*ings of the 2020 International Conference on Computing Advancements, pp. 1–7, 2020.
- [10] D. P. Kingma and J. Ba. Adam: A method for stochastic optimization. In Proceedings of the 2015 International Conference on Learning Representations, 2015.
- [11] N. Kumar, P. N. Belhumeur, A. Biswas, D. W. Jacobs, W. J. Kress, I. C. Lopez, and J. V. B. Soares. LeafSnap: A computer vision system for automatic plant species identifica-

tion. In Proceedings of the 2012 European Conference on Computer Vision, pp. 502–516, 2012.

- [12] E. Landolt. Biosystematic Investigations in the Family of Duckweeds (Lemnaceae). Geobotanischen Institute, 1986.
- [13] Y. Li, H. Qi, J. Dai, X. Ji, and Y. Wei. Fully convolutional instance-aware semantic segmentation. In Proceedings of the 2016 Conference on Computer Vision and Pattern Recognition, pp. 1–9, 2016.
- [14] Z. Liu, C. Liu, and J. Chen. Method for measuring leaf area of brassica napus using image analysis. Proceedings of the 2021 International Conference on Computer Science and Application Engineering, 88:1–6, 2021.
- [15] J. Long, E. Shelhamer, and T. Darrell. Fully convolutional networks for semantic segmentation. In *Proceedings of the* 2015 Conference on Computer Vision and Pattern Recognition, pp. 1–8, 2015.
- [16] A. Lucas. Deep perceptual losses and self-supervised finetuning for image and video super-resolution. Northwestern University, 2020.
- [17] E. Mata-Montero and J. Carranza-Rojas. A texture and curvature bimodal leaf recognition model for identification of costa rican plant species. In *Proceedings of the 2015 Latin American Computing Conference*, pp. 1–12, 2015.
- [18] P. O. Pinheiro, R. Collobert, and P. Dollar. Learning to segment object candidates. In Proceedings of the 2015 Conference on Computer Vision and Pattern Recognition, pp. 1–10, 2015.
- [19] K. Raisa, V. P. I. Sylas, K. C. S. Praveen, A. P. Thomas, and K. R. Shanthiprabha. Role of heavy metal tolerant rhizosphere bacteria in the phytoremediation of Cu and Pb using Eichhornia Crassipes (Mart.) Solms. *International Journal* of Phytoremediation, 24:1120–1132, 2021.
- [20] R. U. Schenk and A. V. Hildebrand. Medium and techniques for induction and growth of monocotyledonous and dicotyledonous plant cell cultures. *Canadian Journal of Botany*, 50:1–7, 1972.
- [21] T. Su, S. Mu, M. Dong, W. Sun, and A. Shi. An improved tradaboost for image recognition of unbalanced plant leaf disease. In *Proceedings of the 2019 International Conference on Computing and Pattern Recognition*, pp. 374–379, 2019.
- [22] J. Tang, Q. Su, C. Lin, Y. Wen, B. Su, and J. Yang. Traffic sign recognition based on hog feature and svm. In Proceedings of the 2020 International Conference on Electronic Information Technology and Computer Engineering, pp. 534– 538, 2020.
- [23] L. Thi-Lan, D. Nam-Duong, N. Van-Toi, V. Hai, H. Van-Nam, and N. Thanh-Nhan. Complex background leaf-based plant identification method based on interactive segmentation and kernel descriptor. In *Proceedings of the 2015 International Workshop on Environmental Multimedia Retrieval*, pp. 3–8, 2015.
- [24] N. Valliammal and S. N. Geethalakshmi. Efficient feature fusion, selection and classification technique for plant leaf image retrieval system. In Proceedings of the 2012 International Conference on Computational Science, Engineering and Information Technology, pp. 132–137, 2012.
- [25] K. Weiss, T. M. Khoshgoftaar, and D. Wang. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22:1345–1359, 2010.
- [26] Y. Wu, J. Wu, and G. Hu. MMFS: A grape disease rcognition method based on multi-feature fusion and svm. In Proceedings of the 2020 International Conference on Cloud and Big Data Computing, pp. 27–31, 2020.
- [27] Y. Yin, C. Yu, L. Yu, J. Zhao, C. Sun, Y. Ma, and G. Zhou. The influence of light intensity and photoperiod on duckweed biomass and starch accumulation for bioethanol production. *Bioresource Technology*, 187:84–90, 2015.