

## 深層学習による材木画像での樹種判定

## Identifying tree species from lumber images using deep learning

西嶋 勘太<sup>‡</sup> 蛭田 雄也<sup>‡</sup>  
Nishijima Kanta Hiruta Yuya

## 1. はじめに

近年、木材の樹種を的確に識別できる熟練技術者の減少が顕著となっており、これに伴い木材加工現場では誤った樹種の選定が発生しやすくなっている[1]。こうした誤判定は、製品の品質低下や木材としての価値の損失、さらには歩留まりの悪化を招くなど、木材産業にとって深刻な経済的損失を引き起こす重大な課題である。

とりわけ、合板や集成材といった複合木材製品の製造においては、異なる樹種が混在するケースも少なくなく、その結果、完成品の等級判定にバラつきが生じる要因となっている。現行の製造工程では、製品の完成後に目視や物理的検査を通じて A~C ランクまたは廃棄といった等級に分類する「後処理的な判別」が主流である。しかし、もし製造前の段階で使用する木材の樹種を高精度かつ迅速に判定できる手段が確立できれば、より適切な材料選定が可能となり、結果として不良品の発生を未然に防ぎ、材料ロスや人的労力、製造コストの大幅な削減が実現できる。これにより、木材加工業者の生産効率や収益性の向上も見込まれる。

本研究は、このような現場における課題を背景として、専門的な知識や高価な装置を必要とせず、誰もが手軽に利用可能な「木材樹種の自動判別システム」の実現を目指すものである。具体的には、スマートフォンなどの一般的な撮影デバイスを用いて、塗装前の木材表面（とくに柾目面）を撮影し、その画像から畳み込みニューラルネットワーク（CNN）に基づく画像認識モデルによって樹種を図1のように自動判別する手法を提案する。

既存の研究においても、木材の顕微鏡画像や高解像度な表面画像を対象に CNN を用いた分類手法が有効であることが報告されている[2][3]。これらの研究では、細かな木目模様や細胞構造といった視覚的特徴を利用し、高精度な判別を実現している。しかし、顕微鏡や特殊な撮影環境を要する点は、現場への応用という観点ではハードルが高い。そこで本研究では、より実用的な運用を想定し、照明や設置環境に制限がある中でも、スマートフォンによる簡易撮影で判別が可能な実装を目指した。

同様のアプローチとして、スマートフォンを用いて撮影された韓国産針葉樹の画像から樹種分類を行った研究[4]が存在し、スマートフォンカメラでも一定の識別精度が得られる可能性が示唆されている。本研究では上記研究と違い日本国内で流通する木材を対象とし、数百枚と少ない学習データでも精度を高められる中規模 CNN の転移学習を行った判別モデルを作成した。これを用いて樹種分類の実現可能性を検証した。

## 2. 深層学習による材木画像での樹種判定

## 2.1 木材画像の取得環境

本研究では、木材の柾目（まさめ）面を対象に、撮影条件を可能な限り統一するための図1の撮影イメージより簡易な撮影ボックスを自作し、データセットを構築した。照明にはスマートフォン内蔵の LED ライトを使用し、外部照明機器を必要としない低コストかつ携帯性に優れた撮影環境を実現した。撮影にはスマートフォンを用い、内蔵 LED ライトを常時点灯させた状態で木材を至近距離から撮影した。LED 光源はカメラレンズの近傍に配置されているため、照明と撮影視点の位置関係が一定であり、被写体に対する陰影や反射のばらつきを最小限に抑えることが可能である。

## 2.2 画像前処理とデータ拡張

取得した画像は、学習モデルへの入力に適するよう、以下の前処理を施した。すべての画像を 224×224 ピクセルにリサイズし、学習時にはデータ拡張として 90 度単位での回転処理を加えた。これにより、過学習の抑制とモデルの汎化性能の向上を図った。

## 2.3 モデル構成と転移学習

本研究では、ImageNet で事前学習された 2 つの CNN アーキテクチャ——VGG19 および ResNet50 を用いた転移学習を行った。両モデルとも、最終分類層を木材のクラス数 (N=6) に対応させた上で学習を行った。

いずれのモデルも損失関数には CrossEntropyLoss を、最適化アルゴリズムには Adam (学習率 1e-4) を用いた。

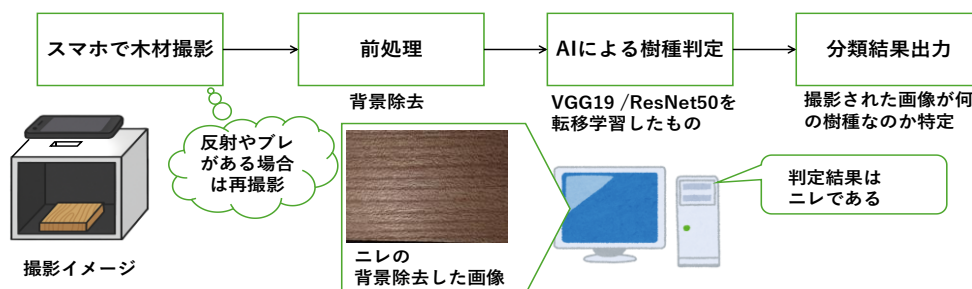


図1 深層学習による材木画像での樹種判定

<sup>‡</sup> 旭川工業高等専門学校 National Institute of Technology, Asahikawa College

## 2.4 学習・評価方法

本研究では学習後のモデル性能を評価するため、全体の正解率 (Test Accuracy) およびクラスごとの分類精度 (各クラスの Accuracy) に着目して評価を行った。特に各樹種 (クラス) ごとの識別性能の違いを明確にするため、分類結果に基づいたクラス別 Accuracy を算出し、精度向上の傾向や課題を把握した。

また、汎化性能を検証するため、学習時とは異なる環境で撮影された未学習の木材画像を用いてテストを行い、モデルの実用性を検証した。

## 3 実験

本研究では、表2のフォルダ構成に従って木材画像を整理し、それぞれのカテゴリごとに学習を行った。各フォルダには図1に示すような対象樹種の画像 (Xperia IVで撮影したもの) が格納されている。

表1 樹種ラベル

0	ウォールナット
1	カバ
2	カラマツ
3	タモ
4	ナラ
5	ニレ
6	ヒノキ
7	杉



図2 ウォールナットの画像

### 3.1 vgg19の評価

VGG19モデルによるテストデータの分類精度は表2より\*\*61.11%\*\*であった。クラス別の精度を見ると、4 (ナラ)、5 (ニレ)、7 (杉) では高精度が得られた一方で、1 (カバ) では全く分類できていない。

表2 認識率

Class	Accuracy_Run1 (%)
0	85.71
1	0
2	75
3	20
4	100
5	75
6	25
7	100
Test Accuracy	61.11

### 3.2 resnet50の評価

ResNet50モデルでは、表3より91.67%という高い分類精度を達成した。とくに0 (ウォールナット)、1 (カバ)、3 (タモ)、4 (ナラ)、5 (ニレ)、6 (ヒノキ) では100%の認識率を示し、非常に良好な結果となった。

表3 認識率

Class	Accuracy_Run2 (%)
0	100
1	100
2	50
3	100
4	100
5	100
6	100
7	75
Test Accuracy	91.67

### 3.3 考察

VGG19とResNet50では、誤分類の傾向に明確な違いが見られた。VGG19では全体的に分類精度が低く、特にカバ(1)に関しては完全な分類失敗が確認された。一方、ResNet50ではほぼ全てのクラスにおいて高精度な分類が実現されており、特に細かい木目模様の識別に有効であったと考えられる。この差異は、ResNet50がより深いネットワーク構造を持ち、微細な特徴を抽出する能力に優れているためであると推測される。木材の樹種判別においては、微細な模様や繊維構造の違いが重要な判断材料となるため、深層モデルの効果が顕著に現れたといえる。

## 4 まとめ

本研究では、スマートフォンによる簡易撮影画像を用いた木材の樹種判別において、転移学習を用いたCNNモデルの有効性を検証した。その結果、VGG19と比較してResNet50が高い精度を示し、木材画像に含まれる微細な情報を捉えるためには深いネットワーク構造が有効であることが示唆された。また、専門機材を用いずとも、簡便な環境で高精度な分類が可能である点から、林業現場や材木店における即時判定システムへの応用可能性が期待される。

今後は、さらなるクラスの追加、撮影条件の多様化、リアルタイム推論性能の向上を図ることで、実務への導入を視野に入れた研究を進めていきたい。

### 謝辞

本研究にあたり、学習用木材や情報のご提供を賜りましたエノ産業株式会社に、深く感謝の意を表します。

### 参考文献

- [1] 令和5年度 森林・林業白書 (林野庁)
- [2] Shinya, T. et al., "Wood species identification using convolutional neural networks," *Forestry Informatics*, vol. 15, no. 2, pp. 45–52, 2020.
- [3] Nguyen, H. et al., "Automatic identification of Southeast Asian wood species using deep learning," *Ecological Informatics*, vol. 60, 2021.
- [4] Kang, E., Moon, J., Jeong, H., et al. (2017). "Automatic Wood Species Identification of Korean Softwood Based on Smartphone Camera", *Journal of the Korean Wood Science and Technology*, Vol.45, No.6, pp.797–805.