

深層学習モデルを用いた樹皮画像によるケヤキの判別


熊本県立八代高等学校 2年（九州大学未来創成科学者育成プロジェクト） 瀬高望

目的

AI技術を用いて樹皮画像によるケヤキの判別が可能かどうか検討

背景

- ▶ 私たちは葉や花の形態を基に図鑑やインターネットを利用して、樹種をある程度判別しているが、専門知識を必要とすることが多く、難しく感じる。とくに花や落葉樹の葉はある時期にしか観察することができず、いつでも樹種を識別することは出来ない。
- ▶ 近年のAI技術の進化は目覚ましく、AI技術を用いて樹種識別ができないかと考えた。
- ▶ 樹皮の形態は樹種によって異なること、一定の撮影条件で1年を通して撮影可能であることに着目した。



作成したケヤキ画像自動判別モデル

chainer-keyaki-model.h5

検証データによるモデルの最終正解率=0.915818




図1 エポックごとの正解率の推移
学習データ（青）、検証データ（オレンジ）





図2 エポックごとの誤差の推移
学習データ（青）、検証データ（オレンジ）

方法①・撮影

- ・撮影場所：14カ所（福岡県・熊本県の5市町村）の公園・街路樹・森林
- ・撮影期間：2023年2月～2024年1月
- ・撮影機器：デジタルカメラ（Olympus Tough TD-6;京セラ Program auto）
- ・撮影方法：自動モード（F値、シャッタースピード）
地上高0.5m、1.3mの部位
4方向について幹から約0.5m、1.0m、2.0mで撮影（幹1本当たり24枚）
- ・撮影樹種数：131種（針葉樹・広葉樹、外国産樹種を含む）
- ・撮影枚数：22,648枚（ケヤキ7,038枚、その他15,610枚）



撮影地

撮影画像の例



撮影部位



結果：モデルの検証

本研究の2月～6月の写真（ケヤキ）



結果「ケヤキ」○

本研究の2月～6月の写真（クスノキ）



結果「その他」○

解析に使用しなかった他時季の写真（ケヤキ）



結果「その他」×

解析に使用しなかった他時季の写真（コナラ）



結果「その他」○

モデルでは90%以上の正解率であるにもかかわらず、解析に使用しなかったケヤキやインターネット上のケヤキの画像を判別させると、ほとんどが「その他」に判別され、ほとんどが正解しなかった。解析に使用しなかったその他の樹種はすべて「その他」に判別された。

考察

正解率が低かった原因として以下の2つを考えた。

①研究当初はどのような画像をどの程度取得し、解析に用いるのか手探り状態であり、画像を大量に確保するため、あらゆる撮影画像を用いた。そのため逆光、人物・建物・他の生物の映り込み、地衣類・コケの大量付着など、樹皮の特徴が捉えにくい画像が多数あった。

→対策：今後はこのような画像を用いない。しかし、コケ類・地衣類のつき方は樹種の特徴であるかも知れないので、この点も含めた画像によるモデルを作成できればより正確になると考えられる。



逆光



地衣類・コケ類の付着



つる類の写り込み



背景の影響

②今回作成した判別モデルは学習データ（今回撮影した写真情報）に特化したモデルになっている可能性が高い。撮影機器、撮影条件、季節（2月～6月）、撮影者の特性による影響も考えられる。

→対策：撮影条件、カメラの機種、撮影者のバリエーションを増やし、学習データを強化あるいは特化することで、より汎用性のある判別モデルを作成できるかもしれない。

今後の予定

現在、異なる季節に撮影したすべての画像を使い（ケヤキ7,038枚、その他15,610枚）モデルの再作成を行っている。発表時にはその結果についても報告する。

方法②・判別用学習モデルの作成

- ・参考書：『今すぐ試したい！機械学習・深層学習（ディープラーニング）画像認識プログラムレシピ』, 川島賢, 2019
- ・プログラムの実装・実行：Google Colaboratory上のPython言語
- ・使用画像数：12,518枚（ケヤキ4,659枚、その他の樹種7,859枚）
※2023年2月～6月までに撮影した画像、一部過去に九州大学演習林で撮影された画像を使用
- ・画像処理
 - ①画像に正解ラベル付け（二値：ケヤキ=0、その他=1）
 - ②画像形式の標準化
タテ128ピクセル×ヨコ128ピクセルに変換
8ビット符号なし整数値（0～255）に変換
32ビット浮動小数点数を0～1の範囲内の値に変換
 - ③学習データとテストデータへのランダム分離
学習データ：80%（9,620枚）、テストデータ（2,405枚）：20%
- ・畳み込みニューラルネットワークモデルを構築
使用ソフトウェア：Chainer
畳み込み層：4層
畳み込み層の結果：ReLU活性化関数を用いてプーリング（最大値プーリング）
バッチサイズ：64（データを64個に分割して学習させた後、パラメータ平均化）
エポック数（全てのミニバッチを使い終わる時間単位）：10
パラメータの最適化：Adam (adaptive moment) 法を採用

謝辞

九州大学未来創成科学者育成プロジェクトでご指導いただいた九州大学農学研究院の古賀信也先生、パソコンの操作、プログラムの実装や解析の際、アドバイスをいただいた楠本聞太郎先生、QFCSP事務局の職員の皆様、撮影にご協力いただいた九州大学大学院生物資源環境科大学院生の楊茂岐さん、朱曉宇さん、管楽さんに感謝申し上げます。