

# 多様な特徴抽出に基づく葉の画像分類

奥田 萌莉<sup>1,a)</sup> 大島 裕明<sup>1,b)</sup>

**概要：**本研究では、樹木の葉の画像を自動的に分類する問題に取り組む。近年、画像分類の問題においては、大量の画像で学習された既存の深層学習モデルをもちいて、転移学習やファインチューニングを行うことで、効率よく分類を行うことができるようになってきている。葉の画像分類においても、同様の方法で取り組むことが可能である。一方で、葉の画像分類においては、葉の特徴を、葉の全体、葉の輪郭、葉の葉脈など、様々な側面に着目して取得することが可能である。異なる側面に着目した際に、分類のしやすさが異なってくると考えられる。そこで、本研究では、まず、葉の特徴の様々な側面に着目した特徴抽出器を作成し、それをもちいた葉の画像分類を行った。その結果、着目する側面によって、分類の正解の傾向が異なることが示された。そこで、それらの特徴を全て組み合わせることによって、葉の特徴の様々な側面を網羅的に考慮した分類器を作成した。その結果、分類の性能が向上することが示された。

**キーワード：**画像分類, 特徴エンジニアリング, 深層学習

## Plant Leaf Image Classification based on Various Feature Extraction

### 1. はじめに

樹木は地球上に存在する重要な生物である。人間は樹木と密接なかかわりをもちながら発展してきたといえる。なぜなら、樹木は光合成を行うことで、人間や人間の活動が放出する二酸化炭素を酸素に変えることを行っているからである。樹木の外観は種類によってさまざまであり、種類によって異なるが、それを見分けることは容易ではない。樹木の種類を判別するときには、花、幹、実といった特徴に着目することもできるが、より一般的には葉に注目することが効果的であるといえる [1], [2], [3]。しかし、葉の外見も、季節や生息地の違いによって異なる場合があったり、異なる樹木の葉が類似していたりすることもある [4]。すなわち、人間が目視で葉を識別することは、専門家であっても困難である場合があるということである。一例をあげると、クスノキとシロダモの葉の外見は非常に酷似しており、深い知識と注意深い観察がないと区別できない。

そのような状況の中、近年、葉の写真から樹木の種類を判別できるアプリケーションが出現している。たとえば、

LeafSnap というアプリケーションでは、葉の写真スマートフォン等で撮影して送信することで、樹木の種類を知ることができる。このようなアプリケーションでは、葉の画像分類の問題を解いているといえる。画像分類の問題においては、大量の画像で学習された既存の深層学習モデルをもちいて、転移学習やファインチューニングを行うことで、効率よく分類を行うことができるようになってきている。葉の画像分類においても同様の方法で取り組むことが可能である [5]。

本研究でも、樹木の葉の画像を入力として、樹木の種類を判別する問題に取り組む。葉の画像分類においては、葉の特徴を、葉の全体、葉の輪郭、葉の葉脈など、様々な側面に着目して取得することが可能である。異なる側面に着目した際には、樹木の種類によっては、分類のしやすさが異なるようになることが考えられる。そこで、本研究では、まず、葉の特徴の様々な側面に着目した特徴抽出器を作成し、それをもちいた葉の画像分類を行う。さらに、それらの特徴を全て組み合わせることによって、葉の特徴の様々な側面を網羅的に考慮して分類を行う。その結果、分類の性能が向上することが示された。

図 1 は、提案手法の流れの概略を表したものである。入力は 1 枚の葉の画像である。本研究では、単葉が鮮明に

<sup>1</sup> 兵庫県立大学 情報科学研究科  
Graduate School of Information Science, University of Hyogo

a) ad21d034@gsis.u-hyogo.ac.jp

b) ohshima@ai.u-hyogo.ac.jp

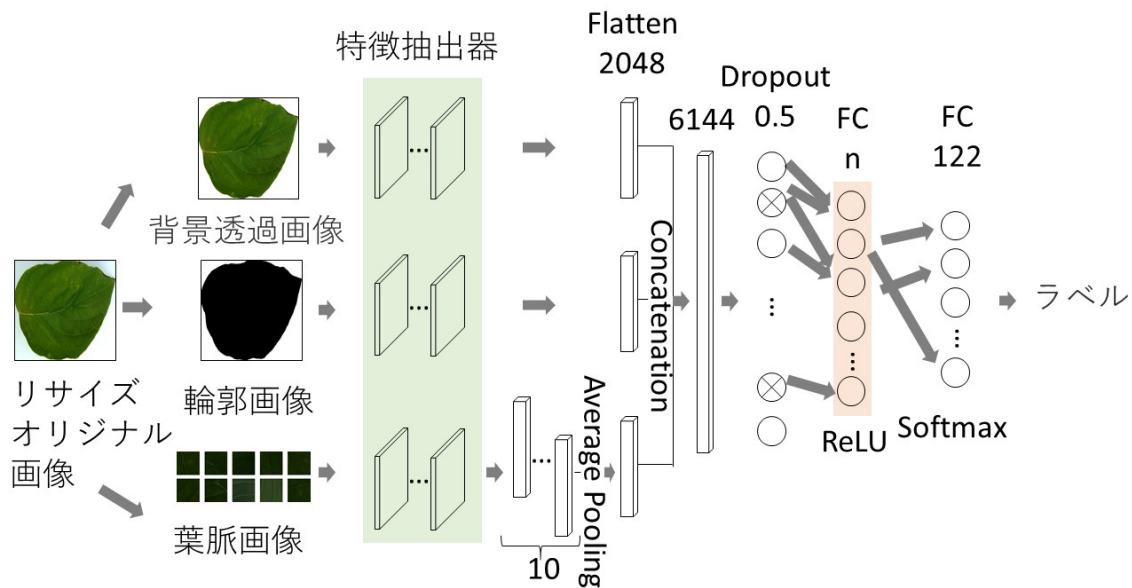


図 1 提案手法の概要. 緑色で示した特徴抽出器には, それぞれの特徴量画像単独で分類したときに学習させた特徴抽出器の重みをそのままちいる.

写っているような画像が入力されると想定する. 入力画像に対して前処理を行い, リサイズオリジナル画像と呼ぶ  $512\text{pixel} \times 512\text{pixel}$  の画像を作成する. リサイズオリジナル画像から, 葉の全体, 輪郭, 葉脈の特徴に着目した 3 つの画像を作成する. それぞれを, 背景透過画像, 輪郭画像, 葉脈画像と呼ぶ. これら 3 つをまとめて, 特徴量画像と呼ぶ. 図の特徴抽出器とは, それぞれの画像データから特徴ベクトルを作成する深層学習モデルのことである. 3 つの画像はそれぞれの特徴抽出器を通して, flatten された特徴ベクトルを取得する. 得られる特徴ベクトルは, 背景透過画像と輪郭画像では, それぞれ 1 つであり, 葉脈画像では 10 個である. 葉脈画像から得られた 10 個の特徴ベクトルはその平均を取った特徴ベクトルに変換する. 以上で, 背景透過画像, 輪郭画像, 葉脈画像から, それぞれ 1 つずつの特徴ベクトルが得られる. それら 3 つの特徴ベクトルを結合する. 最後に, その結合された特徴ベクトルを全結合層で構成された分類器を通すことで, 樹木の種類であるラベルが出力される.

提案手法でもちいる特徴抽出器は, それぞれの特徴量画像を単独でもちいて分類を行った場合のものをそのままちいることとする. すなわち, 図 1 においては, オレンジ色で示した分類器の部分のみを学習することとなる. いわゆる転移学習の一種であると考えてよい.

本研究は, 葉の画像分類において, 様々な側面に着目した特徴それぞれが, 分類性能の向上に資する事例があるということを明らかにし, それらの特徴を組み合わせるとい特徴エンジニアリングを行うことによって, 分類性能が向上するということを示したものであるといえる.

## 2. 関連研究

近年, 様々な応用分野における分類問題が, 深層学習を中心とする機械学習技術をもちいて解かれている. それは葉の画像分類の問題においても同様である. 本研究では, 樹木の葉のさまざまな特徴量を組み合わせることにより, 分類の性能向上を目指す. ここでは葉の画像分類に関する研究について紹介する.

LeafSnap の論文 [6] では, 葉の輪郭から特徴量を構成し, Nearest Neighbor 法をもちいて分類を行うことで樹木の種類の認識を行った. 上位 5 位以内に正解となる種類が含まれている割合は 96.8%であったと報告されている.

Kamrul ら [7] は, 5 種類の紅茶の葉を分類するタスクに取り組んだ. 特徴抽出器として, Inception-V2, VGG16 と, 提案手法もちいられ, 正解率はそれぞれ 96.28%, 92.23%, 95.23%であったと報告されている.

Wu [8] は, Kaggle の葉の分類コンペティションで提供されている 99 種類の葉の画像データをもちいて, 葉の画像を分類する問題に取り組んだ. 分類器として, SVM, K 近傍法, 線形判別分析, ランダムフォレストをもちいた. これらの分類器のハイパーパラメータは, K 分割交差検証で最適化させた. 検証データの正解率, テストデータの正解率, 実行時間の 3 つを比較した結果, 線形判別分析がもっとも高い正解率となった. また, 線形判別分析での分類がもっとも短い実行時間であった.

Tan ら [9] は, 葉の分類を行うための新たな CNN モデルを提案した. それは, D-Leaf という特徴抽出器である. これをもちいて, 熱帯樹 43 種類の分類を行った. D-Leaf は,

すべてで6層のCNNであり、畳み込み層と全結合層が3層ずつで構成されている。D-Leaf, 事前学習済みの AlexNet, ファインチューニング済みの AlexNet, 3種類の特徴抽出器をもちいた。さらに, SVM, ニューラルネットワーク, K近傍法, 単純ベイズ, Tanら独自によって訓練されたCNNを分類器としてもちいた。これら3種類の特徴抽出器と5種類の分類器を組み合わせた。その結果, D-Leafは94.88%, 事前学習済みの AlexNetは93.26%, ファインチューニング済みの AlexNetは95.54%であった。また, いずれの特徴抽出器をもちいても, ニューラルネットワークを分類器とした場合がもっとも正解率が高かった。以上より, D-Leafは熱帯樹の分類に適している可能性が示された。

Wuら[10]は, 4種類のぶどうの葉の主な病気分類を行った。マルチスケールの特徴量融合とSVMによる手法で解決を試みた。それぞれの葉の画像に対する指向勾配(HOG)の色, HSV, テクスチャ, ヒストグラムの4つの特徴を抽出した。次に, 主成分分析によって次元を減らし, 特徴量ベクトルを結合させた。特徴量ベクトルでSVMを訓練し, 訓練された分類器を全ての画像データセットにおける病気の自動認識に適用させた。正解率は92.5%であった。以上より, Wuらの提案手法は, ぶどうの葉の病気認識の正解率の向上に効果的であった。

### 3. 利用したデータとその前処理

本節では, 利用したデータの概要と, その前処理の方法について説明する。

#### 3.1 データの概要

LeafSnapでは, 184種類の樹木のデータセットを公開しており\*1, 本研究ではこのデータセットを用いた。それぞれの樹木の種類に対して, 葉の画像の枚数の平均は41.95, 標準偏差は25.57である。

本研究では, データセット全体における184種類7,719枚の画像から, マツ科32種類, ヒノキ科5種類, スギ科1種類, 複葉の画像24種類, 合計62種類について, もちいるデータから取り除くこととした。これら62種類を取り除いた理由は, 本研究で用いる葉脈画像を作成することができず, 葉脈画像の特徴量を用いることによる効果を検証することが難しくなるからである。結果として, 本研究では122種類4,791枚の画像をもちいることとした。

#### 3.2 リサイズオリジナル画像の作成

データセットにおける葉の画像は, 白い背景に一枚の葉が置かれた画像である。この画像をオリジナル画像と呼ぶこととする。前処理として, オリジナル画像から, 葉の部



図2 LeafSnap データセットから取り除いた画像の例




図3 前処理の手法




図4 背景透過画像, 輪郭画像, 葉脈画像の作成手法

分のみを切り取り, さらに, 正方形に変形することを行った。前処理の流れを図3に示した。

まず, オリジナル画像からグレースケール画像を作成し, 大津二値化[11]をもちいることで, 葉の部分のみが識別された二値画像を作成した。次に, 二値画像から葉の部分のバウンディングボックスを取得し, そのx座標, y座標, 横のサイズ, 縦のサイズを得た。これらの情報を基にして, 葉の部分が収まるように画像を切り取った。最後に, 切り取られた画像はそれぞれ異なる大きさであるため, それを512pixel×512pixelにリサイズした。このように前処理が行われた画像のことをリサイズオリジナル画像と呼ぶこととする。

#### 3.3 3つの特徴量画像の作成手法

リサイズオリジナル画像から, 背景透過画像, 輪郭画像, 葉脈画像と呼ぶ3つの特徴量画像を作成する。3つの特徴量画像の例を図4に示す。1枚のリサイズオリジナル画像から, 背景透過画像と輪郭画像はそれぞれ1枚ずつ作成され, 葉脈画像は10枚作成される。以下で詳細を説明する。

\*1 LeafSnap Dataset : <http://leafsnap.com/dataset/>

### 3.3.1 背景透過画像の作成手法

背景透過画像は、リサイズオリジナル画像における葉以外の背景の部分が白塗りされた画像のことである。リサイズオリジナル画像からグレースケール画像を作成し、大津二値化をもちいて、背景が白の二値画像を作る。この二値画像とリサイズオリジナル画像を組み合わせることで、背景透過画像が作成される。背景透過画像には、葉の全ての情報が存在するということができる。

### 3.3.2 輪郭画像の作成手法

輪郭画像は、リサイズオリジナル画像に大津二値化をもちいて作成される、葉の部分が黒で背景の部分が白である二値画像のことである。樹木の種類の判別において、葉の輪郭の情報が非常に有用な場合があり、場合によっては葉の輪郭の情報のみで正確に判別することも可能だと考えられる。そこで、上記の方法で、葉の輪郭の情報のみをもつ画像を作成した。

### 3.3.3 葉脈画像の作成手法

葉脈画像は、リサイズオリジナル画像の葉の部分のみから四角く切り出された 50pixel×50pixel の画像のことである。それぞれのリサイズオリジナル画像から、合計 10 枚の葉脈画像を取得した。まず、リサイズオリジナル画像の原点を始点として、切り出しのための 50pixel×50pixel のウィンドウを移動させた。移動の際のストライドとしては、まずは、x 座標、y 座標ともに、100pixel を用いた。もし、切り出された画像が、全て葉の部分である場合は、葉脈画像の候補として保持しておく。そのような切り出しを、20 度ごとに回転させながらも行った。多くのリサイズオリジナル画像では、このような操作によって 10 枚以上の葉脈画像の候補が得られたため、その場合には、その中からランダムに 10 枚を選択した。もし、上記の操作で 10 枚以上の葉脈画像の候補が得られなかった場合は、ストライドを 50、25、12、6 と減らすことでより多くの葉脈画像の候補の取得を試みた。この方法によって、いずれの画像からも 10 枚の葉脈画像を取得した。

## 4. 単独の特徴量画像を用いた分類

### 4.1 分類手順

前節では、葉の様々な側面に着目した画像を 3 種類作成した。これら、背景透過画像、輪郭画像、葉脈画像のことを総称して特徴量画像と呼ぶこととした。本研究では、まず、単独の特徴量画像を入力として、葉の画像の分類問題を試みる。単独の特徴量画像から、特徴抽出器を通じて特徴ベクトルを取得し、それをニューラルネットワークで構成された分類器に通すことで、樹木の種類であるラベルが出力されることになる。

これは、以下の 5 つのステップから成る。

- オリジナル画像の読み込み
- 前処理

表 1 背景透過画像における正解率の比較

特徴抽出器	分類器の全結合層のノード数 n				
	1024	512	256	128	64
ResNet152	<b>87.91%</b>	86.88%	87.77%	87.71%	86.46%
InceptionV3	86.41%	87.63%	87.08%	85.83%	83.54%

- 3 つの特徴量画像作成
- Data Augmentation
- 特徴量抽出
- 分類

Data Augmentation は、すべてで 5 種類行った。ランダム回転、平行移動、反時計回りシアー変換、ズーム変形、水平方向における反転である。

ここで、ハイパーパラメータとして、図 1 にて緑色で示した特徴抽出器や、オレンジ色で示した、分類器の全結合層のノード数である n をもちいた。本研究では、特徴抽出器として、ImageNet の事前学習済みモデルである、ResNet152 [12] と InceptionV3 [13] の 2 種類をもちいた。特徴抽出器の出力ベクトルを flatten し、3 層の分類器に入れた。分類器第 1 層は Dropout 層であり、第 2 層と第 3 層は全結合層とした。n の数として、1024、512、256、128、64 の 5 種類をもちいた。分類器の最終層からの出力数は 122 とする。

### 4.2 結果と分析

背景透過画像、輪郭画像、葉脈画像それぞれを学習させた結果を表 1、表 2、表 3 に示した。表 1 より、背景透過画像においては、ResNet152 をもちいて、n の数を 1024 にした場合がもっとも正解率が高かった。表 2 より、輪郭画像においては、ResNet152 をもちいて、n の数を 256 にした場合がもっとも正解率が高かった。表 3 より、葉脈画像においては、ResNet152 をもちいて、n の数を 512 にした場合がもっとも正解率が高かった。

また、3 つの特徴量画像において、それぞれの葉の種類ごとに、正解率を比較した。この結果、背景透過画像、輪郭画像、葉脈画像のそれぞれが、単独で、もっとも正解率が高かった種類数は、39 種類、9 種類、5 種類であった。その一例を図 5 に示した。サトウカエデ種において、3 種類の特徴量画像の中で、背景透過画像の正解率が 80.00% ともっとも高かった。サトザクラ種においては、輪郭画像が正解率 85.71% ともっとも高かった。レッドオーク種においては、葉脈画像が正解率 80.00% ともっとも高かった。

以上より、それぞれの特徴量において、正解率が高い樹木の種類と低い樹木の種類があり、それらがたがいに補完し合う可能性があることを示した。よって、すべての特徴量を組み合わせると、最終的に、正解率が向上する可能性があることが示唆された。

表 2 輪郭画像における正解率の比較

特徴抽出器	分類器の全結合層のノード数 n				
	1024	512	256	128	64
ResNet152	74.38%	76.25%	<b>78.13%</b>	75.42%	74.17%
InceptionV3	74.38%	76.46%	72.50%	74.17%	73.33%

表 3 葉脈画像における正解率の比較

特徴抽出器	分類器の全結合層のノード数 n				
	1024	512	256	128	64
ResNet152	72.29%	<b>74.17%</b>	70.83%	72.92%	72.92%
InceptionV3	68.96%	69.58%	68.54%	67.50%	68.96%



図 5 それぞれの特徴量における分類の分析

表 4 提案手法における正解率の比較

特徴抽出器	分類器の全結合層のノード数 n				
	1024	512	256	128	64
ResNet152	91.44%	<b>92.07%</b>	90.04%	91.23%	90.61%

## 5. 提案手法

### 5.1 分類手順

本研究の提案手法では、背景透過画像、輪郭画像、葉脈画像の特徴量画像を組み合わせで分類した。提案手法を図 1 に示した。これは以下の 9 個の手順から成る。

- オリジナル画像の読み込み
- 前処理
- 3 つの特徴量画像作成
- すべての特徴量画像において Data Augmentation
- すべての特徴量画像において特徴量抽出
- すべての特徴量画像においてベクトルの flatten
- 葉脈画像のみにおいて Average Pooling
- 3 つのベクトルの結合

表 5 もっとも良かった正解率とハイパーパラメータの比較

手法の種類	n	正解率
背景透過画像をもちいた手法	1024	87.91%
輪郭画像をもちいた手法	256	78.13%
葉脈画像をもちいた手法	512	74.17%
提案手法	512	<b>92.07%</b>

### • 分類

図 6 は、提案手法における、分類器の結合層のノード数が 512 のときの学習図である。Early Stopping による早期終了を行った。

背景透過画像、輪郭画像、葉脈画像のすべての特徴量画像において、ResNet152 を特徴抽出器とした。なぜなら、すべての特徴量画像において、ResNet152 がもっとも正解率が良かったためである。すべての特徴量において、特徴抽出器から抽出されるベクトルを flatten した。葉脈画像においてのみ、flatten した 10 個のベクトルを Average Pooling 層に通し、1 つのベクトルを作成した。これら 3 つのベクトルを concat したベクトルを作成した。これを、3 層の分類器に通した。1 層目は Dropout 層である。Dropout 率は 0.5 とした。この層に、全結合層を 2 層加えた。分類器の最終層への入力数である n の数を、1024, 512, 256, 128, 64 とした。最終層の出力数を 122 とした。

その結果を表 4 に示した。表 4 より、もっとも正解率が高かった n の数は 512 であった。また、このときの正解率は、92.07% であった。よって、提案手法による葉の分類が正解率の向上に効果的であることが明らかとなった。

### 5.2 結果と分析

表 5 より、背景透過画像、輪郭画像、葉脈画像をもちいた、それぞれの手法において、もっとも良かった正解率を比較した。正解率は、それぞれ 87.91%, 78.13%, 74.17% であった。それに対して、提案手法における、もっとも良かった正解率は、92.07% であった。

また、表 6 より、上位 5 位以内に該当種がある確率を比較した。背景透過画像、輪郭画像、葉脈画像をもちいた手法における Top5 の確率は、それぞれ 98.13%, 95.63%, 81.81% であった。それに対して、提案手法における上位 5 位以内に該当樹木があるかどうかの確率は、98.96% であった。なお、LeafSnap が公開している論文 [6] におけるデータセットと本研究でもちいたデータは異なり、正解率を比較することは出来ない。

さらに、表 7 より、特徴量画像のなかで 2 種類ずつを組み合わせで分類を行った。この結果、どの 2 つの特徴量を組み合わせても、ほとんどの正解率が約 90% であった。よって、3 つすべての特徴量を組み合わせの場合に比べて、正解率が約 2% 低い結果となった。

表 6 上位 5 位以内に該当樹木があるかどうかの確率の比較

	Top5 の確率
背景透過画像をもちいた手法	98.13%
輪郭画像をもちいた手法	95.63%
葉脈画像をもちいた手法	81.81%
提案手法	<b>98.96%</b>

表 7 2 種類ずつの特徴量画像を結合した正解率の比較 (%)

結合した特徴量	分類器の全結合層のノード数 n				
	1024	512	256	128	64
背景透過+輪郭	90.39	89.98	<b>90.81</b>	89.56	88.73
輪郭+葉脈	89.35	<b>90.61</b>	89.94	88.73	88.52
背景透過+葉脈	90.81	<b>91.44</b>	89.98	91.23	90.18




図 6 提案手法における正解率と損失字の学習図

## 6. まとめ

本研究では、多様な特徴量画像をもちいて、樹木の葉の画像から 122 種類の樹木の葉の分類を行った。特徴エンジニアリングすると葉の分類における正解率が向上することが明らかとなった。まず、オリジナル画像から、背景透過画像、輪郭画像、葉脈画像の 3 つの特徴量画像を生成し、それぞれを分類した。結果、すべての特徴量画像において、もっとも正解率が高いときの特徴抽出器は、ResNet152 であった。また、分類器の全結合層のノード数を比較した。その結果、背景透過画像では 1024、輪郭画像では 256、葉脈画像では 512 をもちいた場合がもっとも正解率が高く、それぞれ 87.91%、78.13%、57.33% であった。提案手法では、特徴量画像それぞれから取り出されたベクトルを組み合わせ、3 層の分類器に入力し、ラベルを出力した。提案手法において、もっとも高い正解率は **92.07%** であった。

よって、背景透過画像、輪郭画像、葉脈画像をもちいた手法それぞれに対して、提案手法では、正解率が、5%程度、14%程度、18%程度向上した。以上より、あらゆる特徴量を網羅的に組み合わせることが、樹木の葉の分類性能を向上させることが明らかになった。本研究では、提案手法が、樹木の葉の分類に効果的であることが示唆された。

**謝辞** 本研究の一部は JSPS 科学研究費助成事業 JP21H03775, JP21H03774, JP21H03554 による助成を受けたものです。ここに記して謝意を表します。

## 参考文献

- [1] Cope, J. S., Corney, D., C. J. Y., Remagnino, P. and Wilkin, P.: Plant Species Identification Using Digital Morphometrics: A Review, *Expert Systems with Applications*, Vol. 39, No. 8, pp. 7562–7573 (2012).
- [2] Caglayan, A., Guclu, O. and Can, A.: A Plant Recognition Approach Using Shape and Color Features in Leaf Images, *Proceedings of the International Conference on Image Analysis and Processing*, pp. 161–170 (2013).
- [3] Hossain, J. and Amin, M. A.: Leaf Shape Identification Based Plant Biometrics, *Proceedings of the International Conference on Computer and Information Technology*, pp. 458–463 (2010).
- [4] Mouine, S., Yahiaoui, I. and Verroust-Blondet, A.: A Shape-Based Approach for Leaf Classification Using Multiscaletriangular Representation, *Proceedings of the ACM Conference on International Conference on Multimedia Retrieval*, pp. 127–134 (2013).
- [5] Chompookham, T., Gonwirat, S. and Lata, S.: Plant Leaf Image Recognition using Multiple-grid Based Local Descriptor and Dimensionality Reduction Approach.
- [6] Kumar, N., Belhumeur, P. N., Biswas, A., Jacobs, D. W., Kress, W., Lopez, I. C. and Soares, J. V.: LeafSnap: A Computer Vision System for Automatic Plant Species Identification, *European Conference on Computer Vision*, pp. 502–516 (2012).
- [7] Kamrul, M. H., Rahman, M., Robin, M. R. I., Hossain, M. S., Hasan, M. H. and Paul, P.: A Deep Learning Based Approach on Categorization of Tea Leaf, *Proceedings of the International Conference on Computing Advancements*, pp. 1–8 (2020).
- [8] Wu, Y.: Leaf Classification Based on Multiple Classifiers, *Proceedings of the International Conference on Aviation Safety and Information Technology*, pp. 257–261 (2020).
- [9] Tan, J. w., Chang, S.-W., Abdul-Kareem, S., Yap, H. J. and Kien-Thai, Y.: Deep Learning for Plant Species Classification Using Leaf Vein Morphometric, *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, pp. 82–90 (2020).
- [10] Wu, Y., Wu, J. and Hu, G.: MMFS: A Grape Disease Recognition Method Based on Multi-Feature Fusion and SVM, *Proceedings of the International Conference on Cloud and Big Data Computing*, pp. 27–31 (2020).
- [11] 田中宏, 藤井勇作, 堀田悦伸, 中川正樹: 対象知識を利用した文書画像の 2 値化, *電子情報通信学会論文誌 D* Vol. J96-D No.4, pp. 1029–1038 (2013).
- [12] He, K., Zhang, X., Ren, S. and Sun, J.: Deep Residual Learning for Image Recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770–778 (2015).
- [13] Chollet, F.: Xception: Deep Learning with Depthwise Separable Convolutions, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1251–1258 (2017).