

機械学習ディープラーニング法による 植物葉の識別

井畔 実穂¹・福井 すみれ²・中山 紘喜³・西野 友子⁴・野上 敦嗣⁵

¹非会員 北九州市立大学 国際環境工学部環境生命工学科 (〒808-0135 福岡県北九州市若松区ひびきの1-1)

E-mail: w5551005@eng.kitakyu-u.ac.jp

²非会員 前北九州市立大学 国際環境工学部環境生命工学科 (〒808-0135 福岡県北九州市若松区ひびきの1-1)

³非会員 北九州市立大学博士後期課程 国際環境工学研究科 (〒808-0135 福岡県北九州市若松区ひびきの1-1)

E-mail: y7dac004@eng.kitakyu-u.ac.jp

⁴非会員 北九州市立大学研究員 国際環境工学部環境生命工学科 (〒808-0135 福岡県北九州市若松区ひびきの1-1)

E-mail: t-nishino@kitakyu-u.ac.jp

⁵正会員 北九州市立大学教授 国際環境工学部環境生命工学科 (〒808-0135 福岡県北九州市若松区ひびきの1-1)

E-mail: nogami@kitakyu-u.ac.jp

生物多様性の保存が重要視される中、GISやドローンの活用等ICTの環境分野への応用が広がりを見せている。しかしそれは情報収集やモニタリングを中心に留まっている。近年急速に発展しているディープラーニング(DL)法による機械学習は、画像認識において高い性能を示すことから種の識別への応用が期待される。本研究では自らが撮影した5種の植物葉に対してDL法を用いた画像認識の性能を評価した。DLライブラリにはCaffeを、ニューラルネットワークにはAlexNetを用い、イチョウ、カエデ、ケヤキ、ネズミモチ、ヤマザクラの5種類の葉の画像で機械学習を行った。撮影した画像は枝葉と1枚の葉「一葉」の2パターンを用意し、それぞれの識別精度を比較した。撮影総数は「枝葉」画像が748枚、「一葉」画像が表裏1168枚であったが、双方とも回転や反転などの画像加工によるデータ拡張を行うことで、識別率は大きく向上した。データ拡張を行った2つの画像パターンを全て学習された総合モデルは、枝葉、一葉全種類のテスト画像に対して89%以上の識別率を達成した。

Key Words : deep learning, vegetation investigation, ICT, image classification, OpenCV

1. 緒言

近年の情報化社会において、測位システム、IOT、AIといったICTの目まぐるしい発展と共に様々な分野でICTの応用研究がなされ、今までは実現不可能だった多くのことが実現可能となっている。環境の分野においては生物多様性の保存が重要視される中、元来より地図を基にした調査や記録がなされていたことから、環境省が早期に自然環境保全基礎調査のGISデータを提供し¹⁾、その結果、植生解析を中心に生物多様性保全管理へのGIS応用研究が広く行われている。例えば、本研究室で行ったGISを用いた地形特性と植生分布の相関解析研究²⁾や、富士通、川崎市等が市民を対象に実施した多摩川での植生

調査³⁾等多くの事例が挙げられる。

また、ドローンを含むリモートセンシング技術とIoTを組み合わせて、植生調査や森林管理、害獣監視などへの応用も活発になってきた。「ICTを活用した生物多様性保全と生物多様性評価」⁴⁾によるとICTによる生物多様性保全において、情報収集、分析・評価、情報管理、モニタリング、教育・普及・啓発の分野でICTの活用の可能性が見込まれており、情報収集、情報管理、モニタリングの分野においては上記のような応用研究が活発である一方、他の分野ではまだ活用例は少ない。

分析・評価の分野においてはAI技術の活用が見込まれる。AI技術に関しては特に自動運転システム等の根底となる画像認識技術の発展が近年急速に進んでいる。その

中でもディープラーニング (DL) 法による機械学習の応用研究は先駆的に行われ、その精度は一部人間に匹敵するものとなった。環境の分野においても、千葉工大によるインターネット画像を学習させて406種の花の分類を行うハナノナ⁹等DL法を用いた識別システムの例が出されているほか、早大等によるリモートセンシング技術の応用において空撮した植物、種の識別には機械学習が用いられている⁹。今後環境の分野へのAI技術の活用は活発になるものと考えられるが、事例は少ない。

画像を用いた種の識別において機械学習は強力な手法ではあるが、DL法においては制御パラメータの経験的な決定の他、量質共に十分な訓練データの整備が必要になる。本研究では既存の植物画像データベースを用いず、自ら撮影した植物葉の写真に対してDL法を用いた機械学習を行った。この際訓練データにはデータ拡張による量質の補強を施し、本研究ではこのデータ拡張の有無を含め、自ら撮影した画像に対してDL法による機械学習の性能を評価した。

2. 研究方法

(1) 学習用画像データと使用したDLシステム

識別に用いた植物はイチョウ、カエデ、ケヤキ、ネズミモチ、ヤマザクラの5種類で、写真の撮影にはオリンパスの「OLYMPUS PEN Lite E-PL3」を用いた。撮影した写真のサイズは横幅が4032ピクセル、縦幅が3024ピクセルとなっており、ファイル形式はjpegである。

大きく分けて3つの訓練データを作成した。一つ目は樹木を撮影したもので、葉を中心に枝ごと写真に収めている。各100枚〜200枚、計748枚撮影した。これを以降「枝葉モデル」と呼ぶ。画像データの一例を図-1に示す。



図-1 イチョウの枝葉モデルの一例

二つ目は葉のみを撮影したもので、採取した葉を1枚ずつ並べそれを写真に収めた。表を各100枚〜150枚、裏を各100枚〜150枚、計1168枚撮影した。これを以降「一葉モデル」と呼ぶ。撮影した画像の一例を図-2に示す。




図-2 イチョウの一葉モデルの一例

(左: 表) (右: 裏)

これら二つの訓練データには次節で示すデータ拡張を行い、訓練データ画像数の増強を2〜4段階で行った。

三つ目の訓練データは「枝葉モデル」と「一葉モデル」を纏めたもので、これを以降「総合モデル」と呼ぶ。各訓練データに対してDL法を用いて学習モデルを作成した。作業はDIGITS上で行い、フレームワークにはCaffeを、ニューラルネットワークにはAlexNetを用いた。

(2) データ拡張

データ拡張とは画像処理によって訓練データの質と量を補うテクニックで、本研究ではOpenCVパッケージを用いたpythonプログラムを自作し画像処理を行った。

画像サイズは撮影時に4032×3024であるが、機械学習入力時に256×256までに圧縮される。この時入力画像のアスペクト比は維持されない。よってアスペクト比が1:1でない画像は入力時に縦横の歪が発生してしまう。そこで訓練データのすべての画像に対してアスペクト比を1:1に加工した。具体的には元画像を中心から大きさが3024×3024になるように切り出した。この訓練データを以降「1:1」訓練データと呼称する。

枝葉モデルについては、写真のいたる領域に葉が映っているので、写真を細かく分割しそれらを訓練データの一部とすることで訓練データの画像数を増やした。具体的には写真の中からランダムに15点の座標を選び、選んだ座標を中心に指定したサイズの領域を切り出して新しい画像ファイルとして保存した。分割した画像のうち葉に関係ない要素が多くを占めるものは除去している。今回は指定サイズを512×512と256×256の2つのパターンで用意した。1:1訓練データに512×512に分割した画像群を加えたものを「分割1」訓練データ、「分割1」訓練データに256×256に分割した画像群を加えたものを「分割2」訓練データと呼称する。

さらなるデータ拡張として分割画像を左右反転、上下反転させ、「分割2」訓練データに加えたものを「反転」訓練データと呼称する。一葉モデルについては1:1訓練データに15度ずつ回転、さらにそれを左右反転させた画像でデータ拡張を行った。この訓練データを「回転」訓練データと呼称する。

データ拡張による画像数数の増加を表-1、表-2に、画

像加工の様子を図-3、図-4に示す。

表-1 枝葉モデルにおける訓練データ群

訓練データ名	画像数	データ拡張の内容
原画像	748	なし
1:1	748	アスペクト比修正
分割1	6572	「1:1」+512×512の画像分割
分割2	8638	「分割1」+256×256の画像分割
反転	24555	「分割2」+上下反転+左右反転

表-2 一葉モデルにおける訓練データ群

訓練データ名	画像数	データ拡張の内容
1:1	1168	アスペクト比修正
回転	51648	「1:1」+15°区分の回転+左右反転




図-3 枝葉モデルのデータ拡張




図-4 一葉モデルのデータ拡張

3. 研究結果

(1) 枝葉モデルの学習結果

枝葉モデルから作成した5つの訓練データの学習結果を表-3と図-5に示す。個々の植物の識別率は表-4に示す。識別率の値は画像数に伴い上がっていることが分かる。特にアスペクト比を調整した場合の向上が著しく、「原画像」と「1:1」で画像数は変わっていないものの10%を越す識別率の向上が見られた。

これにより、学習時における入力画像のアスペクト比を無視した圧縮が識別率に大きな影響を与えられ、この修正が学習率の向上に大きく貢献すると言える。

表-3 枝葉モデルの画像数と識別率

訓練データ名	画像数	識別率(%)
原画像	748	68.23
1:1	748	79.02
分割1	6572	82.75
分割2	8638	84.42
反転	24555	88.35




図-5 枝葉モデルの学習結果

表-4 枝葉モデルにおける個々の植物種の識別率

訓練データ名	原画像	1:1	分割1	分割2	反転
画像数	748	748	6572	8638	24555
イチヨウ	83.33	83.33	89.25	90.91	96.57
カエデ	50.0	81.82	73.87	78.17	80.98
ケヤキ	60.38	62.26	63.8	63.47	72.31
ネズミモチ	97.87	100.0	98.08	98.46	99.92
ヤマザクラ	22.58	70.97	92.15	92.77	94.87

また、画像数の急な増加でも識別率の高い向上が見られる。「1:1」と「分割1」、「分割2」と「反転」の間で画像数が大きく増加しているが、この時の識別率には3~4%の向上が見られ、最終的に「1:1」と「反転」の間では10%近い向上が見られることから、画像数の充実がアスペクト比の調整と同様、学習率の向上に大きく寄与すると言える。表-4からも識別率がばらつき安定しない「原画像」に対し、データ拡張を行った「反転」では平均的に高い識別率を保持できていることが分かる。これらのことから、同一の画像データを基にしたデータ拡張でも学習率の向上に効果があり、個人で用意した訓練データから高い識別率を持つ学習モデルを作ることができることが分かった。

(2) 一葉モデルの学習結果

一葉モデルから作成した2つの訓練データの学習結果を表-5に、個々の植物における識別率を表-6に示す。

表-5 一葉モデルの画像数と識別率

訓練データ名	画像数	識別率(%)
1 : 1	1168	94. 38
回転	51648	96. 59

表-6 一葉モデルにおける個々の植物種の識別率

訓練データ名	1 : 1	回転
画像数	1168	51648
イチョウ	98.39	98.18
カエデ	95.0	99.28
ケヤキ	89.71	100.0
ネズミモチ	92.59	80.44
ヤマザクラ	92.0	98.75

表-5 から、一葉モデルにおいては「1:1」の段階で、即ちアスペクト比調整のみを行い、画像数の補強を行っていない状態で高い識別率が得られた。しかし一葉モデルに用いた画像は、植物葉の向きがすべて同じとなっていた。そこで、訓練データの画像を90度回転、180度回転させた画像を用いて植物の種類ごとに各10枚ずつテストを行った。訓練データの画像例を図-6に、90度回転、180度回転の画像例を図-7に示す。また、90度回転のテスト結果を表-7に、180度回転のテスト結果を表-8に示す。表-6と、表-7、表-8を比較すると回転画像をテストに用いた場合の識別率は大幅に低下した。この結果から、訓練データと異なる向きの画像でテストを行うと、高い識別率が得られないことが分かった。

これに対し、回転の学習モデルに同様のテストを行った。90度回転の結果を表-9に、180度回転の結果を表-10に示す。




図-6 訓練データの画像例




図-7 90度回転および180度回転のテスト画像例

表-7 90度回転のテスト結果(1 : 1)

	正解枚数	不正解枚数	正答率 (%)
イチョウ	9	1	90
カエデ	0	10	0
ケヤキ	2	8	20
ネズミモチ	9	1	90
ヤマザクラ	0	10	0

表-8 180度回転のテスト結果(1 : 1)

	正解枚数	不正解枚数	正答率 (%)
イチョウ	7	3	70
カエデ	0	10	0
ケヤキ	10	0	100
ネズミモチ	4	6	40
ヤマザクラ	10	0	100

表-9 90度回転のテスト結果 (回転)

	正解枚数	不正解枚数	正答率(%)
イチョウ	10	0	100
カエデ	9	1	90
ケヤキ	10	0	100
ネズミモチ	10	0	100
ヤマザクラ	10	0	100

表-10 180度回転のテスト結果 (回転)

	正解枚数	不正解枚数	正答率(%)
イチョウ	10	0	100
カエデ	10	0	100
ケヤキ	10	0	100
ネズミモチ	10	0	100
ヤマザクラ	10	0	100

表-7、表-8、表-9、表-10を比較すると、「1:1」モデルでは低かった正答率が「回転」モデルの場合だとすべて向上していることが分かる。また表-6から、イチョウとネズミモチについては「1:1」モデルの方が「回転」モデルより高い識別率を示しているが、表-7、表-8、表-9、表-10を見ると「回転」モデルの方が高い正答率を示している。これらのことから訓練データにおいては被写体の向き、即ちの被写体のパターンも重視する必要があると言え、これには色彩や形状の場合でも同じような結果になるものと考えられる。

(3) 一葉モデルの学習結果

枝葉モデルと一葉モデルの識別性能の比較を行った。それぞれのモデルで最も識別率が高かった、反転のデータセットと回転のデータセットで比較を行った。テストには枝葉と一葉の写真それぞれから、植物葉の種類ごとに各10枚ずつ、計20枚用いた。どちらの写真も学習に用いていないものから選択し、枝葉の写真については、撮影した写真から新しく切り出した画像を使用した。テストデータ用に切り出した枝葉のテスト画像を、イチョウの画像を例に図-8に、枝葉モデルのテスト結果を表-11に、一葉モデルのテスト結果を表-12に示す。




図-8 イチョウのテスト写真

表-11 枝葉モデルのテスト結果

	枝葉テスト写真			一葉テスト写真		
	正解枚数	不正解枚数	正答率(%)	正解枚数	不正解枚数	正答率(%)
イチョウ	10	0	100	2	8	20
カエデ	10	0	100	4	6	40
ケヤキ	9	1	90	5	5	50
ネズミモチ	10	0	100	0	10	0
ヤマザクラ	10	0	100	0	10	0

表-12 一葉モデルのテスト結果

	枝葉テスト写真			一葉テスト写真		
	正解枚数	不正解枚数	正答率(%)	正解枚数	不正解枚数	正答率(%)
イチョウ	9	1	90	10	0	100
カエデ	0	10	0	9	1	90
ケヤキ	0	10	0	10	0	100
ネズミモチ	0	10	0	10	0	100
ヤマザクラ	1	9	10	10	0	100

表-11 と表-12 をみると、各訓練データと同じ形式のテスト画像を用いた場合の識別率は高い値を示している

が、他方の形式のテスト画像を用いた場合は識別率が大幅に低下したことが分かる。この結果からも、訓練データに用いた画像のパターンの影響が見て取れる。

以上の結果を受け、2つの訓練データを合わせた新たな訓練データを作成し、多くのパターンの画像でも高い識別率が得られるかテストを行った。このモデルを総合モデルとする総合モデルのを表-13に示す。

表-13 データセットの構造（総合モデル）

モデル名	画像数	識別率(%)
総合モデル	75961	95.87

テストには、枝葉の画像を植物葉の種類ごとに各10枚ずつ、一葉の画像を回転させたものを各20枚ずつ用いた。枝葉のテスト写真には図-8の例と同じものを用いた。テスト結果を表-14に、植物葉の種類ごとの識別率を表-15に示す。

表-14 総合モデルのテスト結果

	正解枚数	不正解枚数	正答率(%)
イチョウ	30	0	100
カエデ	30	0	100
ケヤキ	29	1	96.67
ネズミモチ	30	0	100
ヤマザクラ	29	1	96.67

表-15 植物葉の種類ごとの識別率

モデル名	識別率(%)				
	イチョウ	カエデ	ケヤキ	ネズミモチ	ヤマザクラ
総合モデル	98.19	94.09	89.09	98.81	98.29

表-14を見ると全ての植物葉において、高い正答率を示していることが分かる。表-15からもケヤキ以外の植物は90%を超える識別率を示し、ケヤキも89%の高い数値を示している。よって、訓練データに枝葉の写真と一葉の写真を用いることで、多くのパターンの写真でテストを行っても高い正答率が得られる学習モデルを作成できたと考えられる。

4. まとめ

DL法の機械学習には画像データの枚数を増やすデータ拡張が重要な役割を担っていることが分かった。その際、画像を上下左右反転させる簡易的なデータ拡張でも識別率は大幅に上昇することが分かった。また訓練データの作成においては、テストデータのパターンに合わせた訓練データを用意する必要があることが分かった。

今後は、5種からさらに種を増やした訓練データに対しても高い識別率が得られる方法を検討していく。また、ドローンを用いて撮影した画像から今回のように高い識別率を持った学習モデルを作成できるよう研究を進めていきたい。

参考文献

- 1) 環境省 自然環境局 生物多様性センター 自然環境保全基礎調査
http://www.biodic.go.jp/kiso/fnd_list_h.html
- 2) 上田蒼馬, 野上敦嗣, 西野友子: GIS を用いた小流域の地形特性: 植生分布の相関解析と河川間の類似度分析, 環境システム研究論文発表講演集, 43 巻, 123-128, 2015
- 3) ICT を活用した多摩川での植生調査の実施
<http://pr.fujitsu.com/jp/news/2011/09/21-4.html>
- 4) 川口努, 前沢夕夏, 畠山義彦, 小野貴之: ICT を活用した生物多様性保全と生物多様性評価, FUJITSU.62, 6, 745-752, 2011
<http://www.fujitsu.com/downloads/JP/archive/imgjp/jmag/vol62-6/paper18.pdf>
- 5) 千葉工業大学人工知能・ソフトウェア技術研究センター: <https://stair.center>
- 6) 鈴木太郎, 土屋武司, 鈴木真二, 山場淳史: 小型 UAV による空撮画像からのスーパーピクセル分割と機械学習を用いた植生分類手法の構築, Journal of The Remote Sensing Society of Japan, 36, 59-71, 2016
- 7) Caffe DeepLearning Framework
<http://caffe.berkeleyvision.org/>

(2018. 8. 24 受付)

MACHINE LEARNING IDENTIFICATION OF PLANT LEAVES BY DEEP LEARNING METHOD

Miho IGURO, Atsushi NOGAMI, Tomoko NISHINO, Hiroki NAKAYAMA and Sumire FUKUI

The application to the environmental field of the ICT such as the inflection of GIS and the drone shows an expanse while preservation of the biological diversity is regarded as important. In late years application to the identification of the kind is expected because the machine learning by the deep learning (DL) method developing rapidly shows high performance in image recognition. I evaluated performance of the image recognition using the DL method for five kinds of plant leaves which oneself photographed in this study. I used AlexNet for a neural network to .DL method library in Caffe and performed machine learning with a ginkgo, a maple, a zelkova, a Japanese privet, the image of five kinds of leaves of the wild cherry tree. I prepared the image which I photographed by 2 patterns of "Branches and leaves" and "One leaf" and compared each identification precision. As for the photography total number, "Branches and leaves" was 748 pieces and "One leaf" was 1,168 pieces. They greatly improved an identification rate by performing data expansion by image processing such as a turn or the inversion. The general model that data all two expanded image patterns were learned achieved an identification rate of more than 89% for "Branches and leaves", "One leaf" all types of test images.