

畳み込みニューラルネットワークを用いた
山草の毒性識別の可能性

長尾 光悦 佐藤 海
北海道情報大学

Recognition Toxicity in Mountain Plants using a Convolutional
NeuralNetwork

Mitsuyoshi NAGAO and Kai SATO
Hokkaido Information University

2020年12月

北海道情報大学紀要 第32巻 第1号別刷

〈報告〉

畳み込みニューラルネットワークを用いた

山草の毒性識別の可能性

長尾 光悦* 佐藤 海†

Recognition Toxicity in Mountain Plants using a Convolutional Neural Network

Mitsuyoshi NAGAO* Kai SATO†

要旨

山草の有毒性と無毒性を見分けるのは難しく、有毒植物の誤食による食中毒や死亡事故が、毎年、発生している。本論では、このような事故の防止を意図し、畳み込みニューラルネットワーク (Convolutional Neural Network, 以下 CNN) を用いた山草の毒性識別の可能性を検証する。ここでは2層のCNNを構築し、27種類の山草の毒性の識別を行う。また、ハイパーパラメータの変更を行い、識別率の変化を検証する。最後に、AlexNetと本論におけるCNNとの識別率の差を検証する。その結果、CNNを利用した山草の毒性識別の実現可能性が示された。

Abstract

Food poisoning, sometimes lethal, caused by accidental eating of toxic mountain plants, occurs every year because it is difficult to distinguish edible mountain plants from poisonous ones. In this paper, we propose toxicity recognition for mountain plants using Convolutional Neural Network (CNN) in order to prevent accidentally eating toxic mountain plants. Our research identified toxicity in 27 mountain plants by using a CNN with two convolutional layers, two pooling layers, and two fully connected layers. It also indicated variation against recognition performance in use of different hyper parameters for CNN. Finally, the difference of recognition performance between our CNN and AlexNet is discussed.

キーワード

毒性識別 (Recognition toxicity) 山草 (Mountain plants) CNN

* 北海道情報大学経営情報学部システム情報学科教授, Professor, Department of Systems and Informatics, HIU

† 北海道情報大学経営情報学部システム情報学科 B4, B4, Department of Systems and Informatics, HIU

1. はじめに

日本列島にはおよそ 8800 種類ほどの多種多様な植物が自生している（生物多様性センター, 2020）。そのため、春先から夏にかけて、野山に出かけ山菜採りや野草摘みを楽しむ人が数多く存在する。しかしながら、山菜や野草には有毒植物と似ている種が非常に多く、ハシリドコロやバンケイソウなどの有毒植物をフキノトウやギョウシャニンニクなどの無毒性植物と誤食してしまうことがある。厚生労働省の「過去 10 年間の有毒植物による食中毒発生状況（平成 21 年～30 年）」によると、発生事件数が計 176 件、患者数が計 780 件、死亡数が計 12 件と食中毒による事故が多々発生している（厚生労働省, 2020）。このことから、山菜や野草の有毒性と無毒性を見分けることは難しく、誤食によって引き起こされる食中毒の危険性が非常に高いと言える（農林水産省, 2020）。

本論では、このような有毒植物の誤食による食中毒や死亡事故を防ぐため、畳み込みニューラルネットワーク（Convolutional Neural Network, 以下 CNN）を用いた山草の毒性識別の可能性を検証する。ここでは、2 層の畳み込み層、2 層のプーリング層、2 層の全結合層と 3 層のドロップアウト層からなる CNN を構築し、27 種類の山草における毒性識別の可能性を検証する。また、学習回数、最適化アルゴリズム、学習率、フィルタサイズなどのハイパーパラメータを変更することによる学習正解率の変化を検証する。更に、本 CNN と画像認識の分野において成果を挙げている AlexNet における識別率を比較する。

2. CNN

CNN とは、深層学習の手法の 1 つであり、現在、顔認証や物体検出などの画像認識の分野において利用され、大きな成果を挙げている。CNN は従来のニューラルネットワークに畳み込み層とプーリング層という画像の特徴部分を抽出する仕組みを備えたものであり、フィルタを使用することによって画像の特徴部分を抽出することができる。

現在、CNN を利用した画像認識に関する多くの研究が実施されている。例えば、北風らはドローンを用いて害鳥カワウを追いかける手法を提案している。ここでは、ドローンにカワウと他の野鳥を識別するための CNN を用いた画像認識システムを搭載している。CNN の構造は 4 層の畳み込み層と 2 層のプーリング層と 3 層の全結合層で構築されており、識別率 85% という高い識別率を達成している（北風ほか, 2019）。

また、安岡らはドローンを用いて室内環境を撮影し、その撮影した画像にどのような物体が存在するかの識別を CNN により実施する研究を行っている。CNN の構成は 13 層の畳み込み層と 3 層の全結合層で構築されており、画像中に存在する物体を正しく認識することに成功している（安岡ほか, 2018）。

このように CNN は、物体認識の分野で成果を上げている。従来研究において、山草の毒性識別に CNN を利用した研究は見当たらない。そこで、本論文では、CNN を用いて毒性植物か否かを識別することが可能かを検証する。

3. CNN を用いた山草の毒性識別

3-1 学習用データの収集



図1 山草の種類と画像例

本研究で扱う山草の画像を図1に示す。図に示されてるように、無毒性の山草としてフキノトウやタラノメなどの13種、有毒性の山草としてハシリドコロやヤマウルシなどの14種の計27種を採用した。CNNの学習に使用する山草の画像収集にはYahoo!, Google, Bingの画像検索エンジンを利用した。また、山草1種につき、画像を50枚、計1350枚を収集した。加えて、山草画像の前処理として画像サイズを28×28ピクセルの画像に変更し、それぞれの山草画像の背景を切り抜き、学習に不要な部分を削除した。

1350枚の学習用データの内、訓練用のデータを8割と検証用のデータを2割に分割した。検証用データは学習用データの中からランダムに選択される。

3-2 CNNの構成

本研究におけるCNNの構成は、入力層1層、畳み込み層、プーリング層、全結合層を各2層、ドロップアウト層3層、出力層1層から構成されている。本研究におけるCNNの構成を図2に示す。

畳み込み層では、畳み込み処理が行われ、画像の特徴を表す特徴マップの獲得が行われる。これは、画像において、フィルタを横にスライドさせ、左上から右下まで移動させる。また、フィルタをスライドさせる幅のことをストライドと呼ぶ。このとき、フィルタ行列と画素の乗算処理を行う。これにより画像における特徴的な部分の抽出を行う。この処理は畳み込み処理と呼ばれ、本研究ではフィルタサイズを3×3、ストライド数を1とし、1




図2 CNNの構成

層目のフィルタの数を 32 個、2 層目のフィルタの数を 64 個とする。また、畳み込み層では畳み込み処理を行うことで出力する特徴マップが縮小し、特徴マップの端のピクセルまで特徴を捉えられない場合がある。そのため、畳み込み層にゼロパディングを適用する。ゼロパディングとは特徴マップの周囲に値が 0 のピクセルを配置することで特徴マップのサイズが縮小することを防ぐ役割を持つ。

プーリング層では、得られた特徴マップを圧縮し、新たな特徴マップ作成を行う。この操作により細かな変動に対するロバスト性を実現する。具体的な処理としては、各フィルタ内の最大値をそのフィルタ内の値として採用する **Max Pooling** と呼ばれる処理を適用することで特徴マップを圧縮する。本研究では 2×2 のフィルタを使用し、1 層目のフィルタの数を 32 個、2 層目のフィルタの数を 64 個とする。

2 つの畳み込み層とプーリング層の組み合わせの後、全結合層が配置される。全結合層の 1 層目は特徴マップを 1 つのノードに集め、2 層目はノードから送られてくる情報をクラス分類する役割を持つ。本研究では 1 層目のノード数を 512 個、2 層目のクラス数を 2 個に設定する。最後に、全結合層から送られてきたデータに対しソフトマックス関数を用いて確率に変換し、出力層に出力する。

畳み込み層と全結合層の 1 層目では活性化関数として **ReLU** 関数を採用する。特徴マップでは余分な情報が多いほど画像の特徴を識

別することが難しくなる。**ReLU** 関数は、余分な情報を切り捨てることで画像の特徴を捉えやすくする効果を持つ。また、学習データが持つ特徴を過剰に学習することで、汎用性がなくなる過学習が起こる可能性がある。そのため、1 層目のプーリング層と 2 層目の畳み込み層の間、2 層目のプーリング層と 1 層目の全結合層、1 層目の全結合層と 2 層目の全結合層の間にドロップアウト層を設定する。ドロップアウト層では層と層の間の接続の一部をランダムに切断することで過学習を防ぐ役割を果たすものである。

3-3 CNNの実装

本研究における CNN を、OS が Windows 7、CPU が Intel Core i7 の PC を用いて実装した。また、開発ツールとして、Google Colaboratory を使用した。Google Colaboratory は、PC における Anaconda などの環境構築が不要であり、Python, Numpy, Jupyter Notebook などの CNN を実装するための環境が用意されているものである。また、CNN における学習では、膨大な計算が必要となるために、高性能 GPU が必要となる。Google Colaboratory では「Tesla K80 GPU」という GPU を使用することができ、高性能な GPU を備えた PC でなくとも、効果的に CNN を実装することが可能である。また、CNN を実装するためのライブラリとしては、Tensorflow, Keras を使用した。

4. CNNの識別性能検証

4-1 性能検証方法

検証実験では、山草を有毒と無毒に分類する 2 分類、山草を 1 種類ごと分類する 27 分類の 2 種類において性能を検証する。ここでは、基本となるハイパーパラメータとして、学習回数 400 回、バッチサイズ 32、最適化アルゴ

リズム SGD, 学習率 0.01, ドロップアウト率 0.25 を採用する。更に, 学習回数, 最適化アルゴリズム, 学習率, フィルタサイズの各パラメータ設定を変更することにより, 学習正解率がどのように変化するか検証する。

加えて, 画像識別において成果を挙げているアーキテクチャである AlexNet モデルを用いて毒性識別を行い, 本研究におけるモデルの学習正解率と比較を行う。本性能検証実験において, 利用するハイパーパラメータ, 及び, AlexNet の設定を表 1 に示す。

4-2 性能検証結果

4-2-1 クラス分類の検証結果

図 3 に, 山草を有毒と無毒に分類する 2 分類と山草を 1 種類ごとに分類する 27 分類の 2 種類のクラス分類において性能検証結果を示す。2 分類の学習正解率は 89%, 27 分類の学習正解率 56% となった。27 分類のクラスでは非常に似ている種が多々あるため, 学習正解率の低下に繋がったと考えられる。誤食による事故防止を考えた場合, 必ずしも一つ一つの山草が何であるのかを識別する必要はない。このため, 学習正解率の点から考えても 2 クラス分類を実施することが実用であると考えられる。このため, 2 クラス分類においてハイパーパラメータの変更による学習正解率の変化を検証する。

4-2-2 学習回数による検証結果

図 4 に各学習回数における学習正解率を示す。学習回数を 400 とした場合, 最も高い学習正解率である 88% が示された。図に示されるように学習回数を増加させることにより, 徐々に学習正解率は上昇しているが, 学習回数が 300 と 400 の差は, 非常に小さい。このため, これ以上学習回数を増加させたとしても正解率の大きな変化はないものと判断される。加えて, 学習回数を増加させた場合には,

表 1 検証におけるハイパーパラメータ

検証	検証内容
分類クラス	クラス2分類(山草の有毒性と無毒性) クラス27分類(山草1種ずつ)
学習回数	10回, 50回, 100回, 150回, 200回, 300回, 400回
最適化アルゴリズム	Adam, Adadelta, SGD, Nadam
学習率	0.5, 0.1, 0.05, 0.01, 0.001, 0.0001
フィルタサイズ	(3x3) (3x3), (3x3)(5x5), (5x5)(3x3), (5x5)(5x5), (3x3)(7x7), (7x7)(3x3), (11x11)(11x11)
AlexNetモデル	5層の畳み込み層, 3層のプーリング層 3層の全結合層, 1層のドロップアウト層

学習のために必要とされる処理時間が長時間




図 3 クラス分類の性能検証結果




図 4 学習回数における性能検証結果

となる。このため, 400 以上の学習回数設定は, 効果的ではないと考える。

4-2-3 最適化アルゴリズムによる検証結果

CNN では, 正解と出力結果の誤差を誤差関数と定義して勾配降下法を用いて重みやバイアスを更新しながら誤差関数を最小化する。これにより誤差を少なくし, 精度を向上させる。最適化アルゴリズムは, 重みやバイアスの更新量を学習率を用いて決定するためのアルゴリズムである。最適化アルゴリズムには

様々な種類があり、使用する最適化アルゴリズムによる学習正解率の変化を検証する。ここでは、Adam, Adadelta, SGD, Nadam を使用して検証する。また、本研究で使用する各最適化アルゴリズムの学習率は Keras において推奨されている学習率を使用する。

図 5 に検証結果を示す。図に示されるように、学習正解率は、Adam では 85%、Adadelta では 84%、SGD では 88%、Nadam では 84% であった。このため、山草の毒性識別に対しては、基本ハイパーパラメータとして採用した SGD が最適な最適化アルゴリズムであることが示された。

4-2-4 学習率による検証結果

ここでは、学習率の変更による識別性能の変化を検証する。学習率とは、CNN の最適化を行う際に重みやバイアスの調整をどの程度行うかを決定するパラメーターである。

図 6 に検証結果を示す。図に示されるように、基準である学習率 0.01 が最も高い正解率を示した。学習率を 0.01 より高い値として設定した場合には、正解率は低下する。これは、調整の値が大きすぎ、最適な値を発見できていないため正解率が低下しているものと考えられる。また、0.01 よりも小さい値に設定した場合にも、正解率が低下することが確認された。これは、学習回数が同一のため値が小さすぎることによって十分な学習ができていないためであると考えられる。

4-2-5 フィルタサイズによる検証結果

図 7 に畳み込み層におけるフィルタサイズの変更による識別性能の検証結果を示す。図に示されるように、1 層目 3×3、2 層目 5×5 のフィルタサイズを用いた場合、学習正解率が 90% となり最も高い値を示した。他のサイズのフィルタを利用した場合には、軽微な正解率の減少が示された。しかしながら、フィルタサイズが大きくなりすぎた場合には、正解率が大きく減少することが確認された。フ

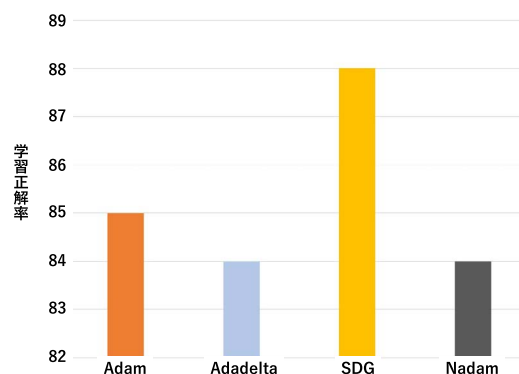


図 5 最適化アルゴリズムによる検証結果




図 6 学習率による検証結果




図 7 フィルタサイズによる検証結果

ィルタサイズを大きくしすぎた場合には、山草の特徴を捉えられないことが原因と考えられる。

4-2-6 AlexNet との比較検証結果

AlexNet とは、トロント大学において開発され、画像認識において大きな功績を上げていたモデルである。ここでは AlexNet と本モ

デルの学習正答率の比較を行う。AlexNet における構成、及び、設定ハイパーパラメータの詳細を表 2 に示す (Alex Krizhevsky, *et al*, 2012)。一方、本モデルにおけるハイパーパラメータは、識別性能検証において最も高い識別性能を示した、学習回数 400 回、フィルタサイズ 1 層目 3×3, 2 層目 5×5, 最適化アルゴリズム SGD, 学習率 0.01, ドロップアウト率 0.25 を採用している。

学習正解率の結果を図 8 に示す。AlexNet モデルは 92%, 本モデルは 90%の学習正解率を示した。学習正解率は AlexNet を用いた場合の方が、2%高い値を示した。しかしながら、AlexNet を用いた場合には、画像サイズが 227×227 と大きく、また、層の数も多いため非常に長い学習時間が必要とされた。一方、本モデルは画像サイズが小さく、層の数も少ないため比較的短時間で学習を行うことが可能である。このため、学習に必要な時間や環境を考慮し、採用すべきモデルを検討する必要があると考える。

5. おわりに

本論では、CNN を用いた山草の毒性識別の可能性を検証した。本研究では、シンプルな構成の CNN を利用し、毒性の有無の 2 分類において、90%という高い正解率を実現することができることを実験によって示した。更に、学習回数、最適化アルゴリズム、学習率、フィルタサイズを変更することによる学習正解率の変化を検証した。検証の結果、誤ったハイパーパラメータの設定により正解率が低下することが示された。また、AlexNet モデルを使用した毒性識別においては、本モデルを利用した場合と比較し、2%正解率を向上させることができることが示された。これにより、本学習モデルを改善させることにより更なる正解率の向上を実現することができる可

表 2 AlexNet の設定

層	サイズ	フィルタ数	ストライド	パディング	活性化関数
入力層	227×227×3				
畳み込み層1	11×11	96	4	なし	ReLU
バッチ正規化レイヤー					
プーリング層1	3×3		2		
畳み込み層2	5×5	256	2	あり	ReLU
バッチ正規化レイヤー					
プーリング層2	3×3		2		
畳み込み層3	3×3	384	1	あり	ReLU
畳み込み層4	3×3	384	1	あり	ReLU
畳み込み層5	3×3	384	1	あり	ReLU
プーリング層3	3×3		2		
全結合層1	4096				
ドロップアウト層					
全結合層2	4096				
全結合層3	2				ReLU

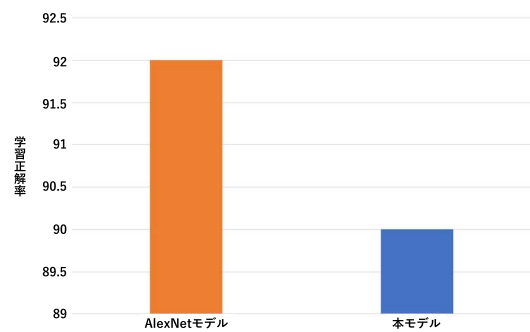


図 8 AlexNet との比較検証結果

能性が示された。これは今後の課題である。

参考文献

Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton (2012) 「ImageNet Classification with Deep Convolutional Neural Networks」, <https://papers.nipscc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf> (2020年1月28日)。
 北風裕教, 岡部蒼太, 吉原蓮人, 松村遼 (2019) 「Data Augmentation を用いた CNN 学習画像の増加による害鳥認識システムの認識率の改善」, 産業応用工学会論文誌, Vol.7, No.2, pp.69-76。
 厚生労働省 (2020) 「過去 10 年間の有毒植物による食中毒発生状況 (平成 21 年～30 年)」
<https://www.mhlw.go.jp/stf/seisakunitsuite/b>

unya/kenkou_iryoushokuhin/youudoku/

(2020年1月28日)。

農林水産省(2020)「野菜・山菜とそれに似た有毒植物」

<https://www.maff.go.jp/j/syouan/nouan/rinsanbutsu/leaflet.html> (2020年11月6日)。

生物多様性センター(2020)「日本の野生生物の既知種数」

https://www.biodic.go.jp/biodiversity/about/initiatives2/files/section_02/1-4_4.pdf, (2020年1月28日)。

安岡里都, 菌頭元春, 飯山将晃(2018)「ドローン搭載カメラ画像を用いた物体認識」, ELCAS Journal, Vol.3, pp.85-87。