

赤外線年輪画像の CNN 解析による木材の分類

浅野 美代子 (大東文化大学法学部)

Classification of Tree-Rings in Infrared Images using Convolutional Neural Network

Miyoko ASANO

要旨

木材産業では知識や情報が共有されず、森林伐採から製材品流通までの連携が不十分であるという問題がある。木材の樹種、原産地及び品質などを表示し、利用する木材にかかわる様々な情報を共有システムが必要である。本研究では、丸太の赤外線年輪画像を入力画像とし、画像認識技術である畳み込みニューラルネットワーク (Convolutional Neural Networks (CNN)) による丸太個体を特定する。

1 はじめに

林業の活性化や森林持続可能性に寄与するため「木材資源循環」と「木材トレーサビリティ」が重要である。[林野庁、令和2年度森林・林業白書 (2020)]、現状として消費者は自らが使用している製材品を確認する術はなく、正確な情報を得ることが困難である。木材の出所・履歴を明らかにし、木材流通における追跡可能性、即ち木材のトレーサビリティ (traceability) が注目されている。[林野庁、森林・林業基本計画]

これまで木材トレーサビリティシステムを構築する試みは、木材の情報を記載した QR コードや電子タグなどの方法が実施されている。しかし、QR コードや電子タグは取れやすいという欠点がある。[添原 洋平、他 (2014)]

一方、木材の年輪の生成は、周りの環境及び気象状況などによって影響を受けることが知られている。原木丸太の端部においては、年輪、寸法及び形状の情報が含まれているため、こちらの情報が古くから木材の樹齢、樹種識別に使われている。そこで本研究では、画像認識でよく使われるディープラーニングの代表的な畳み込みニューラルネットワーク (Convolutional Neural Networks (CNN)) [Y. Lecun、他 (1998)] [A. Krizhevsky、他 (2012)]、[S. Pereira、他 (2016)] を用い、丸太赤外線年輪の画像を解析して木材の特定を可能にする。

丸太年輪の赤外線画像解析 CNN モデルに関しては、[浅野美代子・鄭宏杰、他 (2020)] と同一の丸太年輪の画像解析 CNN モデル (図 1) を用いた。

浅野美代子・鄭宏杰、他(2020)では、市販の一眼レフカメラで撮影した画像を用いたが、本論では赤外線カメラ(PRNTAX KP-IR)撮影画像を用いた。赤外線カメラは研究開発・調査目的での使用が多く、一般の方が使用する事がない機材である。被写体からの放射される赤外線もしくは被写体に赤外線を照射して撮影するカメラで赤外線の吸収、反射の違いが通常の可視光撮影のカメラと違う画像が得られるため木材木口のチョークの文字や樹液や切り口の汚れなど赤外線を吸収しない部分は反射で白く見え年輪が鮮明に確認できた。また、赤外線カメラは同様に切断した断面の段の影響も抑えられたフラットな画像を得られる事ができた。

CNN分析は、深層学習(Deep Learning)とも言われているが、ニューラルネットワーク分析の1つである。一番単純なモデルは、入力層、中間層1層、出力層のフィードフォワード型ニューラルネットワークである。中間層にコンボリューション層とプーリングを加え多層にしたモデルがCNNモデルである。

実務で有効なニューラルネットワーク解析として[浅野良晴, 他(2000a)、(2000b)]があげられる。しかしながら、ニューラルネットワーク分析は、「予測精度は高いが、解析はブラックボックスで解釈可能性が低い」と言われていた。浅野らによって、予測精度の高い理由が解明された。[浅野美代子(2001)、(2002)]、[Asano, M., Tsubaki, H., Yoshigawa, T. (2002)]。ニューラルネットワーク分析では変化点が自動的に発見されていた。さらに解釈可能である解析法:ニューラルネットワークと線形回帰分析のハイブリッド解析法[浅野美代子・椿広計(2003)]を提案した。

2 研究方法

本研究では、CNN特徴量に基づく赤外線年輪画像から丸太を分類する。CNNは深層学習モデルの一つで、何段も深い層を持つニューラルネットワークである。

図1にCNNによる赤外線年輪画像を認識するCNNモデルの概要を示す。このモデルのネットワーク構造は、入力層-Conv16-MP-Conv32-MP-Conv64-MP-Conv64-MP-Conv64-MP-FC500-FC200-FC100-FC50-Softmax(2クラス)とした。ここで、MPは最大プーリング2×2、FCは全結合層、活性化関数はReLUとし、全ての層においてフィルタのサイズはサイズ3×3とした。学習回数は10回として学習を行った。データ画像の前処理として、まず元の赤外線年輪画像を年輪の中心位置を円心として円形で切り取った。その後切り出した画像は、CNNモデルの入力として、224×224画素にリサイズし入力画像サイズを統一した。CNNの出力としては、特定したい年輪とそれ以外の年輪の識別を行う2クラス分類に設定した。

シミュレーションは、TensorFlowをもちい、データ拡張(水増し)は、ニューラルネットワークライブラリ:Keras[12]、[13]のImageDataGeneratorクラスを用いて行った。

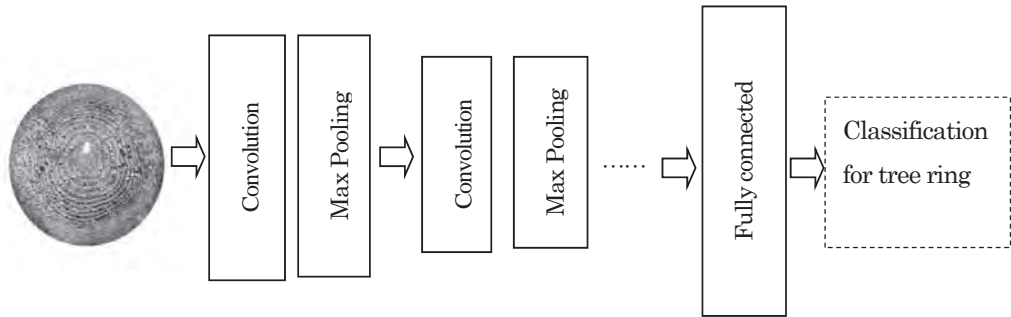


図 1. CNN による年輪の分類

浅野美代子・鄭宏杰、他、「年輪の CNN 分析」、大東文化大学紀要第 59 号、〈社会科学〉、P.203 (2020) より引用。

3 実験内容

この章では、3. 1 実験：赤外線年輪画像分析、3. 2 学習用データセット、3. 3 検証用データセット、3. 4 実験結果と考察について述べる。

3. 1 実験：赤外線年輪画像分析

ここで学習に用いるデータセットと検証用データセットを紹介する。2021 年 3 月 22 日に、青梅市にある多摩木材センターで撮影した 25 赤外線年輪画像を用いた。図 2 に示した。

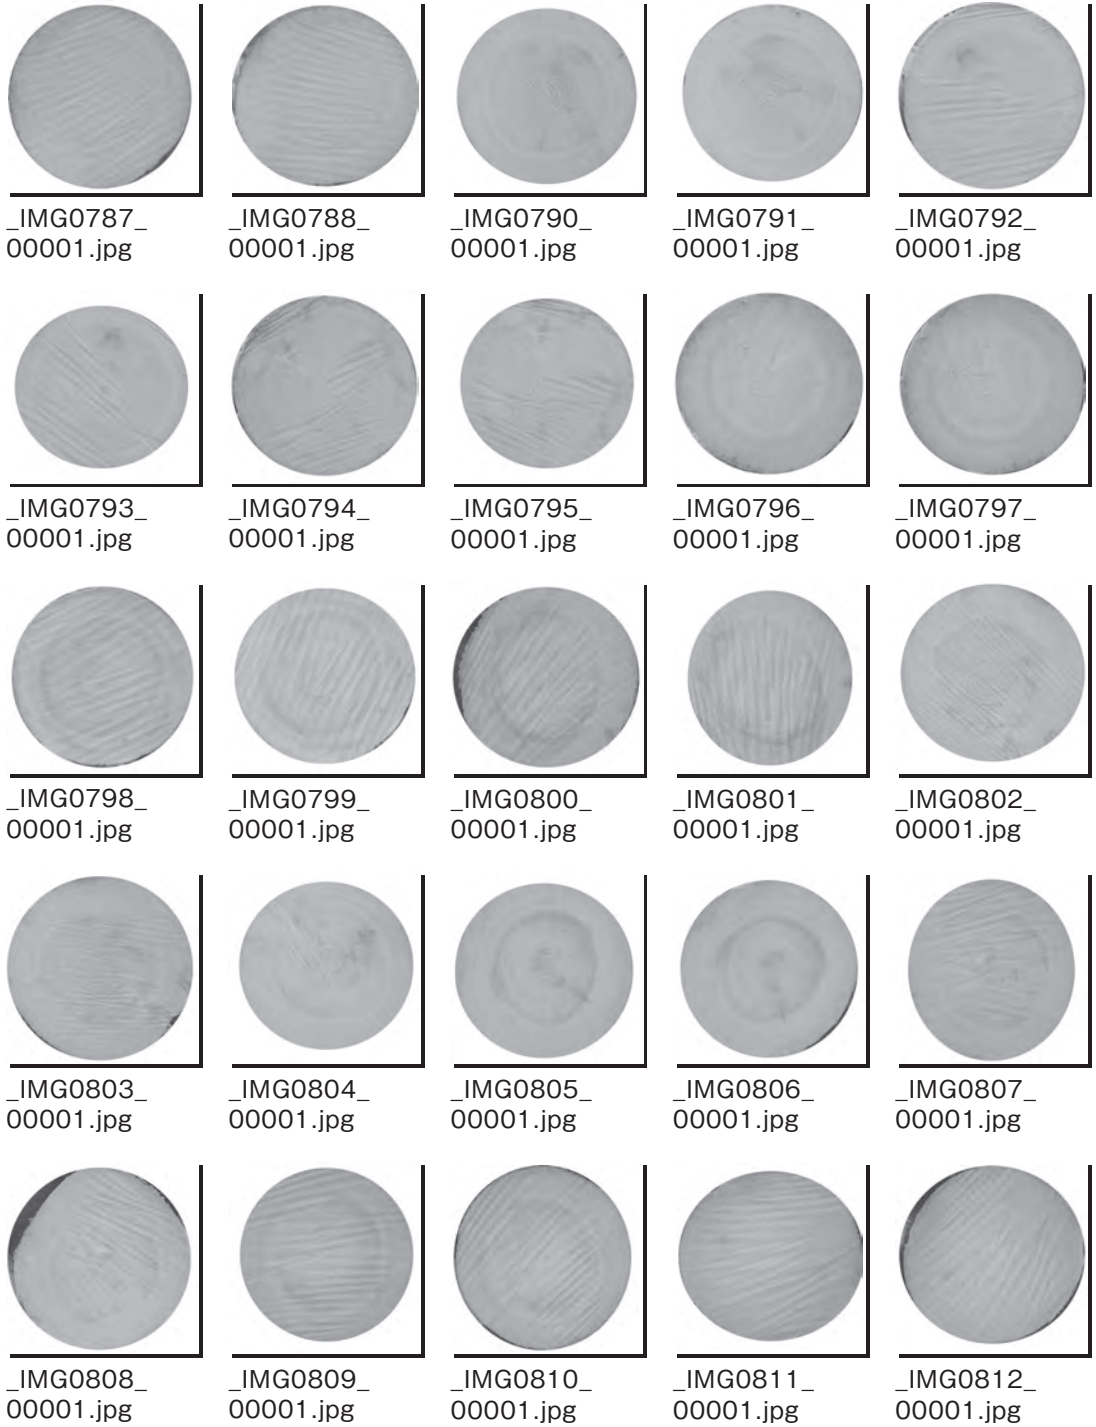


図2. 25赤外線年輪画像：多摩木材センター，撮影日：2021年3月22日。



図 3. 赤外線年輪画像：(a) 特定したい年輪、(b) それ以外の年輪の例

3. 2 学習用データセット

学習データは、IMG0790 の水増し赤外線年輪画像データ 383 枚、IMG0792 から IMG0812 の：21 画像を、それぞれ約 20 画像水増しした合計 441 赤外線年輪画像との合計 824 赤外線年輪画像とした。赤外線年輪画像の特性を保持するために、データ拡張方法としては、回転・拡張・明度変更の画像を学習データに追加した。まず特定したい年輪（図 3a）を回転による拡張し 383 画像を作成した。分類するラベルは“1”に設定した。次にそれ以外の年輪（図 3b）は、9 枚の年輪画像から回転・拡張・明度変更により拡張し、それぞれ約 20 画像、合計 441 画像を作成した。分類するラベルは“0”に設定した。作成した学習データをさらに訓練用データとテスト用データに分割した。すなわち、訓練用データ（741 画像）とテスト用データ（83 画像）に分割した。図 4 に TensorFlow で出力される訓練データとテストデータのエポックごとの精度、図 5 に訓練データとテストデータのエポックごとの誤差を示した。

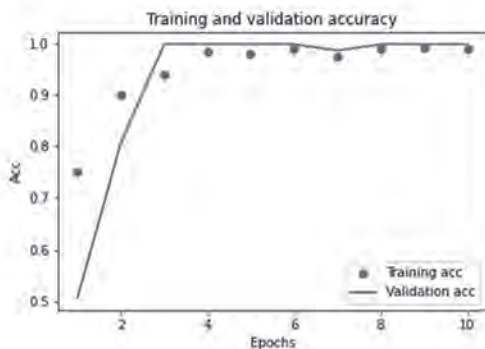


図 4. 訓練データとテストデータのエポックごとの精度

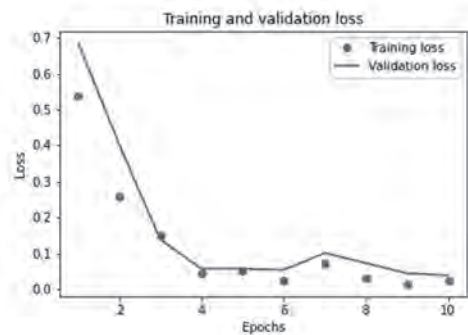


図 5. 訓練データとテストデータのエポックごとの誤差

3. 3 検証用データセット

検証データは、図1の25赤外線年輪画像と、IMG0790の水増し年輪画像データ40枚合計65赤外線画像とした。

3. 4 実験結果と考察

検証用データの分類結果を表1に示す。表1より、特定したい年輪の正解率は97.6%、それ以外の年輪の正解率は100.0%であった。実際に木材を認証する際に、故意に木材を他の所から持ち込んだ場合、或いは故意ではないが作業で紛れ込んだ場合を想定すると、さらに検証用データを作り誤認識をシミュレーションすることが大事であるが、訓練時に特定したい年輪以外の画像を増やすことにより、正解率は高くなると考えられる。今後学習データ数と検証用データセット数のさらなる検討を行うことにより、正解率を向上させることができる。

表1. 検証用データの分類結果

| 区分 | 分類クラス名 | 正解数 | 不正解数 | 正解率 |
|-----------------|--------|-----|------|--------|
| 特定したい年輪よる拡張した画像 | 1 | 40 | 1 | 97.6% |
| それ以外の年輪よる拡張した画像 | 0 | 24 | 0 | 100.0% |

4 まとめ

本稿では、CNNによる年輪画像を認識手法の有効性を確認した。さらに学習と検証用データセットの作成方法を報告し、認識精度について検証を行った。但し、1本の丸太木口に1枚の画像を用い、画像処理によって学習データおよび検証データを作成したため比較的認識しやすい。今後は、1本の丸太木口において画像を増やし、検証する予定である。

浅野美代子・椿広計が2003年に提案した「ニューラルネットワークと線形回帰分析のハイブリッド解析法」を用いて解析を行いCNN結果と比較する。

謝辞

リコージャパン株式会社 ICT事業本部エッジソリューション企画センター SmartVision 事業企画室の豊見坂 誠様に赤外線カメラ (PENTAX KP-IR) 及び、可視光・赤外透過フィルター (IR フィルター) の使い方を教示していただきました。東洋大学総合情報学部・鄭宏杰先生に、赤外線年輪画像分析 CNN モデル構築で助言をいただきました。信州大学工学部特任教授・浅野良晴先生に年輪画像の提供と木材の性格・定義を教示していただきました。

ここに記してお礼を述べます。

本研究は日本学術振興会の科学研究費補助金（基盤研究 C：20K12286）の助成を受けたものである。（研究課題名：CNN と線形回帰のハイブリッド解析法を用いた年輪の赤外線画像分析、研究代表者：浅野美代子）

参考文献

1. A. Krizhevsky, I. Sutskever, G. E. Hinton (2012), ImageNet classification with deep convolutional neural networks, NIPS.
2. S. Pereira, A. Pinto, V. Alves, C. Silva (2016), Brain Tumor Segmentation Using Convolutional Neural Networks in MRI Images. IEEE Transactions on Medical Imaging, 35 (5), p. 1240–1251.
3. Y. Lecun, L. Bottou, Y. Bengio, P. Haffner (1998), Gradient-Based Learning Applied to Document Recognition, Proc. of The IEEE.
4. 浅野良晴, 馬場宗, 浅野美代子 (2000a) 「東京都の限定された区域における給水量の経年推移の予測法に関する研究」, 日本建築学会計画系論文, 第 528 号, 51-57.
5. 浅野良晴, 馬場宗, 浅野美代子 (2000b) 「戸建て住宅における用途別使用水量の推定に関する研究」, 日本建築学会計画系論文, 第 527 号, 53-59.
6. 浅野美代子 (2001), 「階層型ニューラルネットワークを用いた変化点問題の解析」, 第 69 回日本統計学会, 225-226.
7. 浅野美代子 (2002), 「ニューラルネットワークを用いた層別因子を含む回帰構造の解析」, 計算機統計学, 第 14 巻 2 号, 123-137.
8. Asano, M., Tsubaki, H., Yoshizawa, T. (2002). Effectiveness of neural networks to regression with structural changes, Applied Stochastic Models in Business and Industry, Volume 18, Number 3, 189 – 195.
9. 浅野美代子, 椿広計 (2003) 「ニューラルネットワークと線形回帰分析のハイブリッド解析法」, 応用統計学, 第 31 巻 3 号, 227-238.
10. 添原 洋平, 松場 啓太, 浅野 良晴, 高村 秀紀 (2014), 建築用木材のデータベース化に関する研究 (第 2 報) 木材トレーサビリティシステムの実証実験, 平成 26 年度大会 (秋田) 学術講演論文集, 第 10 巻, 都市・環境編, D-72.
11. 浅野美代子, 鄭 宏杰, 鈴木 輝, 海老原 広和, 年輪の CNN 分析, 「大東文化大学紀要」, 第 69 号, <社会科学>, pp.200 – 205 (2020).
12. Keras. 2015. Home page: <https://keras.io/>, (アクセス日 2021/09/15) .
13. Chollet F. Keras. 2015. <https://github.com/fchollet/keras>, (アクセス日 2021/09/15).
14. 林野庁, 令和 2 年度森林・林業白書 (2020), <https://www.rinya.maff.go.jp/j/kikaku/hakusyo/r1hakusyo/zenbun.html>, p. 167 (アクセス日 2020/09/09).
15. 林野庁, 森林・林業基本計画, 森林・林業基本計画: 林野庁 (maff.go.jp), (アクセス日 2021/09/15).
16. 浅野美代子, 基盤研究 (C), 2007～2008 年度, ニューラルネットワークと線形回帰分析のハイブリッド解析法 Web システム, 研究代表者.