

論文

異なる再造林地におけるUAV画像を用いた
深層学習によるスギ植栽苗木検出^{*1}二神慶多^{*2}・加治佐剛^{*3}・寺岡行雄^{*3}

二神慶多・加治佐剛・寺岡行雄：異なる再造林地における UAV 画像を用いた深層学習によるスギ植栽苗木検出 九州森林研究 77 : 77 - 81, 2024 林業・林産業分野において、近年急速な技術的發展を遂げている深層学習を活用した研究が進んでいる。本研究では、異なる再造林地で撮影した UAV 画像を使用して、畳み込みニューラルネットワークをベースとした物体検出アルゴリズムである YOLOv5 によるスギ植栽苗木の自動検出を試みた。学習モデルに対して複数の再造林地の UAV 画像を混合させた場合は、Precision (適合率) と Recall (再現率) とともに 0.9 程度の値となり、高精度で苗木を検出することができた。一方で、学習モデルと評価用データに対してそれぞれ異なる再造林地の UAV 画像を使用した場合は、Precision は 1.00 に近い値を示したものの、多くの苗木を検出できず、Recall は最小で 0.01 を示し、学習モデルと評価用データとで画像のパターンが異なると汎用性が認められないことが示唆された。汎用性を向上させるためには、データのさらなる拡充や学習モデルの見直しが重要な課題だと考えられる。

キーワード：UAV, 再造林地, 苗木検出, 深層学習, 汎用性

I. はじめに

我が国の森林の約 4 割は人工林であり、さらにその半数が 50 年生を超えており、主伐期を迎えている (林野庁, 2023)。2021 年 6 月に閣議決定された森林・林業基本計画では、新たな基本計画のポイントに森林・林業・木材産業による「グリーン成長」を掲げており、森林資源の循環利用に向けて再造林を推進している (林野庁, 2021)。再造林後において植栽本数や枯損率を把握することは重要であるが、これらの作業を現地で行うには多大な労力を要する。そこで、高解像度のデータを容易に取得できる UAV (Unmanned Aerial Vehicle) を活用すれば、再造林地のモニタリングを効率的に行うことが可能になる。また、林業・林産業分野においても、近年急速な技術的發展を遂げている深層学習による研究が活発化している (松下, 2022)。例えば、携帯端末で撮影した画像を使用したスギとヒノキの自動分類 (神原ほか, 2021) や針葉樹の自動樹種判別 (美濃羽・中司, 2022) などが報告されている。海外では UAV 画像を使用して深層学習により針葉樹苗木を自動検出する研究が進んでおり (Fromm *et al.*, 2019; Pearse *et al.*, 2020; Yu *et al.*, 2022)、いずれも高精度での検出結果を報告している。一方で、国内では GIS を使用して作成した樹冠高モデルから、苗木の自動検出を試みた事例がある (中川ほか, 2021) が、深層学習による苗木の自動検出の事例は少ない。国内の再造林地においても海外と同様に UAV 画像上から苗木の自動検出が可能になれば、植栽本数や枯損状況のモニタリングが容易になり、再造林地の長期的管理が期待できる。

本研究では、UAV 画像から深層学習によるスギ苗木の自動検出精度を明らかにすることを目的とし、複数の造林地の UAV 画像を使用して苗木検出を行った。また、深層学習による物体検出

は、未知のデータに対しても対応できる汎用性が重要となる。ここで、学習モデルと評価用データに対してそれぞれ異なる再造林地の UAV 画像を使用して苗木検出の精度評価を行った。

II. 材料と方法

1. 調査対象地

調査対象地は、鹿児島県霧島市に位置する 3, 4 年生スギ人工林 (以下、霧島) と、鹿児島県垂水市に位置する鹿児島大学農学部附属高隈演習林 (以下、高隈) 106 林班 36 ア-1 小班 4 年生スギ人工林, 108 林班 5 小班 5 年生スギ人工林, 108 林班 43 小班 5 年生スギ人工林とした (図-1)。

霧島および高隈 108 林班 5 小班では下草はあまり見られなかったが、高隈 108 林班 43 小班および 106 林班 36 ア-1 小班では下草が繁茂していた。とりわけ 106 林班 36 ア-1 小班において下草が発達していた。

2. 空中撮影

撮影に使用した UAV は Phantom 4 Pro (DJI, 中国) である。霧島は 2021 年 12 月 13 日 (当時 3 年生) と、2022 年 9 月 7 日 (当時 4 年生) に、高隈は 2023 年 9 月 13 日に撮影を行った。飛行高度はいずれも 30 m とし、自動航行アプリである GS PRO (DJI, 中国) を使用してコースを設定し、自動で撮影を行った。

3. 深層学習

深層学習は、多層のニューラルネットを用いた機械学習の方法であり (岡谷, 2015)、代表的な手法として畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) が挙げら

^{*1} Futagami, K., Kajisa, T. and Teraoka, Y.: Detection of sugi (*Cryptomeria japonica*) seedling using UAV imagery with different reforested areas in deep learning

^{*2} 鹿児島大学大学院農林水産学研究所 Grad. Sch. Agric., Kagoshima Univ., Kagoshima 890-0065, Japan

^{*3} 鹿児島大学農学部 Fac. Agric., Kagoshima, 890-0065, Japan

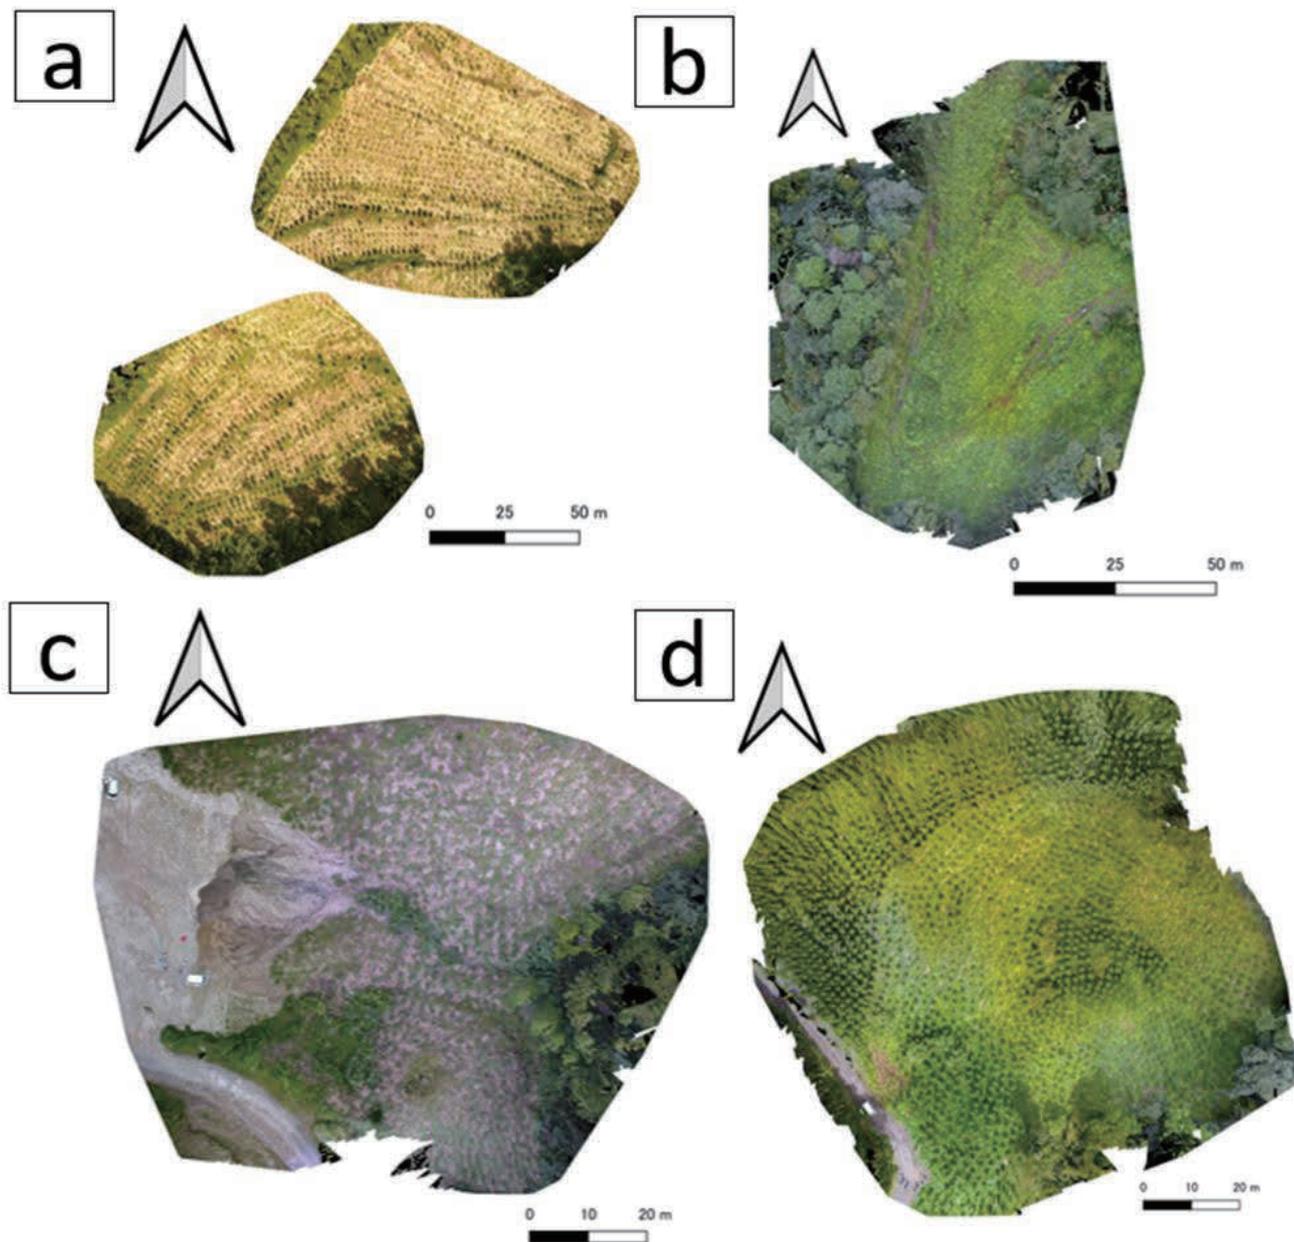


図-1. 調査対象地
 a : 霧島 (9月撮影), b : 高隈 106 林班 36 ア-1 小班, c : 高隈 108 林班 5 小班, d : 高隈 108 林班 43 小班

れる。CNNとは、視覚神経系の構造にヒントを得たモデルの総称である。また、特定のタスクにとって最も有益な特徴量を自動的に学習でき (Raschka and Mirjalili, 2018), 物体検出のベースネットワークとして広く利用されている (内田・山下, 2019)。

YOLO (You Only Look Once) は、CNNをベースとしたオープンソースの物体検出アルゴリズムであり、既存のアルゴリズムと比較して処理速度が速いとされている (Redmon *et al.*, 2016)。本研究では、YOLOv5 (Jocher, 2020) を使用して学習・精度評価を行った。

4. アノテーションデータおよび学習モデルの作成

YOLOv5に入力する画像には、アノテーションと呼ばれる作業を行う必要がある。アノテーションとは、画像から検出対象

(本研究ではスギ苗木) を Bounding Box と呼ばれる矩形領域で囲み、教師付きデータを作成する作業である。本作業にはアノテーションツールである labelImg (Tzutalin, 2015) を使用した。

なお、Phantom 4 Pro で撮影した単写真は、4,000 × 3,000 pix であるが、単写真には非常に多くの苗木が写っており、正しくアノテーションを行えない可能性がある。そこで、単写真を YOLOv5 の学習モデルの標準サイズである 640 × 640 pix へと分割し、分割画像を学習・精度評価に使用した。最終的に、霧島から 758 枚、高隈から 607 枚の画像を取得した。さらに、霧島の画像 758 枚から、166 枚を検証用データへと無作為に抽出し、残りの画像 592 枚を学習用データとした。また、高隈の画像 607 枚から各小班 30 枚、合計 90 枚ずつを検証用データと評価用データへとそれぞれ無作為に抽出し、残りの画像 427 枚を学習用データ

とした。

本研究では、これらのデータから2つの学習モデルを作成してそれぞれ実験 (a), (b) を行った。実験 (a) では霧島と高隈の画像から学習モデルを作成し、実験 (b) では霧島の画像から学習モデルを作成した。また、評価用データはいずれも高隈の画像を使用した。各実験におけるデータセットの詳細を表-1に示す。

5. 精度評価

本研究では、混同行列 (Confusion Matrix) から算出される評価指標を使用した。混同行列とは、二値分類の結果をまとめた行列であり、予測値と実測値の関係を表す (表-2)。TP (True Positive) は苗木を正しく検出したもの、FP (False Positive) は苗木ではない領域を苗木だと誤検出したもの、FN (False Negative) は苗木を苗木ではないと見逃したものを表す。評価指標は、Precision (適合率) と Recall (再現率) を使用した。Precision は、検出した苗木のうちどれだけ正しく検出できたかを表し、Recall は、正解データのうちどれだけ正しく苗木を検出できたかを表す。Precision と Recall の計算式を以下に示す。

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

III. 結果

1. 実験 (a)

実験 (a) における検出結果を表-3に示す。各小班において FP が FN よりも多く、検出された苗木の本数は実際の苗木の本数を上回った。Precision は、各小班で0.9程度の値を示した。

表-1. 実験 (a), (b) におけるデータセットの詳細

実験	データセット	霧島		高隈		合計	
		画像 (枚)	苗木本数 (本)	画像 (枚)	苗木本数 (本)	画像 (枚)	苗木本数 (本)
実験 (a) (霧島 + 高隈 →高隈)	学習用データ	592	6,623	427	8,379	1,019	15,002
	検証用データ	166	1,835	90	1,888	256	3,723
	評価用データ			90	2,076	90	2,076
実験 (b) (霧島→高隈)	学習用データ	592	6,623			592	6,623
	検証用データ	166	1,835			166	1,835
	評価用データ			90	2,076	90	2,076

表-2. 混同行列

		予測値	
		Positive	Negative
実測値	Positive	TP (True Positive)	FN (False Negative)
	Negative	FP (False Positive)	TN (True Negative)

また、Recall は、各小班で1.00に近い値を示した。各小班において Recall が Precision よりも高い値を示し、苗木の見逃しよりも苗木の誤検出が多い結果となった。

2. 実験 (b)

実験 (b) における検出結果を表-4に示す。106林班36ア-1小班で TP は9本である一方で、108林班5小班では275本と、小班によって苗木の検出本数に大きな差が見られた。Precision は106林班36ア-1小班と108林班43小班で1.00を示し、検出した苗木は全て正解であった。108林班5小班においては、FPは見られたが5本であり、Precision は0.98であった。一方で Recall は、106林班36ア-1小班で0.01と最小となり、最大は108林班5小班で0.42であった。

表-3. 実験 (a) における苗木検出結果

	106林班	108林班	
	36ア-1小班	5小班	43小班
TP	600	635	786
FP	90	84	56
FN	20	17	18
実際の本数	620	652	804
検出本数	690	719	842
Precision	0.87	0.88	0.93
Recall	0.97	0.97	0.98

IV. 考察

1. 実験 (a)

FP, FN の例を図-2に示す。FP の例として下草を苗木だと誤検出しているものも多く見られた (図-2 (a))。Pearse *et al.* (2020) は、下草はFPの主な要因であると報告しており、本実験でも同様であると考えられる。またFNの例として、苗木が

表-4. 実験 (b) における苗木検出結果

	106林班	108林班	
	36ア-1小班	5小班	43小班
TP	9	275	151
FP	0	5	0
FN	611	377	653
実際の本数	620	652	804
検出本数	9	280	151
Precision	1.00	0.98	1.00
Recall	0.01	0.42	0.19

密集している領域において苗木の見逃しが見られた（図-2 (c)）。苗木が密集していると、苗木の輪郭が不鮮明になるため（花岡, 2021）、FNが発生したと考えられる。また、画像の端の領域においてはFPとFNどちらも多く見られた（図-2 (b), (d)）。単写真を分割する線上に存在する苗木は見切れてしまう。画面端で見切れてしまった苗木は、樹冠全体が写っている苗木よりもデータ量が少なかったため、十分に学習できず正しく検出できなかったと考えられる。

2. 実験 (b)

霧島の画像および高隈の各小班における苗木検出例を図-3に示す。霧島は下草が繁茂しておらず、地面と苗木の違いが明瞭であるが、Recallが最小値を示した106林班36ア-1小班では小班全体に下草が繁茂していた。深層学習による物体検出では、学習モデルに含まれないデータの予測は困難であり（間下, 2018；宮本, 2020）、本実験では、学習モデルと評価用データとで苗木の写り方などの画像のパターンが異なっていたため苗木が検出できなかったと考えられる。また、108林班5小班は、学習モデルに対して地面と苗木の色調などの特徴量がほかの小班と比較して最

も類似していたため、Recallが0.42と最大値を示したと考えられる。汎用性を高めるためには、多様な条件で撮影した画像を取得するほか、学習・精度評価に同時期での画像を使用するなど、データの与え方に工夫が必要である。

V. まとめ

本研究では、異なる再造林地のUAV画像を混合させて学習・精度評価を行った実験(a)と、学習・精度評価に対してそれぞれ異なる造林地のUAV画像を適応させた実験(b)を行った。実験(a)では、PrecisionとRecallともに0.9程度の値を示し、海外での先行研究と比較して同等以上の検出精度を示し、国内の造林地においても苗木の自動検出は有効であることが示唆された。一方で、実験(b)では、Precisionは高い値を示したものの、Recallは、最小で0.01と苗木を十分に検出できず、汎用性が認められなかった課題が挙げられた。学習モデルに含まれていないパターンの物体検出は困難であることから、汎用性を向上させるために、様々な再造林地や異なる時期での撮影や、回転させた画像を使用してアノテーションを行い、1枚の画像から数枚のア

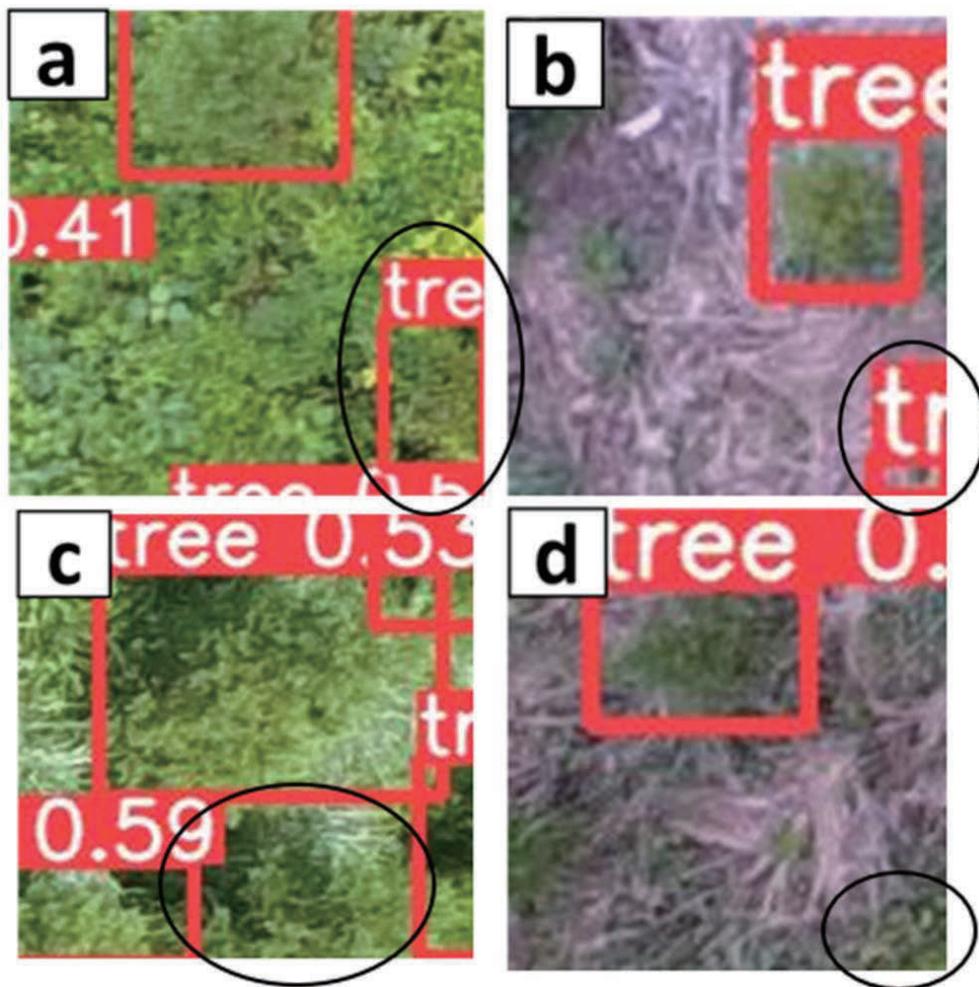


図-2. 実験 (a) における FP ((a), (b)) と FN ((c), (d)) の例
FP, FN となった領域をトリミングし、黒丸で囲い、拡大表示している。また、矩形で囲われている苗木にはそれぞれ信頼度スコアが表示されている。

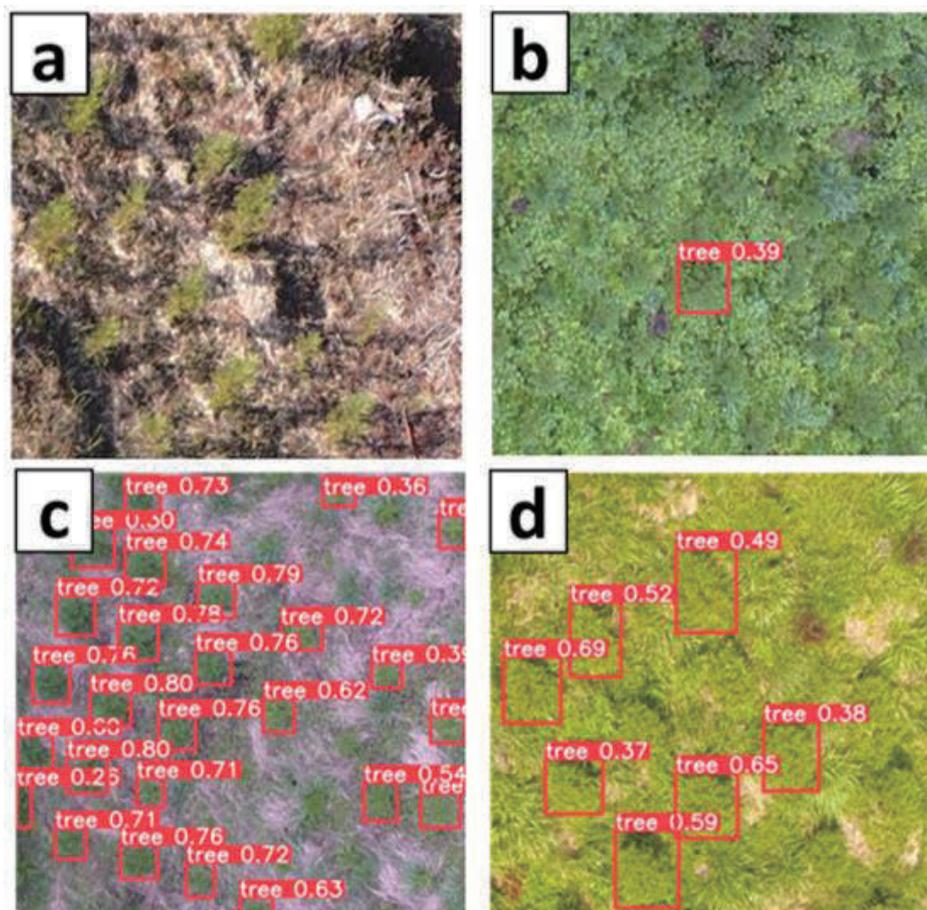


図-3. 霧島の画像および高限の苗木検出例
 a: 霧島 (12月撮影), b: 高限 106 林班 36 ア-1 小班, c: 高限 108 林班 5 小班, d: 高限 108 林班 43 小班
 矩形で囲われている苗木にはそれぞれ信頼度スコアが表示されている。

ノテーションデータを作成してデータを拡充させることが今後の課題である。一方で、アノテーションは人間が行う必要があり、時間を要する作業であるために、少ないデータ量であっても高精度で苗木を検出できる学習モデルを作成することもまた重要な課題であると考ええる。

引用文献

- Fromm M *et al.* (2019) *Remote Sensing* 11 (21) : 2585
 花岡創 (2021) *日林誌* 103 : 372 - 377
 Jocher G (2020) *ultralytics/yolov5* URL: <https://github.com/ultralytics/yolov5> (2023年11月4日利用)
 神原章博ほか (2021) *森林誌* 36 (1) : 5 - 12
 間下以大 (2018) *映像メディア学会誌* 72 (2) : 236 - 240
 松下通也 (2022) *森林遺伝育種* 11 : 172 - 175
 美濃羽靖・中司駿 (2022) *森林計画誌* 56 (1) : 13 - 23
 宮本崇 (2020) *AI・データサイエンス論文集 1 (J1)* : 270 - 277
 中川太人ほか (2021) *森林計画誌* 55 (1) : 35 - 38
 岡谷貴之 (2015) *日本ロボット学会誌* 33 (2) : 92 - 96
 Pearse G *et al.* (2020) *ISPRS Journal of Photogrammetry and Remote Sensing* 168 : 156 - 169
 Raschka S and Mirjalili V (2018) 第3版 Python 機械学習プログラミング達人データサイエンティストによる理論と実践, 福島真太郎監訳, 447 - 448 pp, インプレス, 東京
 Redmon J *et al.* (2016) *IEEE Conference on Computer Vision and Pattern Recognition*: 779 - 788
 林野庁 (2021) *森林・林業基本計画*, 5 pp, URL: [index-10.pdf](http://index-10.maff.go.jp/) (maff.go.jp), (2023年11月3日利用)
 林野庁 (2023) *令和5年版森林・林業白書*, 38 pp, 全国林業改良普及協会, 東京
 Tzutalin (2015) *HumanSignal/labelImg* URL: <https://github.com/HumanSignal/labelImg> (2023年11月4日利用)
 内田祐介・山下隆義 (2019) *電子情報通信学会誌 D* 102 (3) : 203 - 225
 Yu K *et al.* (2022) *Remote Sensing* 14 (2) : 295
 (2023年11月10日受付; 2024年1月15日受理)