

令和7年度

再造林の推進に向けた伐採状況の  
把握手法等に関する調査委託事業

報 告 書

令和8年3月

**林野庁**



# 目次

1. 要約.....	1
1.1.衛星画像等のリモートセンシング技術を活用した推定手法の精緻化.....	1
1.2.行政情報の集計等による推定手法との比較検証.....	3
1.3.衛星判読による推定と行政情報の比較検証.....	4
1.4.マニュアル等の整備.....	4
1.5.衛星画像等のリモートセンシング技術を活用した更新状況の把握に向けた検討..	5
1.6.検討委員会の開催.....	6
2. 背景と目的.....	7
3. 語句解説.....	8
4. 事業内容.....	10
4.1.衛星画像等のリモートセンシング技術を活用した推定手法の精緻化.....	10
① 令和6年度調査における衛星画像を利用した伐採面積推定に係る調査設計概要.....	10
②各データの対象期間の整理.....	12
③過去の伐採面積の推定（全国）.....	14
④FAMOST を活用した伐採面積の推定（全国）.....	20
⑤FAMOST を活用した伐採面積の推定（スギ人工林伐採重点区域）.....	49
⑥都道府県別の伐採面積推定に向けた検討.....	54
⑦A I 技術等活用による推定の省力化に向けた検討.....	61
4.2.行政情報の集計等による推定手法との比較検証.....	73
①伐採造林届出等の行政情報に基づく推計.....	73
②木材供給量からの換算による推計.....	74
4.3.衛星判読による推定と行政情報の比較検証.....	77
①年次推移の全体像.....	77
4.4.マニュアル等の整備.....	82

①目視判読マニュアルの作成.....	82
②FAMOST 活用マニュアルの作成 .....	82
4.5.衛星画像等のリモートセンシング技術を活用した更新状況の把握に向けた検討	83
①検討方法 .....	83
②結果 .....	88
5.  まとめと課題 .....	97
5.1.過去の伐採面積の推定（全国） .....	97
5.2.FAMOST を活用した伐採面積の推定（全国） .....	97
5.3.FAMOST を活用した伐採面積の推定（スギ人工林伐採重点区域） .....	98
5.4.行政情報の集計等による推定手法との比較検証.....	98
5.5. A I 技術等活用による推定の省力化に向けた検討.....	99
5.6.衛星画像等のリモートセンシング技術を活用した更新状況の把握に向けた検討 .....	100
6.  巻末資料 .....	102
6.1.報告書付属資料.....	102
6.2.目視判読マニュアル .....	109
6.3.FAMOST 活用マニュアル.....	135
6.4.検討委員  議事録の要約 .....	161
6.5. ..第 1 回 .....	161
6.6. ..第 2 回 .....	165

## 1. 要約

### 1.1. 衛星画像等のリモートセンシング技術を活用した推定手法の精緻化

#### ① 過去の伐採面積の推定（全国）

Landsat 時系列マップを活用し、平成 29（2017）年から令和 2（2020）年までの各年の伐採面積について層化無作為抽出法により推定し、および伐採年毎に 95%信頼区間を算定した。サンプル数の決定方法、判読方法、伐採面積の算出方法は令和 6 年度調査にて設計した方法を踏襲した。

伐採マップの目視判読については、95%信頼区間を各年の伐採推定面積の±10%程度とするため、サンプルプロット数を約 3 万点とし、目視判読の誤差を低減するため、3 名以上で判読した。

伐採面積の推定値は、平成 29（2017）年 41,529ha、平成 30（2018）年 53,059ha、令和元年（2019）年 56,683ha、令和 2 年（2020）年 50,942ha で、95%信頼区間の伐採面積に対する比率は 12.3%～14.2%であった。

#### ② FAMOST を活用した伐採面積の推定（全国）

FAMOST による伐採抽出設定を改良した FAMOST 改により作成した伐採マップ（以下、「Sentinel-2 簡易マップ改」という。）を作成し、①と同様の層化無作為抽出法と目視判読により年次伐採面積を推定した。

Sentinel-2 簡易マップ改の作成では、推定精度の向上を図るため伐採見逃しを減らすことを目指し、閾値の調整を実施した。まず現行版 FAMOST で使用している指標の閾値調整を行ったが、誤検出が増加する結果となった。次いで、Landsat 時系列伐採マップで使用されていた指標のうち 4 つの指標を導入し閾値調整を行ったが、大幅な改善には至らなかったため、さらに 4 つのフィルタリング処理をし、伐採検出箇所を維持しつつ誤検出を減らす検討を行った。

この検討の結果を踏まえ伐採マップを作成し、①と同じ手順で伐採面積を推定した。令和 5（2023）年の伐採面積は 49,969ha、令和 6（2024）年は 48,454ha で、95%信頼区間の伐採面積に対する比率は 10%程度であった。

#### ③ FAMOST を活用した伐採面積の推定（スギ人工林伐採重点区域）

「スギ人工林伐採重点区域」を対象に、令和 5（2023）年及び令和 6（2024）年の伐採面積を推定した。伐採マップとして使用したのは②で作成した Sentinel-2 簡易マップ改、対象エリアは林野庁提供の都道府県から収集されたスギ人工林伐採重点区域の GIS ポリゴンのうち民有林である。①、②同様の手順で伐採面積を推定した。

推定された伐採面積は令和 5（2023）年が 6,733 ha、令和 6（2024）年が 7,362 ha で、信頼区間の伐採面積に対する比率は 10%程度であった。

#### ④ 都道府県別の伐採面積推定に向けた検討

昨年度の検討では、都道府県別の民有林伐採面積を推定する際の必要サンプル数が、①民有林面積、②伐採面積割合、③誤差率設定、④分類精度（Producer's 精度・User's 精度）に強く依存することが確認された。特に、伐採面積の 10%に相当する 95%信頼区間を達成しようとする、伐採面積割合の小さい都道府県では必要サンプル数が急増することが明らかとなった。このことは、全国一律に相対誤差を設定した場合、小規模県に過大な作業負担が生じ得ることを示している。

そこで本年度は、精度設定を「相対誤差（±%）」および「絶対誤差（±ha）」の両面から整理し、伐採規模を踏まえた合理的な都道府県のサンプル数設定方法を検討した。

まず、相対誤差を 10～25%に変化させた場合の必要サンプル数を算出した。その結果、相対誤差を小さくするほど必要サンプル数は増加し、特に±10%付近で急増する傾向が確認された。また、同じ誤差率でも、伐採面積が小さい県では許容される誤差面積が小さくなるため、必要サンプル数が増加する構造が明らかとなった。

次に、絶対誤差を±200haに固定した場合を検討したところ、伐採面積の大きい県ほど相対誤差が小さくなり、より多くのサンプル数を要することが確認された。すなわち、相対誤差方式と絶対誤差方式は、都道府県規模によって有利・不利が逆転するトレードオフの関係にあることが明らかになった。

さらに、本事業で実施した約 30,000 点という実務上の制約を前提に、相対誤差±10%を第一目標として都道府県を整理した。その結果、±10%を達成可能な A グループ、30,000 点では±10%は困難だが実質誤差が 10～15%に収まる B グループ、15%を超える C グループに分類された。

以上より、全国一律の精度設定ではなく、相対誤差±10%を基本としつつ、達成困難な都道府県については 30,000 点制約下で実現可能な誤差水準に基づき段階的に整理する方法が、統計的妥当性と実務的実行可能性を両立する合理的な設計であると考えられた。

#### ⑤ AI 技術等活用による推定の省力化に向けた検討

本検討は、伐採マップの作成およびサンプル地点の目視判読に要する作業時間の削減を目的として、衛星画像の時系列情報と機械学習（AI）による分類手法の適用可能性を整理したものである。対象データは、全国一律の条件で取得可能な衛星観測データ（Landsat、Sentinel-2）とし、平成 28（2016）年及び令和元（2019）年から令和 4（2022）年を対象期間

として、NDVI（正規化植生指数）およびNBR（正規化燃焼比）<sup>1</sup>の月次時系列データを、1ピクセル点単位で整備した。

分類手法としては、(1) 教師なし学習である LSTM Autoencoder を用いた異常検知的アプローチ、(2) 教師あり学習である次元畳み込みニューラルネットワーク（1D CNN）による二値分類（森林／その他）を試行した。

LSTM Autoencoder（教師なし）では、実運用に耐えうる精度を得られなかった。一方、1D CNN では、NDVI よりも NBR を用いた場合に高い判別性能が確認された。検証データ 15,492 地点に対し、全体精度を重視した閾値設定では、森林を 97.1%の確度で判定可能であった。さらに、User's 精度（森林と判定した結果の確からしさ）を重視した閾値設定では、森林サイト 13,986 地点のうち 1,700 地点を、誤判定なし（確度 100%）で森林として自動検出した。以上より、目的に応じて判定閾値を調整することで、判別精度と検出件数のバランスを柔軟に制御できる可能性が示された。

今後は、教師データの品質管理（判読が困難な地点の除外等）を徹底し、時系列情報に加えて周辺のテクスチャ等の空間情報を取り込む二次元 CNN（2D CNN）などへ拡張することで、さらなる森林検出精度向上を図ることが望ましい。

## 1.2. 行政情報の集計等による推定手法との比較検証

伐採面積の推定方法のうち、従来から用いられている行政情報等を用いた民有林の伐採面積を推定する以下 2 通りの方法について整理する。

- (ア) 行政手続の積み上げによる推定
- (イ) 木材供給量からの推定

### ① 行政手続の積み上げによる推定

林野庁がとりまとめた伐採造林届出等の行政情報の積み上げによる平成 28（2016）年度から令和 5（2023）年度までの推計結果は、期間を通して概ね 50,000～55,000ha の値で推移している。

### ② 木材供給量からの推定

森林・林業統計要覧にて公表されている、平成 28（2016）年度～令和 5（2023）年度の民有林における立木伐採面積は、概ね 70,000～90,000ha の間で推移しており、行政手続の積み上げベースの推計値に比べ、20,000 ha程度大きく推計されている。

---

<sup>1</sup> Normalized Burn Ratio。焼失・伐採等の変化検出に用いられる指標。近赤外と短波赤外（SWIR2）を用いる。

令和 6 年度調査にて検討したとおり、材積を面積に割り戻すための換算係数を森林生態系多様性基礎調査 (NFI) のデータを用いて見直したところ、50,000~60,000 ha と推計され、行政手続きベースの推計値や衛星判読による推定値と同程度か、やや大きい傾向となった。

### 1.3. 衛星判読による推定と行政情報の比較検証

本節では、平成 29 (2017) 年から令和 6 (2024) 年までの主伐面積について、行政手続きベース、木材供給量ベース、衛星画像による推定値 (令和 6+7 事業成果)、および GLAD が提供する森林被覆減少データを比較検証した。

全体として、行政手続きベースは比較的安定した推移を示し、木材供給量ベース (NFI 換算) は概ね上昇傾向を示す。一方、衛星推定値は年ごとの増減がやや大きい傾向が確認された。また、GLAD の森林被覆減少データは、アルゴリズムおよび処理体系が異なるにもかかわらず、衛星推定値と概ね同方向の年次変動を示しており、衛星観測に基づく変動には一定の実態が反映されている可能性がある。

行政手続きベースと衛星推定値の間には、年次変動の位相差が観察される。衛星推定は概ね 11 月~翌年 10 月、行政手続きベースは 4 月~翌年 3 月を対象としており、特に伐採が集中する冬季 (1~3 月) の年次配分が異なる。この結果、同一の冬季伐採が行政では前年度、衛星では翌年度に計上される構造となり、衛星推定値は行政手続きベースに対して 1 年遅れて変動しているように観察された。

特徴的な年として、平成 29 (2017) 年は衛星推定値が低位に推定されているが、Sentinel-2 運用初期にあたり観測条件が十分でなかったことから、画像制約に起因する精度低下の影響が考えられる。

また、令和 3 (2021) 年はウッドショック期に該当し、原木価格は令和 3 (2021) 年 4 月以降急騰し令和 4 (2022) 年 3 月まで高値が継続した。価格上昇期にあたる令和 4 (2022) 年 1~3 月の伐採は、行政手続きベースでは令和 3 (2021) 年に、衛星推定では令和 4 (2022) 年に計上される構造となる。このため、令和 3 (2021) 年における両者の差は、年次配分の違いに加え、価格急騰期の伐採動向が異なる年次に反映された可能性を含んでいる。ただし、ウッドショックのような急激な価格変動は例外的事象であり、通常価格変動範囲では年次配分の違いは長期的に相殺されると考えられる。

以上より、衛星推定値は行政手続きベースよりも年変動が大きい、GLAD データとも整合的な変動傾向を示している。衛星推定値と行政値を比較する場合、単年度の一致のみを基準とするのではなく、年度区切りや観測期間の違いを踏まえた上で、複数年のトレンド比較として評価することが適切であると考えられる。

### 1.4. マニュアル等の整備

本節では 2 つのマニュアルを整備した。

#### ① 目視判読マニュアル

層化抽出法による伐採面積推定のために必要となる目視判読を行う際、判読者の違いによる誤差は、伐採面積の推定精度への影響が大きいことから、判読する際の留意事項や、判読が難しい場合の対処方法等について整理したマニュアルを作成した。

## ② FAMOST 活用マニュアル

FAMOST について、個々の技術者が自ら衛星画像の分析等が可能なオープンプラットフォーム上でも運用できるよう、プログラムのソースコード及び運用手順を整理したマニュアルを作成した。実行環境は Google Earth Engine である。

### 1.5. 衛星画像等のリモートセンシング技術を活用した更新状況の把握に向けた検討

本検討は、衛星画像等のリモートセンシング技術を活用して、伐採跡地における「更新(再造林・自然回復等)の進捗状況」を広域かつ効率的に把握するための手法について、試行結果を整理したものである。検討では、(1) Landsat (30m) による冬季 NDVI の時系列から回復指標 (RI: Recovery Indicator) を算出し、(2) 航空機 LiDAR (DCHM) から得られる樹高分布を参照データとして、RI から樹高クラス ( $\leq 1\text{m}$  (未回復相当)、 $1\text{--}5\text{m}$  (回復途中相当)、 $>5\text{m}$  (回復相当)) を推定できるかを評価した。混同行列は rows=Reference (樹高)、cols=Predicted (RI<sup>2</sup>) として整理し、User's 精度 (予測クラスの精度) および Producer's 精度 (参照クラスの再現率) を算出した。

参照とする樹高指標について、まず、LiDAR データから得られる樹高分布が、伐採後に更新された樹木の成長のみを捉えられていると判断できる伐採跡地(サイト)を Google earth を用いて選別したうえで評価を行った(単独ピーク限定(最頻値樹高)、対象サイト数:150)。この結果、伐採後5年後の時点で樹高が1m未満(未回復相当)の箇所の検出精度は90%、伐採後10年後の時点で未回復相当の箇所の検出精度は100%だった。

次に、LiDAR データから得られる樹高分布が、サイト外周の立木やサイト内の残置森林を含めて捉えてしまっているサイトも含めて評価を行うため、パーセンタイルにより樹高分布からサイトの樹高を定めた上で、評価を行った(全サイト(パーセンタイル樹高)、対象サイト数:519)。この結果、第50パーセンタイル(中央値)での検出精度は、伐採後5年・10年とも低く、第80パーセンタイルとすると検出精度は見かけ上高まった。しかし、第50パーセンタイルではサイトの約7割が樹高1-5m(回復途中相当)に、第80パーセンタイルではサイトの約9割が樹高5m以上(回復相当)に分類されており、伐採後に更新された樹木の成長を的確に評価できていない可能性が高いと考えられた。これは、以下の影響が大きいと考えられる。

---

<sup>2</sup> 回復指標。伐採前基準値に対する回復度を0~1(超)で表す。

- エッジ影響：伐採地ポリゴンの端部に伐採されていない樹冠が混入し、樹高が実態より高く推定されることで、参照クラス（樹高）と RI による推定結果の対応が崩れ、分類精度が低下する場合があった。
- 土地利用転用の混在：伐採後に太陽光パネルや茶畑等へ転用された箇所が含まれると、植生回復（樹高）と RI の関係が単純でなくなり、分類精度が低下する場合があった。  
冬季 NDVI の時系列データから求めた RI による検出により、伐採後の更新された樹木の成長を評価できる可能性が示唆されたものの、検出精度の評価のために参照する LiDAR データの処理方法について、課題が残された。

## 1.6. 検討委員会の開催

委員 3 名、林野庁計画課、受託者及び林野庁計画課が指名する助言者で構成する調整委員会を対面・オンライン併用で開催し、業務の進捗管理及び方針を決定した。調整委員会の開催数は 2 回で、各委員会の開催日及び概要は下表のとおりである。

調整委員会	日時	概要
第 1 回	令和 7 年 11 月 28 日	作業・解析手法の説明と質疑応答、進捗の確認、一部結果の報告と質疑応答等
第 2 回	令和 8 年 3 月 3 日	結果報告と質疑応答、課題の整理

## 2. 背景と目的

我が国の森林資源が本格的な利用期を迎える中、人工林資源の循環利用の推進が重要であり、特に適正な伐採への誘導と適切な更新の確保が求められている。

こうした施策の検討や効果の検証のためには、伐採（主伐を指す。以下同じ。）や伐採後の更新の状況を的確に把握することが求められる。

これまで伐採面積の推定は、木材供給量の統計数値や、森林法に基づく伐採造林届等の行政情報を元に行われてきたが、木材供給量を元にした推計では複数の仮定をおいて算出するものであり、また、行政情報を元にした推計では行政手続と実際の伐採に時間差があり手続後不実行となる場合も一定数含まれるなど、いずれも実際に生じている伐採面積を的確に捉えられているかの判断が困難という課題がある。

また、伐採後は公益的機能の発揮の観点から確実な更新が求められるが、人的制約等により更新状況の確認が必ずしも十分に行われていない場合が多く、より効率的に更新状況を把握することも課題となっている。

このような中、近年、衛星画像等のリモートセンシング技術の普及が進んできており、こうした技術を用いて伐採面積の推定等を行う学術研究成果も見られる。林野庁では、令和6年度再造林の推進に向けた伐採状況の把握手法等に関する調査委託事業（以下「令和6年度調査」という。）により、衛星画像を利用した層化無作為抽出法（抽出点に係る伐採・非伐採の目視判読を含む。以下同じ。）により全国及び地域（都道府県・スギ人工林伐採重点区域）の伐採面積を推定する手法の検討を行い、令和3（2021）年と令和4（2022）年の伐採面積の推定結果を含め、一定の成果を得たところである。しかしながら、2か年を超えてより長期間の伐採面積の推定の妥当性の検証が不足しているほか、推定に要する労力の観点から改善を検討すべき点が依然として存在している。

また、衛星画像等から伐採後の更新状況を把握することは、伐採状況の把握に比べ技術的課題が多く、把握手法の確立には課題整理が必要である。

本調査では、令和6年度調査の成果を踏まえ、衛星画像を利用した伐採面積推定手法について、妥当性・継続性の観点からさらに精査し、実装に向けた検討を行うとともに、

衛星画像等を利用した更新状況の把握について併せて検討を行うものである。

以下本報告書においては、事業の仕様書に示された事業内容、すなわち（1）衛星画像等のリモートセンシング技術を活用した推定手法の精緻化、（2）行政情報の集計等による推定手法との比較検証、（3）マニュアル等の整備、（4）衛星画像等のリモートセンシング技術を活用した更新状況の把握に向けた検討、（5）検討委員会の開催の順に沿ってそれぞれ成果を記述する。

### 3. 語句解説

本事業における語句の定義を表 1 に示す。

表 1 R7 年度伐採状況把握手法等調査委託事業における語句の定義（順不同）

○ 本事業固有の用語	
伐採 <sup>3</sup>	本報告書での伐採とは主伐を指すこととし、間伐・除伐等の主伐ではない伐採は調査対象としない。主伐は皆伐と択伐に分けられる。立木が実際に伐採された区域の面積を伐採面積と表し、伐採後の土地利用が森林かどうかは問わない。
FAMOST	林野庁が開発した森林変化点抽出プログラムの呼称。林野庁ホームページ令和 4 年度伐採造林届出制度の効果的な運用に向けたリモートセンシング技術の活用促進に関する調査事業報告書参照 ( <a href="https://www.rinya.maff.go.jp/j/keikaku/shinrinsettou.mudanbassai_bousi.html">https://www.rinya.maff.go.jp/j/keikaku/shinrinsettou.mudanbassai_bousi.html</a> )
伐採マップ	伐採が行われたと考えられる箇所を、2 時期以上の衛星画像を機械学習等による差分解析により抽出することで作成したラスターデータ（マップ）の総称
層化マップ	サンプル抽出による目視判読の効率化を図るため、伐採マップを元に、伐採・非伐採・バッファなどに分類（層化）したマップの総称。
Landsat 時系列マップ	Shimizu and Saito (2021) <sup>4</sup> が Landsat 衛星画像から作成した伐採マップのことを指す、本事業における呼称 ( <a href="https://zenodo.org/records/17221149">https://zenodo.org/records/17221149</a> )
Sentinel 簡易マップ	FAMOST を活用し Sentinel-2 衛星画像から作成した伐採マップのことを指す、本事業における呼称

<sup>3</sup> 令和 6 年度調査報告書より抜粋

<sup>4</sup> Shimizu, K. and Saito, H., 2021, Country-wide mapping of harvest areas and post-harvest forest recovery using Landsat time series data in Japan, Int'l J. Applied Earth Observation and Geoinformation, Vol 104, <https://doi.org/10.1016/j.jag.2021.102555>

○ 統計処理用語	
層化無作為抽出法	<p>統計的に精度評価のために標本（サンプル）を抽出する手法のひとつで、層化マップの分類毎に、目視判読地点を抽出する点数（サンプル数）を割り当て、各分類内で無作為に抽出する方法。</p> <p>この際、伐採発生割合が低い（0.2%程度）伐採層に集中してサンプル点を割り当てることで、層化に寄らず均等に無作為抽出する場合に比べ、少ないサンプル点数で、精度良く推定することが可能で、衛星画像解析で広く用いられる。</p>
信頼区間	<p>標本から求めた推定値の確実性を表す。95%信頼区間は、同じ方法で標本抽出を繰り返したとき 100 回のうち 95 回程度は真の値を含む範囲を表す。本報告書では、信頼区間は標準誤差から計算し、標準誤差は分散から計算するため、これらを相互的に利用する場合がある。</p>
User's 精度	<p>分類結果のうち、ある区分に分類されたものが、実際にもその区分である割合（分類結果の正解率）を示す指標で、地図やデータを「利用する側（ユーザー）」の立場から見たときの信頼性を表す。</p> <p>例えば、あるプロットが「伐採」と判定された場合に、その場所が実際に伐採されている確率を示す。</p> <p>この精度が低い場合、他の区分が誤って分類されている可能性が高いことを意味する。</p>
Producer's 精度	<p>実際にある区分に属しているもののうち、正しくその区分に分類された割合（見落とさず分類した率）を示す指標で、データを「作成する側（プロデューサー）」の立場から見たときの再現性を表す。</p> <p>例えば、実際に伐採されたプロットのうち、どの程度が「伐採」と正しく判定されたかを示す。</p> <p>この精度が低い場合、本来その区分に分類されるべきものが他区分に分類されている（見落としている）可能性が高いことを意味する。</p>

## 4. 事業内容

### 4.1. 衛星画像等のリモートセンシング技術を活用した推定手法の精緻化

#### ① 令和6年度調査における衛星画像を利用した伐採面積推定に係る調査設計概要

全国民有林およびスギ重点地区における衛星画像を使った伐採面積の推定では、令和6年度事業「再造林の推進に向けた伐採状況の把握手法等に関する調査委託事業」（以下令和6年度調査）において、令和3年（2021）年および令和4年（2022）年の伐採面積を推定する際に設計・実行された層化無作為抽出法を基本的に踏襲した。以下令和6年度の調査設計の概略を述べる（詳細は令和6年度調査の報告書を参照）。

##### i. 伐採面積推定の基本的な考え方

衛星画像から作成された伐採マップをサンプル抽出の効率化を図るための分類（層化）に利用し、分類毎に抽出した地点を目視判読により伐採・非伐採に分類した結果を用いて、対象全域の伐採面積を統計的に推定する方法を適用した。

##### ii. 伐採マップと層化マップの作成

令和3（2021）年および令和4（2022）年の伐採面積推定における目視判読点のサンプル抽出では、層化に用いる伐採マップとして、Landsat 時系列マップ（1985-2022）が使用された。なお、推定の空間単位（10m）に合わせるため、当該マップは10m解像度に変換（1画素（以下画素をピクセルと呼ぶ）：10m×10m）して用いられた。

層化の分類は、1. 変化なし、2. 伐採、3. バッファ（伐採箇所周囲の1ピクセル）の3層である。バッファ層は、機械抽出により変化なしと判断されたものの、実際には伐採されている誤分類の発生割合が高いと考えられる。バッファ層を設定することで、伐採面積推定の95%信頼区間の幅を小さくし、目視判読が必要なサンプル点数を減らすことが期待できる。

##### iii. 目視判読点の抽出（層化無作為抽出）

全国推定のサンプル数は、95%信頼区間の幅を伐採面積の概ね±10%程度に抑えることを目標に、民有林の伐採面積割合を仮定した上でサンプル点数を31,000点程度とし、想定される伐採発生割合を元に、伐採・バッファ層に多く配分して抽出された（令和3（2021）年および令和4（2022）年の場合、変化なし約27,815点、伐採約2,050点、バッファ約1,135点）。なお、層化によらない単純無作為法を用いると、同じ信頼区間幅の精度で推定するには235万点抽出する必要があるため、目視判読の省力化効果は極めて大きい。

#### iv. 抽出点の目視判読

抽出した各サンプル点について、衛星画像等を参照し伐採の有無および伐採年を目視にて判読する。判読するために参照する情報には、Google Earth Engine 等を用いて整備した Sentinel-2 衛星画像を年次毎に合成（5～9 月、雲被覆率 70%以下の画像から中央値合成）した画像、対象期間における NDVI<sup>5</sup>の推移のグラフを用い、特に伐採の可能性がある場合には、Google Earth で公開されている高解像度衛星画像も参照して判定された（p.16 図 4 参照）。

判読結果は、一度複数の区分（クラス）を設けて整理した上で、最終的に伐採・非伐採の 2 区分に集約された。伐採区分には主伐を対象とすることを前提に、主に北海道で見られる幅広の帯状択伐地や、開発による伐採も含むとされた。非伐採区分には一般的な間伐や、人為に寄らない自然災害による崩壊地や風倒等が含まれる。

目視判読に伴う誤差（判読者間のばらつきやデータ入力ミス）を減らすため、複数判読者による判読を基本とし、多数決により伐採/非伐採が決定された。令和 6 年度の設計では、31,000 点のサンプルに対して主に 3 名で判読がなされた。

#### v. 推定値の算出

層毎の目視判読結果から伐採発生割合を算出し、森林面積に乗ずることで各層における伐採面積を算出する。例えば、伐採層の森林面積が 1,000ha で、当該層のサンプルのうち 0.03%が伐採であれば、伐採層からの寄与は約 3ha となる。

令和 3（2021）・令和 4（2022）年の伐採面積推定では、伐採マップを年別に作成して抽出・判読を行わず、2 年分をまとめた統合伐採マップを基に抽出・判読されている。ここから各年の伐採面積を推定するには、目視判読の際にいずれの年に伐採されたかを記録し、推定対象年に伐採された抽出点から伐採割合を算出することで求めている。サンプル点の大半を占める 2 年間通じて非伐採と判読される点を共有できる利点があるが、判読に時間がかかる伐採と判読されたサンプル点は各年判読する必要があるため、省力化効果は限定的だった。

#### vi. 推定結果

令和 6 年度の検証では、上述の設計で令和 3（2021）・令和 4（2022）年および令和 6（2024）年の全国民有林伐採面積が推定され、95%信頼区間の相対幅は概ね 1 割強となった。さらに、1 名のみ判読では判読誤差の影響が大きい一方、3 名以上で同一地点を判読することで判読誤差の影響を低減できることが示された。

---

<sup>5</sup> Normalized Difference Vegetation Index。植生の活性度を示す指標。近赤外と赤の反射を用いる。

なお、令和 6(2024)年<sup>6</sup>の伐採面積推定では、林野庁事業で開発されたプログラム FAMOST を活用した伐採マップが使用され、予算等の都合により判読者 1 名での判読結果が用いられた。

## ② 各データの対象期間の整理

伐採面積推定の対象期間は、図 1 に示したように衛星画像を用いた手法と行政情報の集計等による手法で差異がある。基本的に、衛星画像による推定では展葉期の合成画像の差分解析によるもので、概ね前年 11 月～当年 10 月までの期間の推定とならざるを得ない。一方、行政データは年度で集計、木材供給量は年次での集計である。このため、例えば令和 3 (2021) 年 11 月・12 月に伐採があった場合、衛星画像での推定では令和 4 (2022) 年の伐採に計上され、年次や年度の推計と対象期間に相違が生じることから、比較する際には留意が必要である。

---

<sup>6</sup> 令和 6 年度調査では、令和 5 (2023) 年の推計値として扱ったが、本事業で定義を見直し、令和 6 (2024) 年として取り扱うこととした (図 1 参照)

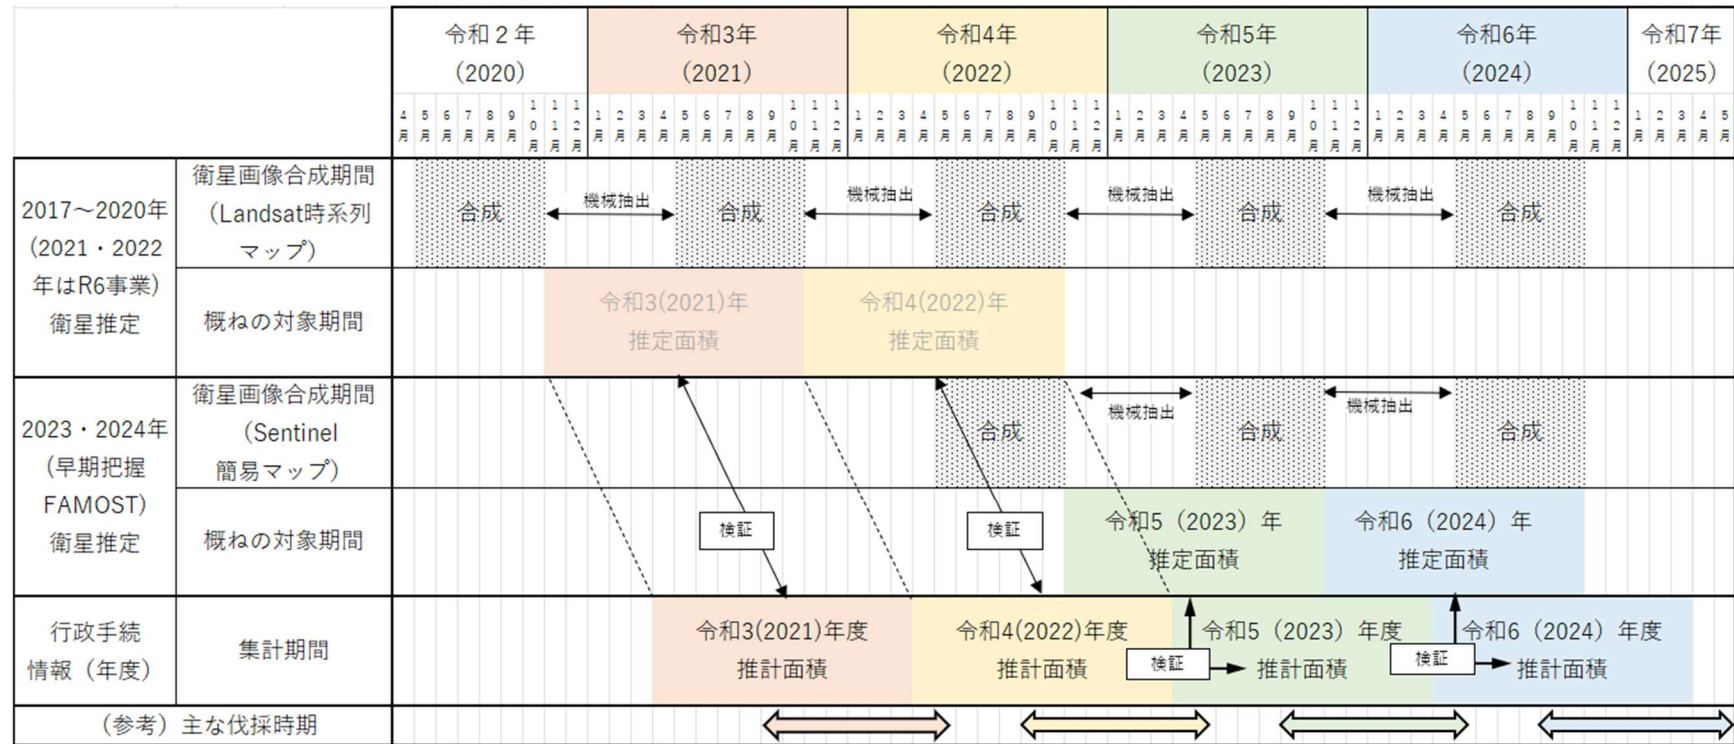



図1 伐採面積把握推定の対象期間  
(令和3(2021)～令和6(2024)年の伐採面積推定の期間を例として示す)

### ③ 過去の伐採面積の推定（全国）

全国の民有林を対象として平成 29（2017）年から令和 2（2020）年までの各年の伐採（主伐）面積を上述の令和 6 年度調査で設計された方法を用いて推定した。

層化に用いた伐採マップは、Landsat 時系列マップ（1985-2023）<sup>7</sup>で、推定対象とする平成 29（2017）-令和 2（2020）年における、伐採・非伐採の機械判読結果を 1 つに統合したものである。この伐採マップを 10m 解像度に変換（1 ピクセル：10m×10m）したうえで、民有林内で層化マップを作成した（図 2）。



- 2017-2020 年伐採
- 伐採箇所周囲 1 ピクセル（バッファ）
- 民有林で変化なし
- 民有林以外

図 2 Landsat 時系列マップから作成の層化マップの拡大図（約 8km 四方）

---

7 Shimizu, Katsuto and Saito, Hideki, Published September 29, 2025 | Version 1.3, Dataset: Country-wide mapping of harvest areas and post-harvest forest recovery using Landsat time series data in Japan, <https://zenodo.org/records/17221149>

層の区分は、1. 変化なし（非伐採層）、2. 平成 29（2017）-令和 2（2020）年のいずれかで伐採とされたピクセル（伐採層）、3. 伐採エリア周囲 1 ピクセルを空間的バッファとして設定したピクセル（バッファ層）の 3 層である。

全国推定するために必要な目視判読点サンプル数は、各年の 95%信頼区間を推定伐採面積の概ね±10%程度に抑えることを目標とし、令和 6 年度調査の設計に倣い約 3 万点（ $n=31,000$ ）とした。想定される伐採発生割合と、層別の面積割合に応じてサンプル数を配分し、各層内で無作為抽出を実施した（表 2）。抽出したサンプル地点の位置を図 3 に示す。なお、抽出した 31,000 点のうち 5 点は目視判読時に参照が必要な Sentinel-2 画像が取得できなかったため、判読・推定に用いた有効サンプルは 30,995 点である。



図 3 平成 29（2017）～令和 2（2020）年判読用に抽出したサンプル（ $n=31,000$ ）の位置（黒点）

なお、4年間の伐採面積を推定する場合、年次毎に3万点サンプルを抽出（4年間で12万点）判読する必要があるところ、4年間分の伐採マップを元に共通のサンプル地点数を用いることで目視判読の省力化を図った。これにより、今回抽出した30,955点の判読により4年間分の目視判読が一括で実施となり、特に判読が容易であるものの点数の多い、1. 非伐採層の判読は省力化が図られたが、点数が少ないものの判読時間の大半を占める、2. 伐採層、3. バッファ層の判読作業は、年次毎に判読する場合と同じ労力が必要であることから、判読作業全体への省力化の効果は限定的であった。

目視判読では、抽出した各サンプル要素について、判読用データセット（Sentinel-2の年次合成画像およびNDVI時系列推移グラフ、Google Earthで公開されている高解像度衛星画像のセット。図4に例示する。）を参照し平成29（2017）～令和2（2020）年の各年の伐採の有無を判定した。

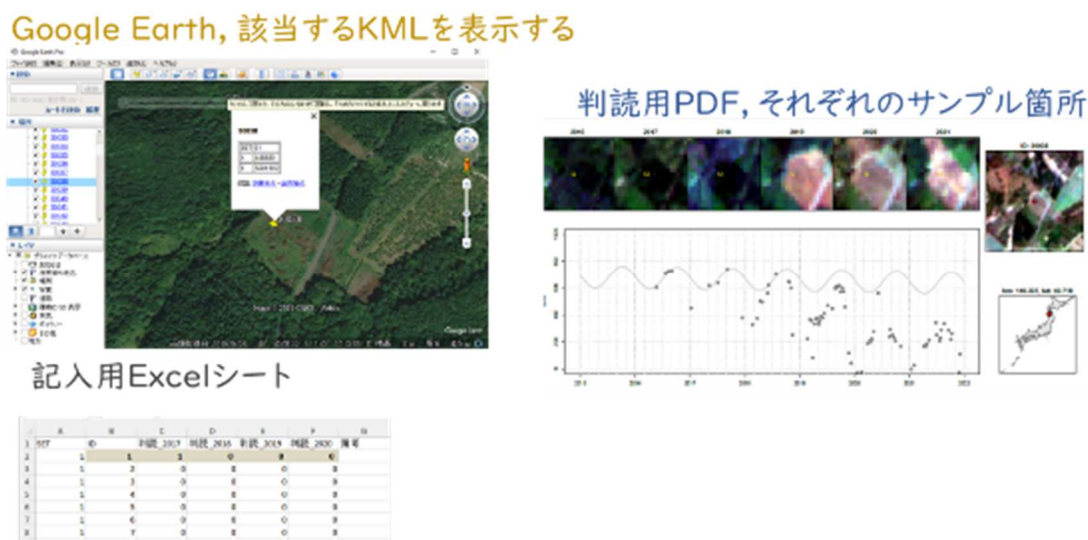


図 4 判読用データセットの例

目視判読結果は表3に示すとおり、1. 非伐採、2. 伐採、3. 判読不能の3区分（クラス）である。伐採クラスの定義は基本的に主伐地（皆伐地、開発地等）とし、北海道等で見られる幅広の帯状択伐（0.1ha以上）も含めた。なお、間伐、崩壊地・風倒・森林火災等の自然攪乱、0.1ha未満の作業道開設等は非伐採クラスとして整理した。判読不能クラスは雲・陰などで地物が判断できないケースを整理したものである。

なお、目視判読に伴う誤差の低減を図るため、作業では3名で同一地点を判読し、多数決により伐採/非伐採を決定した。

表 2 民有林での平成 29 (2017) ~令和 2 (2020) 年伐採面積推定のための層化区分とサンプル数

層	マップ面積※(ha)	面積割合(%)	n**
民有林で変化なし (変化なし)	17,612,241	98.6	24,144
平成 29(2017)~令和 2(2020)年伐採 (伐採)	190,878	1.068	4,458
伐採箇所周囲 1 ピクセル (バッファ)	66,987	0.375	2,393

※マップ面積とは、伐採マップに占める各層のピクセルの面積を全て足し合わせたもの

※※平成 29 (2017) -令和 2 (2020) 年のサンプル 31000 点のうち、5 点は Sentinel-2 画像が無かったため、合計サンプル数は 30,995 である

表 3 目視判読結果の分類クラス表

クラス名	土地被覆の状況	例
1 非伐採	伐採以外の変化	間伐、崩壊地、風倒、森林火災、0.1ha 未満の作業道開設
	森林のまま変化なし	針葉樹、広葉樹、伐採跡地、樹冠被覆率 30%以上を目安とする
	森林以外のまま変化なし	裸地 (崩壊地含む)、農地、果樹園、河川、住宅、太陽光パネル、道路、樹冠被覆率 30%未満の笹地
2 伐採	皆伐地、開発地	人為的に木を切ったところ、林業的伐採箇所 0.1ha 以上の作業道開設、
	帯状択伐	伐採面積が 0.1 ha 以上の帯状伐採
3 判読不能	衛星画像に起因する判読不能地点	雲、陰、ハレーション

## ■ 結果

令和 6 年度調査報告書に示された推定式を使用して伐採面積を計算、また 95%信頼区間も計算した。層化マップの Producer's 精度と User's 精度を表 4、伐採面積推定の概要を表 5、および推定結果を表 6 に示す。伐採面積の推定値は、平成 29 (2017) 年 41,529ha、平成 30 (2018) 年 53,059ha、令和元年 (2019) 年 56,683ha、令和 2 (2020) 年 50,942ha で、95%信頼区間の伐採面積に対する比率は 12.3%~14.2%であった。年次の増減要因や行政情報との比較に関する考察は、4.3 衛星判読による推定と行政情報の比較検証の節で後述する。

表 4 層化マップの Producer's 精度と User's 精度

層	Producer's 精度	User's 精度
変化なし	0.994	0.997
2017-20 伐採	0.737	0.578

表 5 平成 29 (2017) ~令和 2 (2020) 年の推定伐採面積の概要

層化区分	変化なし		2017-2020 伐採				バッファ		層化マップ 面積合計				
	サンプル数	層化マップ面積	サンプル数	層化マップ面積	サンプル数	層化マップ面積							
	24, 114 点	1, 761.2 万ha	4, 458 点	19.1 万ha	2, 393 点	6.6 万ha	1, 786.9 万ha						
推定対象年	判読結果		平均 伐採 割合	推定 伐採面積	判読結果		平均 伐採 割合	推定 伐採面積	推定 伐採面積 合計				
平成 29(2017)年	伐採	15 点	0.0006	10, 942 ha	伐採	615 点	0.138	26, 332 ha	伐採	152 点	0.0635	4, 255 ha	41, 529 ha
	非伐採	24, 129 点			非伐採	3, 843 点			非伐採	2, 241 点			
平成 30(2018)年	伐採	19 点	0.0008	13, 860 ha	伐採	822 点	0.1844	35, 196 ha	伐採	143 点	0.0598	4, 003 ha	53, 059 ha
	非伐採	24, 125 点			非伐採	3, 636 点			非伐採	2, 250 点			
令和元(2019) 年	伐採	21 点	0.0009	15, 319 ha	伐採	868 点	0.1947	37, 165 ha	伐採	150 点	0.0627	4, 199 ha	56, 683 ha
	非伐採	24, 123 点			非伐採	3, 590 点			非伐採	2, 243 点			
令和 2 (2020)年	伐採	18 点	0.0007	13, 130 ha	伐採	787 点	0.1765	33, 697 ha	伐採	147 点	0.0614	4, 115 ha	50, 942 ha
	非伐採	24, 126 点			非伐採	3, 671 点			非伐採	2, 246 点			

各層化区分の推定伐採面積は、層化マップ面積×平均伐採割合による求められる。

表 6 平成 29 (2017) -令和 2 (2020) 年の信頼区間と伐採面積に対する比率

年	推定面積(ha)	95%信頼区間(ha)	伐採面積に対する比率
平成 29 (2017)	41,529	5,900	14.2%
平成 30 (2018)	53,059	6,628	12.5%
令和元 (2019)	56,683	6,945	12.3%
令和 2 (2020)	50,942	6,461	12.7%

## ■ 課題

平成 29 (2017) 年の推定伐採面積は 41,529ha であり、翌年の平成 30 (2018) 年の 53,059ha と比べて約 11,500ha 小さく、また、95%信頼区間の推定面積に対する比率が 14%と、他年（概ね 12%程度）より大きい結果となった。その原因として平成 29 (2017) 年は判読の際に参照する衛星画像の不足の制約により精度低下が考えられる。

目視判読の際に参照している Sentinel-2 は 2 機体制で運用されているが（Sentinel-2A は 2015 年 6 月、Sentinel-2B は 2017 年 3 月に打ち上げ）、撮影データの提供が安定化するまで、運用・整備に一定の期間を要する。このため、平成 30 (2018) 年以降では比較的確保しやすい一方、平成 29 (2017) 年は観測機会が相対的に少なく、さらに平成 29 (2017) 年の伐採の判読の際に比較する前年の平成 28 (2016) 年の比較画像は更に限られ、他の 3 年より制約が多かった。

年別の推定伐採面積の違いは、年変動の可能性もあるが、少なくとも平成 29 (2017) 年については判読材料の制約が推定の不確実性を増加させた可能性に留意する必要がある。

なお、判読に用いる画像は、色味や反射率の一貫性が高いプロダクト（例：Sentinel-2 Surface Reflectance Harmonized）の方が判読しやすい。しかし、本節の過去年次の推定では、平成 29 年 (2017) 年に限らず低いプロダクトレベルの画像が含まれていた影響により衛星画像の色調のばらつきが生じたため、伐採／非伐採の判別が難しい箇所が生じ、判読に要する時間も増加した。

Sentinel-2 画像に基づく平成 29 (2017) ～令和 2 (2020) 年の面積推定結果は、特に平成 29 (2017) 年について、判読材料の制約に起因する精度低下の可能性を踏まえて解釈する必要がある。このように、衛星自体の技術的課題や気象条件（特に雲量）により、衛星アーカイブの数が減少する期間や画像の質による判読材料の制約が大きい期間では推定精度が低下し得るため、対象期間のうち使用できた画像の頻度を出すなど、不確実性を示すことも今後の課題として挙げられる。

#### ④ FAMOST を活用した伐採面積の推定（全国）

全国の民有林を対象とし、令和 5（2023）年及び令和 6（2024）年の伐採（主伐）面積を推定した。前節の平成 29（2017）～令和 2（2020）年の面積推定では、公開されている Landsat 時系列マップを伐採マップとして使用したが、令和 6（2024）年のマップが公開されていないため、2 時点の差分変化から森林変化点を抽出するプログラム（以下 FAMOST）を活用した伐採マップを作成し推定することとした。FAMOST は林野庁の令和 3 年度「森林情報活用促進事業のうち無断伐採の把握体制の整備」および令和 4 年度「伐採造林届出制度の効果的な運用に向けたリモートセンシング技術の活用促進に関する調査事業」（以下 FAMOST 事業）で開発された、2 時期の Sentinel-2 衛星画像から伐採箇所を抽出するプログラムである。

令和 6 年度調査では、Landsat 時系列マップが公開されていない時点でも、当該年の伐採面積の推定を可能とすることを念頭に、FAMOST を用いて伐採マップを作成する手法が試行された。報告書では、FAMOST は誤検出を抑える設計のため User's 精度が高い一方、見逃しが多く Producer's 精度が相対的に低い点が課題として指摘された。層化無作為抽出法による推定において推定精度に与える影響は、User's 精度より Producer's 精度の方が大きいことが報告されており、見逃しを減らす（Producer's 精度の向上）よう FAMOST を設計し直す必要があるとした。

本年度はこの成果を踏まえ、FAMOST による伐採抽出設定を改良した伐採マップ（以下、Sentinel-2 簡易マップ改）を作成し、①と同様の層化無作為抽出法と目視判読により年次伐採面積を推定した。

##### i. FAMOST 改良による伐採マップ作成の概要

FAMOST は、期首（before）・期末（after）の衛星画像の合成画像から植生や湿潤指数、焼失指標等を算出し、その差分に閾値処理を適用して伐採候補ピクセルを抽出する設計である。抽出はピクセル単位で行い、必要に応じて最小面積条件等で伐採地から除去する。期首と期末の年別の合成画像は、複数の Sentinel-2 画像から雲・雲影等を除いたうえで、中央値を使い合成される。

FAMOST 伐採抽出の方法は以下のとおりである（図 5）。

- ✓ 期首と期末の Sentinel-2 画像を入手（1 年間に複数毎の画像が提供されているが、地域や季節により使用できる画像の枚数に差がある）
- ✓ 各画像につき 4 つの指標を計算
- ✓ 年ごとに中央値を抽出し合成画像を作成
- ✓ 期首・期末の差分画像を作成
- ✓ 4 つの指標の閾値を使い伐採マップを作成

Sentinel-2 簡易マップ改を元に、層化マップを作成したあとは、前節①過去の伐採面積の推定（全国）と同じ方法（目視判読用のサンプル数 31000 点）で伐採面積を推定した。

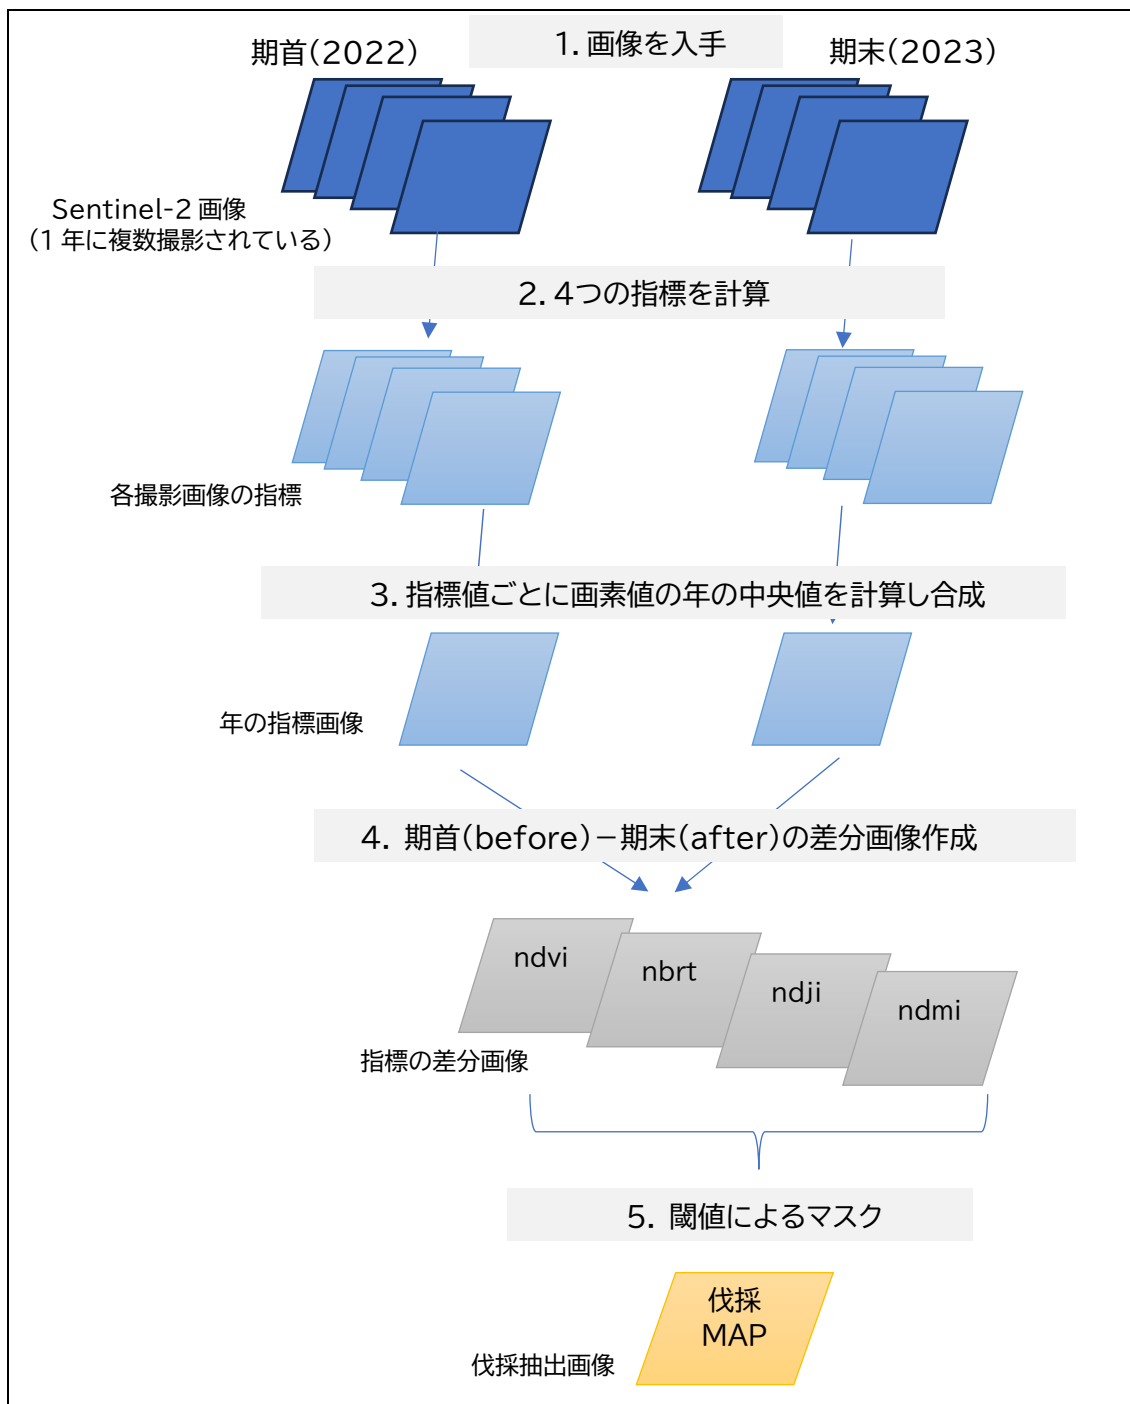


図 5 FAMOST による伐採地抽出の方法 (例 令和 5 (2023) 年の伐採マップ作成)

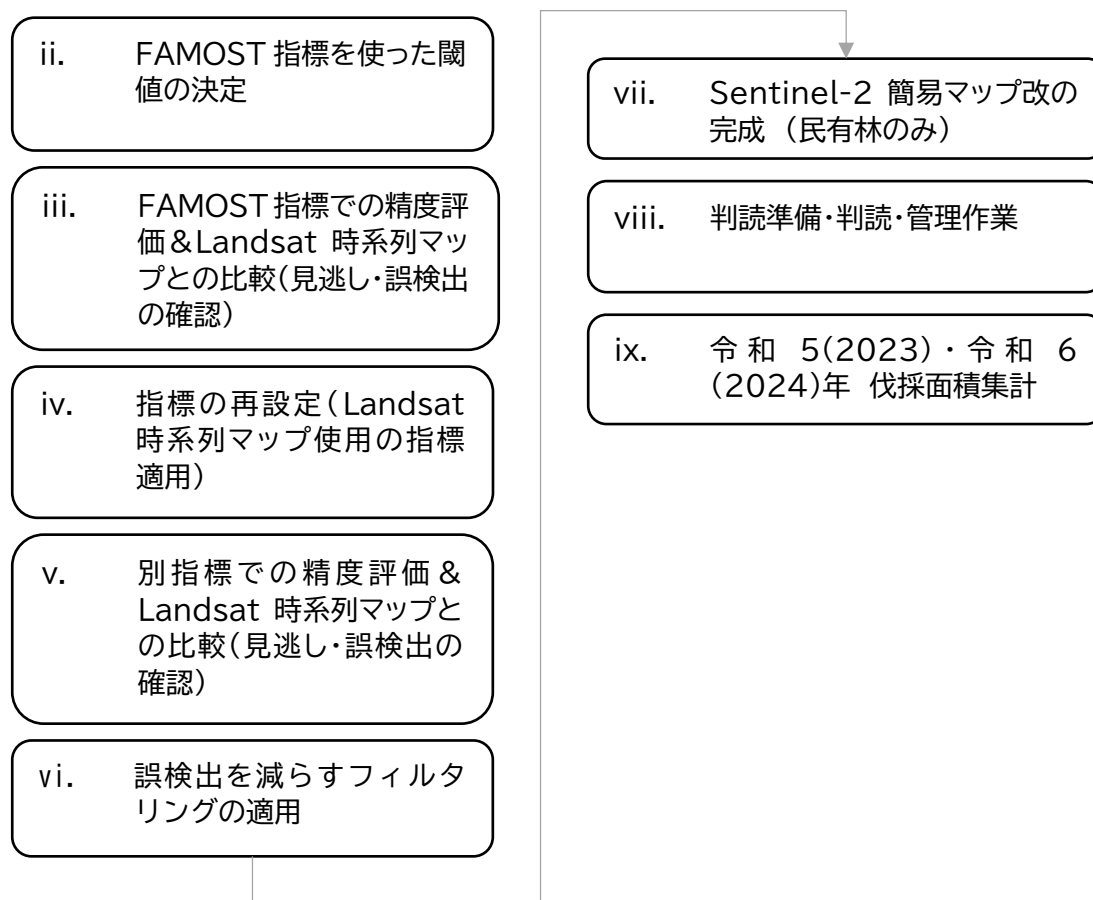


図 6 FAMOST 改良版伐採 MAP 作成から面積集計までの流れ

閾値の検討から面積推定までの作業の流れを図 6 に示す。図中のローマ数字で示した番号に沿って、以下説明する。

## ii. FAMOST 指標を使った閾値の決定

閾値の検討では、令和 6 年度調査で整理した全国の目視判読データ（令和 3（2021）年、令和 4（2022）年、令和 6（2024）年の目視判読結果）を教師データとして用い、ROC 分析により指標別の閾値候補を決定した。

現行版 FAMOST で使用されている以下の 4 つの指標について、期首と期末の差分値を計算して解析に用いた。

### 1. NDVI(正規化植生指数)

$$NDVI = \frac{NIR - R}{NIR + R}$$

## 2. NDMI(正規化湿潤指数)

$$NDMI = \frac{NIR - SWIR1}{NIR + SWIR1}$$

## 3. NDJI (日林協指数) <sup>8</sup>

$$NDJI = \frac{B+G-R}{B+G+R}$$

## 4. NBRT 変則 (正規化燃焼比熱の変則版) <sup>9</sup>

$$NBRT \text{ 変則} = \frac{NIR - 0.0001 \times SWIR1 \times SWIR2}{NIR + 0.0001 \times SWIR1 \times SWIR2}$$

B:青 Sentinel-2 の b2

G:緑 Sentinel-2 の b3

R:赤 Sentinel-2 の b4

NIR:近赤外 Sentinel-2 の b8

SWIR : 短波長赤外(SWIR1: Sentinel-2 の band11, SWIR2: Sentinel-2 の band12)

### ■ ROC(Receiver Operating Characteristic analysis)の指標を用いた閾値の検討

#### ROC (Receiver Operating Characteristic analysis)の概要


伐採地の抽出では、各指標 (NDVI、NDMI、NDJI、NBRT 変則) の期首・期末の差分値を「伐採が起きた可能性を表す値」として扱い、伐採／非伐採の2つに分類するために閾値を設定した。閾値は、「どの程度の変化を伐採とみなすか」という判定基準であり、厳しくすれば誤検出は減るが見逃しが増え、緩くすれば見逃しは減るが誤検出が増えるというバランスを左右する。

閾値の決定には、ROC を用いた。ROC は二つの種類に分類する際、予測モデルの良し悪しを目に見える形で評価する際に使われる。FAMOST での指標を使った伐採地抽出では、閾値を大きく (厳しく) すると伐採と判定される地点が減り、誤検出 (False Positive) は減りやすい一方、見逃し (False Negative) が増えやすい。逆に、閾値を小さく (緩く) すると見逃しは減りやすいが、誤検出が増えやすい (図 7)。

---

<sup>8</sup> 令和4年度「伐採造林届出制度の効果的な運用に向けたリモートセンシング技術の活用促進に関する調査事業」で経験的に作成された指標

<sup>9</sup> 本来は熱赤外バンドを有する衛星に適用。FAMOST 事業で熱赤外バンドを短波長赤外バンド(SWIR2)に割り当てて Sentinel-2 に適用



<https://www.tomomi-research.com/archives/2401>

閾値を高く設定：陽性予測は少なくなり真陽性率（TPR）も低くなる一方、偽陽性率（FPR）も低くなる  
 閾値を低く設定：陽性予測は増え真陽性率（TPR）も高くなる一方、偽陽性率（FPR）も高くなる

図 7 二つの種類の閾値の設定イメージ

この関係を定量的に評価するため、分類結果と判読データ（参照データ）を突合し、混同行列（TP、FP、FN、TN）を作成する。TP（True Positive）は「伐採を伐採と判定」、FP（False Positive）は「非伐採を伐採と判定（誤検出）」、FN（False Negative）は「伐採を非伐採と判定（見逃し）」、TN（True Negative）は「非伐採を非伐採と判定」である。混同行列から、真陽性率  $TPR = TP / (TP + FN)$ （感度・再現率）と、偽陽性率  $FPR = FP / (FP + TN)$ （誤検出率）を計算する（図 8）。

TPR と FPR は閾値により変化し、閾値を連続的に変化させた際の TPR と FPR の関係を可視化する際、ROC 曲線が用いられる。ROC 曲線は、閾値を連続的に変化させたときの座標上の点（FPR, TPR）を図示したものであり、左上（FPR が小さく、TPR が大きい）に近いほど、誤検出と見逃しの両方が小さいことを意味する（図 9）。ROC 曲線の下面積である AUC（Area Under Curve）は、特定の閾値に依存せずに伐採と非伐採を分離できる指標であり、一般に 0.5 付近はランダム、1 に近いほど判別が良いと解釈される。

		正解(参照データ)	
		Positive (伐採)	Negative (非伐採)
予測(分類結果)	Positive (伐採)	真陽性 <b>TP</b> の数	偽陽性 <b>FP</b> の数 誤検出
	Negative (非伐採)	偽陰性 <b>FN</b> の数 見逃し	真陰性 <b>TN</b> の数

$$\text{Precision} = \text{TP}/(\text{TP}+\text{FP})$$

衛星リモートセンシングの  
マップ精度における  
User's 精度側

$$\text{Recall} = \text{TP}/(\text{TP}+\text{FN})$$

衛星リモートセンシングのマップ精度における  
Producer's 精度側

TP(True Positive,真陽性)	実際に陽性を陽性と予測した件数
FN(False Negative,偽陰性)	実際に陽性を陰性と予測した件数(見逃し)
FP(False Positive, 偽陽性)	実際は陰性だが陽性と予測した件数(誤検出)
TN(True Negative, 真陰性)	実際に陰性を 陰性と予測した件数

Precision (適合率) =  $\text{TP}/(\text{TP}+\text{FP})$

Accuracy (正解率) =  $\text{True}/\text{all} = (\text{TP}+\text{TN})/(\text{TP}+\text{TN}+\text{FP}+\text{FN})$

特異度 =  $\text{TN}/(\text{FP}+\text{TN})$  陰性を誤検出しない割合

Recall (真陽性率)  $\text{TPR} = \text{TP}/(\text{TP}+\text{FN})$

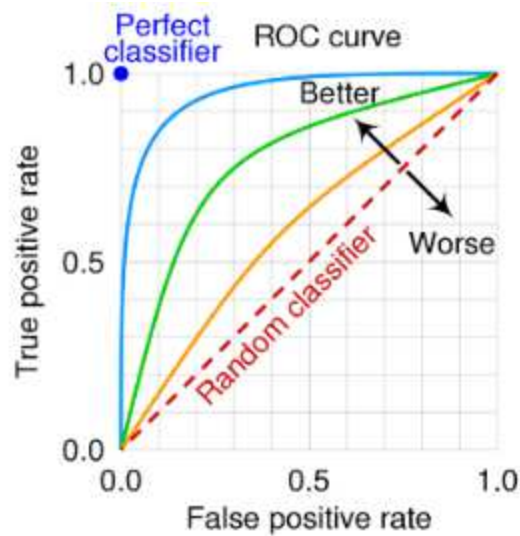
感度(Sensitive)、再現率、検出確率とも呼ばれる。陽性を取りこぼさない割合

偽陽性率  $\text{FPR} = \text{FP}/(\text{FP}+\text{TN})$  誤検出の確率とも呼ばれる

AUC: Area Under Curve

- 対象としている連続変数(例:検査の値、スコア、または予測確率)が、二値のアウトカム(例えば正/誤)をどの程度正確に識別できるか
- 0から1までの値をとり、値が1に近いほどモデルの性能が良いとされる。0.5 に近いほど、分類はランダムと同じとされ、精度は低い

図 8 ROC で使われる指標



<https://www.tomomi-research.com/archives/2401>

ROC 曲線が左上に寄るほど優れた性能を持つモデルといえ、ROC 曲線下の面積 (AUC) が大きいほどモデルの性能が高くなる

図 9 ROC 曲線のイメージと Top-left (Perfect classifier) の位置

Sentinel-2 簡易マップ改のための閾値決定の検討には、(1) F1 最大 (適合率と再現率の調和平均)、(2) Youden 指数最大 (ROC 曲線上での基準)、(3) Top-left (ROC 曲線上の理想点への距離最小) の 3 手法を比較した。各手法の概要を以下に示す。

#### (1) F1 値最大による閾値決定

F1 値最大は、判読データに対する分類結果が「誤って伐採と判定する (誤検出)」ことと「伐採を見逃す」ことの両方をできるだけ小さくするように、各指標の閾値を決定する方法である。ここで F1 値は、適合率 (Precision: 伐採と判定したもののうち、実際に伐採であった割合) と、再現率 (Recall: 実際に伐採であるもののうち、伐採と判定できた割合) を同時に考慮するための指標であり、両者のバランスが良いほど高くなる。

具体的には、まず各指標 (NDVI、NDMI、NDJI、NBRT 変則) について候補となる閾値を一定間隔で準備し、候補の組合せごとに伐採/非伐採の分類を行う。複数指標を同時に用いる場合は AND 則を採用し、「複数の条件をすべて満たす場合に伐採と判定する」ルールとする (例: NDVI 差分が閾値を超え、かつ NDMI 差分も閾値を超える場合に伐採と判定)。

各候補セットについて、分類結果と判読結果を突合し、混同行列 (TP、FP、FN、TN) を作成する。これに基づき、

$$\text{適合率 Precision} = \text{TP} / (\text{TP} + \text{FP})$$

再現率  $\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$

$\text{F1} = 2 \times \text{Precision} \times \text{Recall} / (\text{Precision} + \text{Recall})$

を計算する。最後に、得られた F1 値が最大となる閾値の組合せを、当該指標群に対する最適な閾値セットとして採用する。

なお、計算では各閾値を  $\times 1000$  して整数化したうえで 5 刻みで候補値を作成した。この範囲で候補を総当たりで評価し、F1 が最大となる組合せを抽出した。

## (2) Youden 指数最大による閾値決定

Youden 指数は、ROC 分析に基づき感度 (sensitivity = TPR) と特異度 (specificity = TNR) のバランスが最も良い閾値を選ぶ方法である。

Youden 指数  $J$  は

$$J = \text{sensitivity} + \text{specificity} - 1$$

で定義され、ROC 曲線上では  $J = \text{TPR} - \text{FPR}$  と同じである。伐採を拾える割合 (TPR) を高めつつ、誤検出率 (FPR) を低く抑える度合いを 1 つの値で表した指標であり、ROC 曲線上で  $J$  が最大となる点を閾値候補として採用する考え方である。

まず指標ごとに閾値を掃引し、各閾値で算出される  $J$  を比較して最大となる閾値 (ベスト点) を求めた。次に、指標ごとに得られた最適閾値を AND 則で組み合わせ、最終的な伐採判定に用いた。

また、Youden 指数は Precision (適合率) を用いず、 $\text{TPR} \cdot \text{TNR}$  (または  $\text{TPR} \cdot \text{FPR}$ ) といった「率」に基づくため、クラスの偏り (陽性の少なさ・多さ) の影響を相対的に受けにくい、という性質を有する。

## (3) Top-left (理想点への距離最小) による閾値決定

Top-left は、ROC 曲線上で理想点 ( $\text{FPR}=0, \text{TPR}=1$ ) に最も近い点を閾値として選ぶ方法である。ROC 空間では、FPR が小さいほど誤検出が少なく、TPR が大きいほど見逃しが少ないため、理想点は「誤検出も見逃しも最小」を意味する。

具体的には、閾値を掃引して得られる各点 ( $\text{FPR}, \text{TPR}$ ) について、理想点までの距離 (例:  $\sqrt{(\text{FPR} - 0)^2 + (1 - \text{TPR})^2}$ ) を計算し、この距離が最小となる閾値を採用する。Youden 指数と同様に指標ごとに Top-left 点を求め、複数指標を用いる場合は AND 則で統合した。

### ■ 閾値の計算

閾値の頑健性を確保するため、令和 6 年度調査で実施した令和 3 (2021) 年、令和 4 (2022) 年、令和 6 (2024) 年判読の結果 (約 9 万点) を 2 分割して教師用・検証用のデータセット

を作成した。データセット作る際、ランダムに 10 通り分作成し、閾値を計算した。最終的な閾値は、10 通りの反復計算で得られた教師用結果の中央値とした。

## ■ 結果

各手法による精度を表 7 に示す。

閾値設定では、伐採地の見逃しを極力抑えることを第一目的とした。一方で、誤検出が過度に増加すると、後続の判読・確認作業や推定値の安定性に影響し、運用上の負担が増大する。このため、見逃しの低減を優先しつつ、誤検出の増加を抑えるバランスの取れた閾値を採用する必要がある。

三つの閾値決定手法を比較した結果、それぞれの精度に大きな差がなく、その中で F1 値最大は再現率（見逃しの少なさ）と適合率（誤検出の少なさ）を同時に評価し、両者のバランスが最も良い組合せを直接選定できることから、本検討では F1 値最大の方法で閾値を決定した。

表 8 に、現行 FAMOST および改良 FAMOST の閾値を示す。現行版よりも閾値が小さくなり、これまで見逃していた伐採を抽出できることを示唆した。

表 7 3つの方法による精度一覧

		F1	Precision	Recall	Accuracy
Train	①F1Max	0.876	0.850	0.906	0.991
	②youden	0.858	0.815	0.905	0.989
	③topleft	0.856	0.809	0.910	0.989
Test*	①F1Max	0.870	0.841	0.901	0.990
	②youden	0.855	0.811	0.905	0.989
	③topleft	0.853	0.803	0.910	0.989

\*クロスバリデーションのため、目視判読地点 9 万点を 2 分割し、閾値決定用の Train データ・検証用の Test データを準備。Test データには、Train データから決定した閾値をあてはめ精度を出した

表 8 指標ごとの閾値

指標	現行 FAMOST 閾値 (大なり)	改良 FAMOST 閾値 (大なり)
NDVI	0.25	0.09
NDMI	0.40	0.03
NDJI	0.30	0.05
NBRT 変則	0.38	0.05

### iii. FAMOST 指標での精度評価および Landsat 時系列マップとの比較

上述の閾値で令和 5 (2023) 年と令和 6 (2024) 年の Sentinel-2 簡易マップ改をそれぞれ作成し、令和 5 (2023) 年のマップについて、Landsat 時系列マップの令和 5 (2023) 年と比較した結果、本州では比較的 Landsat 時系列マップと一致したが、北海道のいくつかの地域で誤検出が多くみられた。Landsat 時系列マップと伐採個所が比較的一致している熊本県人吉地域の例を図 10 に、誤検出が多かった北海道の厚真地域の例を図 11 に示す。なお、厚真では平成 30 (2018) 年の地震により斜面崩壊が多発している地域であるが、目視で確認したところ、斜面崩壊が発生した箇所は非伐採クラスであり、このエリアの崩壊は誤検出には影響していないと考えられた。誤検出は、落葉樹林、湿地、草地、地形や樹木の影などの箇所に集中して生じていた。

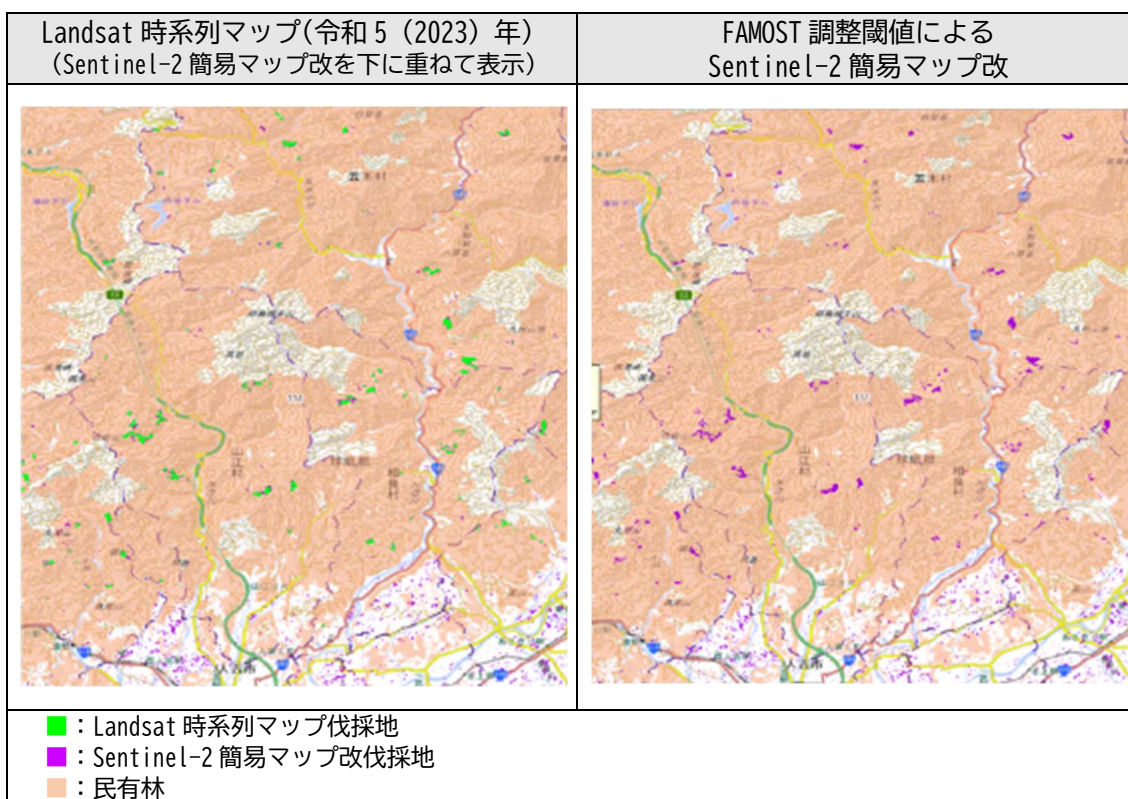


図 10 伐採マップで誤検出が少ない例 (熊本県人吉市北部)

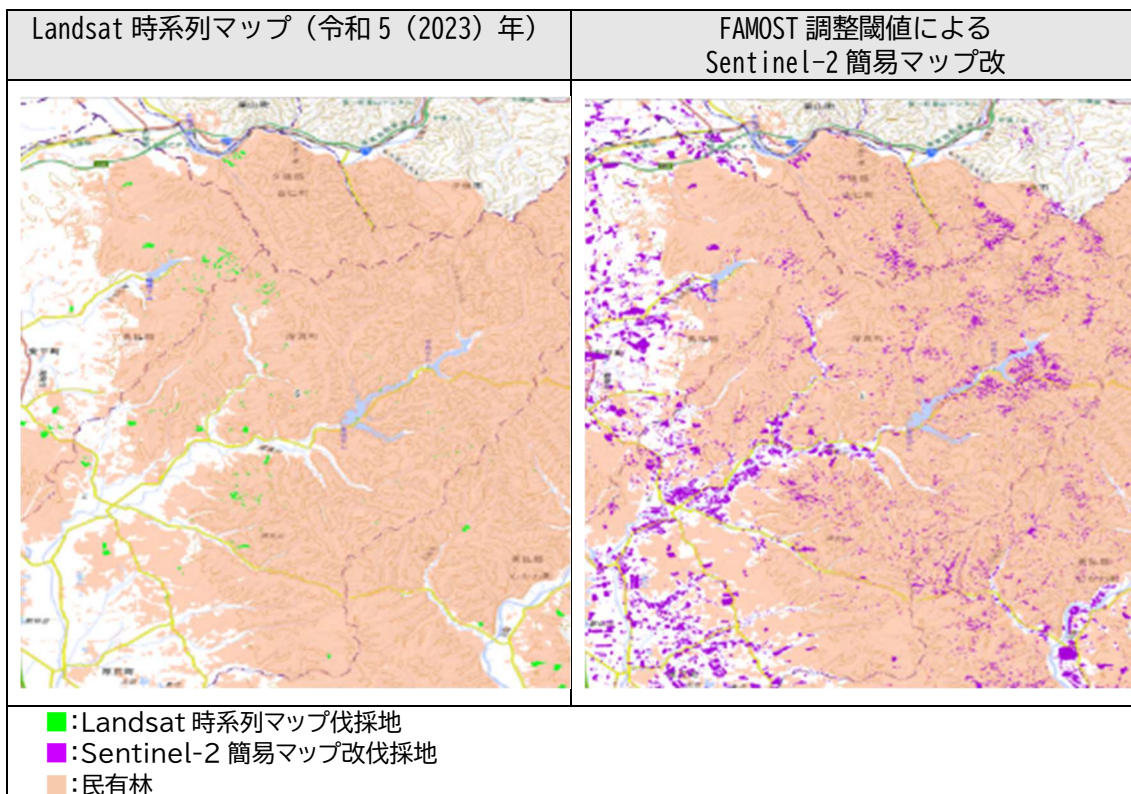


図 11 伐採マップで誤検出が多い例（北海道厚真町付近）

#### iv. 指標の再設定（Landsat 時系列マップ使用の指標適用）

比較の結果、特に北海道等の一部地域で誤検出が目立ったため、FAMOST で用いる指標を、Landsat 時系列解析で用いられる指標群のうち 4 つの指標（NBR およびタッセルドキャップ変換由来の指標等）に置き換えて再度閾値を検討した。

NBR は以下の計算式から求められる。

NBR(正規化燃焼比)

$$NBRT = \frac{NIR - SWIR2}{NIR + SWIR2}$$

タッセルドキャップ変換（Tasseled Cap Transformation: 以下、TCT という。）とは、衛星画像の複数バンド（可視・近赤外・短波赤外など）を、地表の状態を表しやすい少数の指標に変換する手法である。森林伐採のような変化は、概ね「明るさが増える」「緑が減る」「湿り気が減る」といった形で現れる。TCT では、このような変化に対応する成分を Brightness（明るさ）、Greenness（緑）、Wetness（湿潤度）として抽出され、解析や閾値判定に使用する。

各成分が表す意味は以下のとおりである。

**Brightness** (明るさ: TCB) : 地表がどれだけ「明るく見えるか」を表す。裸地や伐採後の地表は明るくなりやすく、森林は相対的に暗くなりやすい。

**Greenness** (緑: TCG) : 植生の「緑具合」を表す。森林や草地では高く、伐採や枯死で低下しやすい。

**Wetness** (湿潤度: TCW) : 植生や土壌の「湿り気」に関連する成分である。伐採による樹冠の消失や乾燥した裸地が露出すると低下しやすい。

伐採の検出では、前年と当年の差分値を取ることで、「明るさの増加」「緑の減少」「湿潤度の低下」といった変化を抽出する。

TCT の3つの成分は、各バンドに係数を掛けて足し合わせる線形変換であり、今回使用した指標のうち、TCG と TCW 係数×6つのバンドの加重和で計算した。

$$\text{TCG また TCW} = C_i \times B + C_{ii} \times G + C_{iii} \times R + C_{iv} \times \text{NIR} + C_v \times \text{SWIR1} + C_{vi} \times \text{SWIR2}$$

(※係数とバンドは Shi & Xu<sup>10</sup> 2019 から引用)

TCA (Angle) は、Brightness (TCB) と Greenness (TCG) の関係を逆正接として表したものである。

$$\text{TCA}(\text{angle}) = \arctan \frac{\text{TCG}}{\text{TCB}}$$

TCA は明るさに対して緑がどの程度あるかという相対的な状態を表現する。伐採や裸地化では、一般に「明るさが増え、緑が減る」方向に変化するため、TCA の差分も伐採の判別に有効となる。

図 12 は、ある地域の Landsat 画像について、TCT で得られた Brightness (横軸) と Greenness (縦軸) の分布を散布図として示した例である。多数の画素が特有の形状(房のついた帽子のような形)に分布することから“Tasseled Cap”と呼ばれる。散布図上で、森林・農地・裸地などの地表被覆は異なる位置に現れやすく、伐採のような変化は「緑が低下し、明るさが増す」方向への移動として捉えられる。

---

<sup>10</sup> Shi, Tingting and Xu, Hanqiu, 2019, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 12: 4038-4048, DOI: 10.1109/JSTARS.2019.2938388

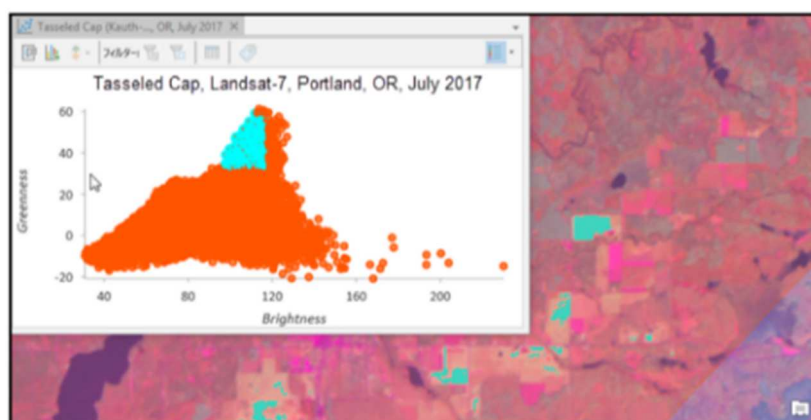


図 12 タッスルドキャップのイメージ図<sup>11</sup>

## ■ 結果

各手法による精度を表 9 に示す。現行 FAMOST で使用された指標のケースと同じく、F1 値最大の手法を採用した。各手法の閾値を表 10 に示す。

表 9 別指標を使った 3 つの方法による精度一覧

Landsat 時系列マップで使用されている指標		F1 最大	Precision	Recall	Accuracy
Train	①F1Max	0.874	0.860	0.890	0.991
	②youden	0.833	0.834	0.832	0.988
	③topleft	0.832	0.853	0.813	0.988
Test	①F1Max	0.867	0.854	0.882	0.991
	②youden	0.831	0.831	0.831	0.988
	③topleft	0.828	0.849	0.809	0.988

表 10 別指標ごとの閾値

指標	符号	閾値
NBR**	>=	-30
TCG	<=	670
TCW	<=	-390
TCA**	>=	100

\* クロスバリデーションのため、目視判読地点 9 万点を 2 分割し、閾値決定用の Train データ・検証用の Test データを準備。Test データには、Train データから決定した閾値をあてはめ精度を出した

\*\* NBR と TCA の差分値は×1000 で計算

<sup>11</sup> <https://pro.arcgis.com/ja/pro-app/latest/help/data/imagery/overview-of-imagery-and-raster-charts.htm>

### v. 別指標での手法別・教師/検証データの精度評価および Landsat 時系列マップとの比較

上述の Landsat 時系列マップ作成でも使用された 4 つの指標の閾値を用い、令和 5(2023)年と令和 6(2024)年の Sentinel-2 簡易マップ改をそれぞれ作成した。現行 FAMOST の指標値によるマップと同じく、令和 5(2023)年のマップについて、Landsat 時系列マップの令和 5(2023)年と比較した。北海道のいくつかの地域で多くみられた誤検出が少し減ったが、未だ誤検出が残った。Landsat 時系列マップと伐採個所が一致している熊本県人吉地域の例を図 13 に、誤検出が多かった北海道の厚真地域の例を図 14 に示す。誤検出は、前の指標と同じく落葉樹林、湿地、草地、地形や樹木の影などの箇所に集中して発生した。

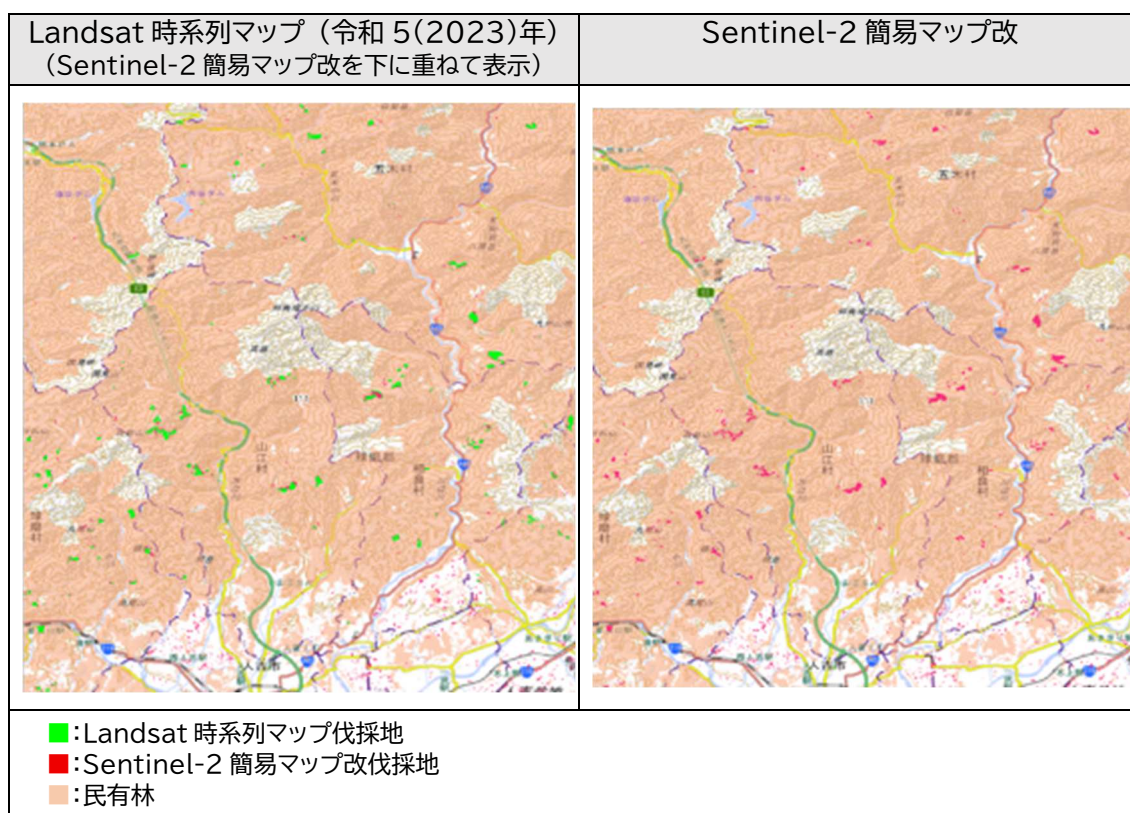


図 13 誤検出が少ない例 (熊本県人吉市北部)

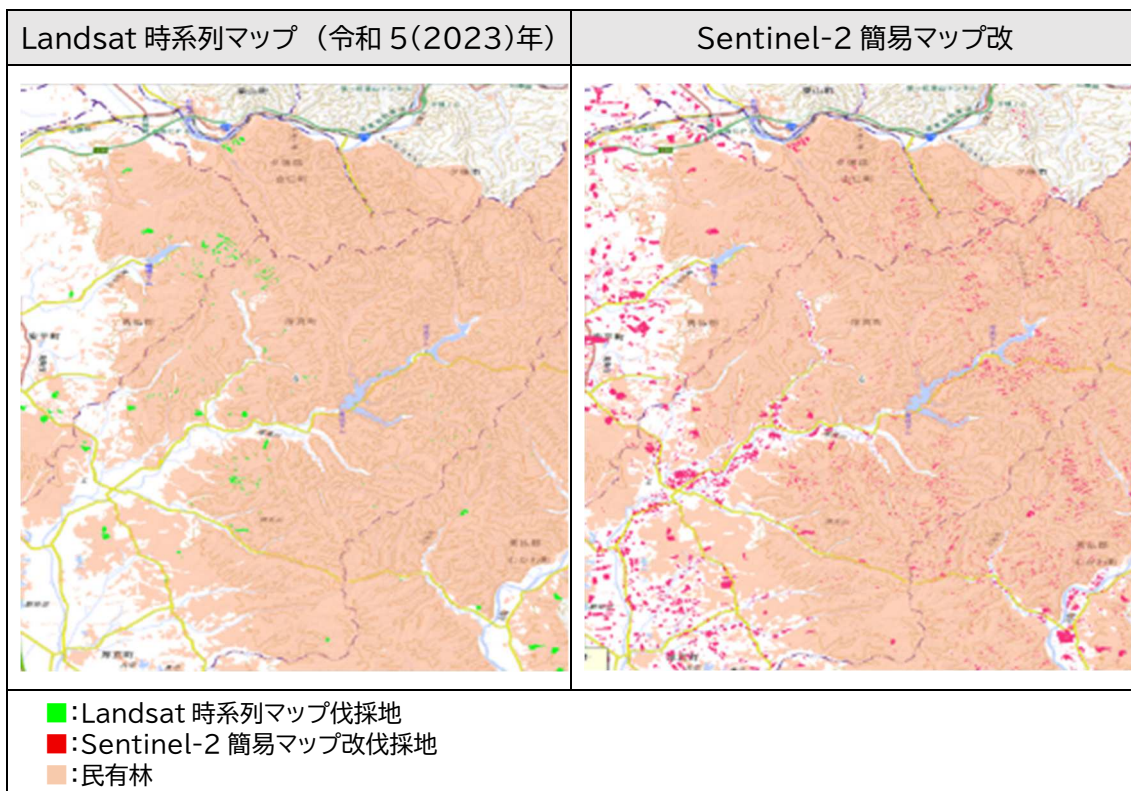


図 14 誤検出が多い例 (北海道厚真町付近)

**vi. 誤検出を減らすフィルタリングの適用**

指標の見直し後、地形や樹木の影、落葉広葉樹、湿地や草地等に起因する誤検出が多少減ったものの、目立って残った箇所もあった。面積推定の伐採マップとして用いるためには、伐採箇所を見逃すことなく検出しつつも、明らかな誤検出を防ぐ必要がある。このため、Sentinel-2 のシーン分類層やピクセル値を使い、追加フィルタリングを段階的に適用した。

北海道のいくつかの地域での誤検出を防ぐことで、それ以外の地域での伐採箇所の見逃しが増加しては推定精度に偏りが生じるため、他地域でも同程度の検出傾向となるよう、熊本県人吉北部でも伐採マップの出力結果を確認した。

誤検出を減らすためフィルタリングは以下 (1) ~ (4) である。

## (1) Sentinel-2 の SCL の使用

Sentinel-2 の SCL (シーン分類層 (Scene Classification Layer)) のうち 2, 3, 7-11 に該当する画素 (ピクセル) は合成画像の計算から除外した。

コード	名称
0	No Data (データなし)
1	Saturated or defective pixel (飽和または欠陥ピクセル)
2	Dark features (暗い地物 - 例: 影)
3	Cloud shadows (雲の影)
4	Vegetation (植生)
5	Not vegetated (非植生)
6	Water (水域)
7	Unclassified (未分類)
8	Cloud medium probability (中程度の雲確率)
9	Cloud high probability (高い雲確率)
10	Cirrus (巻雲)
11	Snow/Ice (雪/氷)

## (2) 影の追加マスク

山地等では地形や樹木の影により画素の反射率が低下し、伐採地と誤って判定される誤検出が生じやすい。この影響を減らすため、Shadow Index (SI)<sup>12</sup>を用いて暗い画素を抽出し、伐採マップ作成時に影領域をマスクする処理を検討した。SI は可視域の Blue (Sentinel-2 の B2)、Green (Sentinel-2 の B3)、Red (Sentinel-2 の B4) の反射率 (0-1) を用い、次式により算出する。

$$SI = \{(1 - B2) \times (1 - B3) \times (1 - B4)\}^{1/3}$$

SI は RGB の反射率がいずれも低い (暗い) 画素ほど値が大きくなり、1 に近づく。したがって、SI に閾値を設けて「SI が一定値より大きい画素」を影としてマスクすることで、地形影に起因する誤検出を抑制できる可能性がある。なお、SI=1.0 はマスク無し (影の除去を行わない) 条件に相当する。

本年度は、SI の閾値を 0.01 刻みで変化させて伐採マップを作成し、Landsat 時系列マップとの比較および目視確認により、影マスクの影響を評価した。例として、地形影の影響が顕著で誤検出が生じやすい北海道厚真付近を対象に、SI < 0.97、0.95、0.93 を適用した結果を

<sup>12</sup> geopera <https://docs.geopera.com/en/docs/spectral-indices/sentinel-2/si>

図 15 に示す。閾値を厳しくするほど影領域が除去され、誤検出は減少する一方で、伐採地の一部も同時に除去される傾向が確認された。

これらを踏まえ、最終的には目視確認の結果に基づき、 $SI=0.95$  を採用した。 $SI=0.95$  では、影起因と考えられる誤検出をある程度抑制できる一方、伐採地の抽出結果は概ね維持されることを確認した。ただし、影に起因する誤検出は一部残存する。

さらに、比較対象として熊本県人吉付近について、影マスク無し ( $SI=1.0$ ) と  $SI<0.95$  を適用した結果を図 16 に示す。 $SI<0.95$  では伐採地がわずかに減少するものの、主要な伐採箇所はほとんど残存しており、影マスクによる検出低下は限定的であることが確認された。

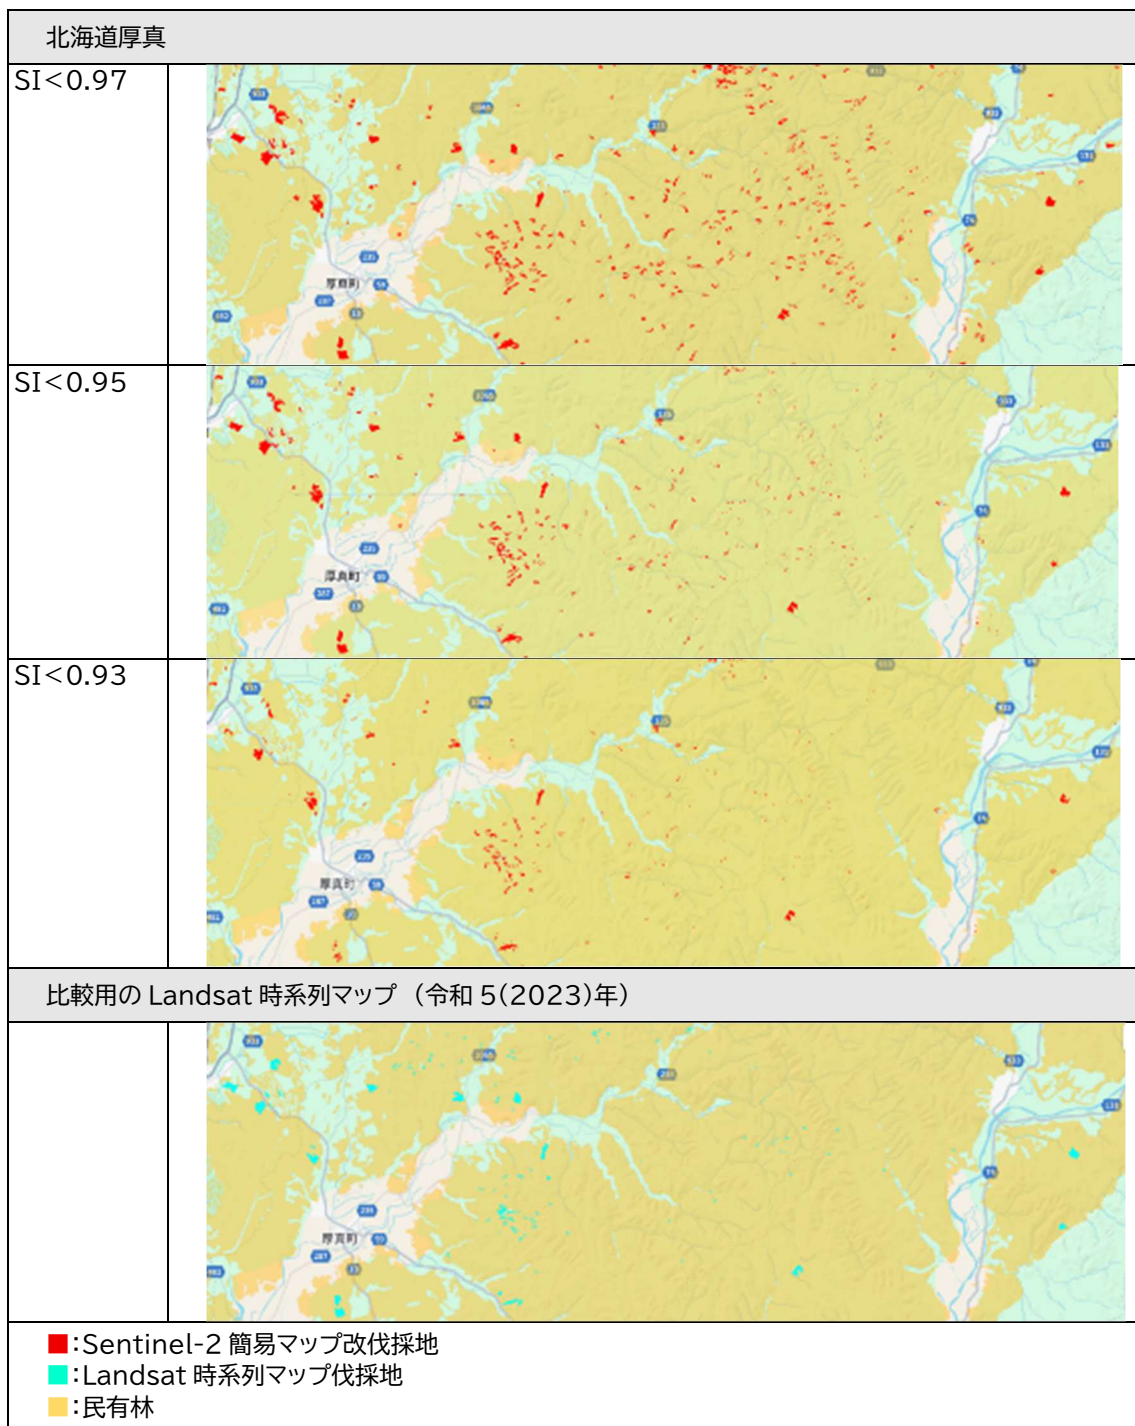


図 15 Shadow Index 適用後の北海道厚真付近の伐採地(例 SI> 0.97、0.95、0.93)

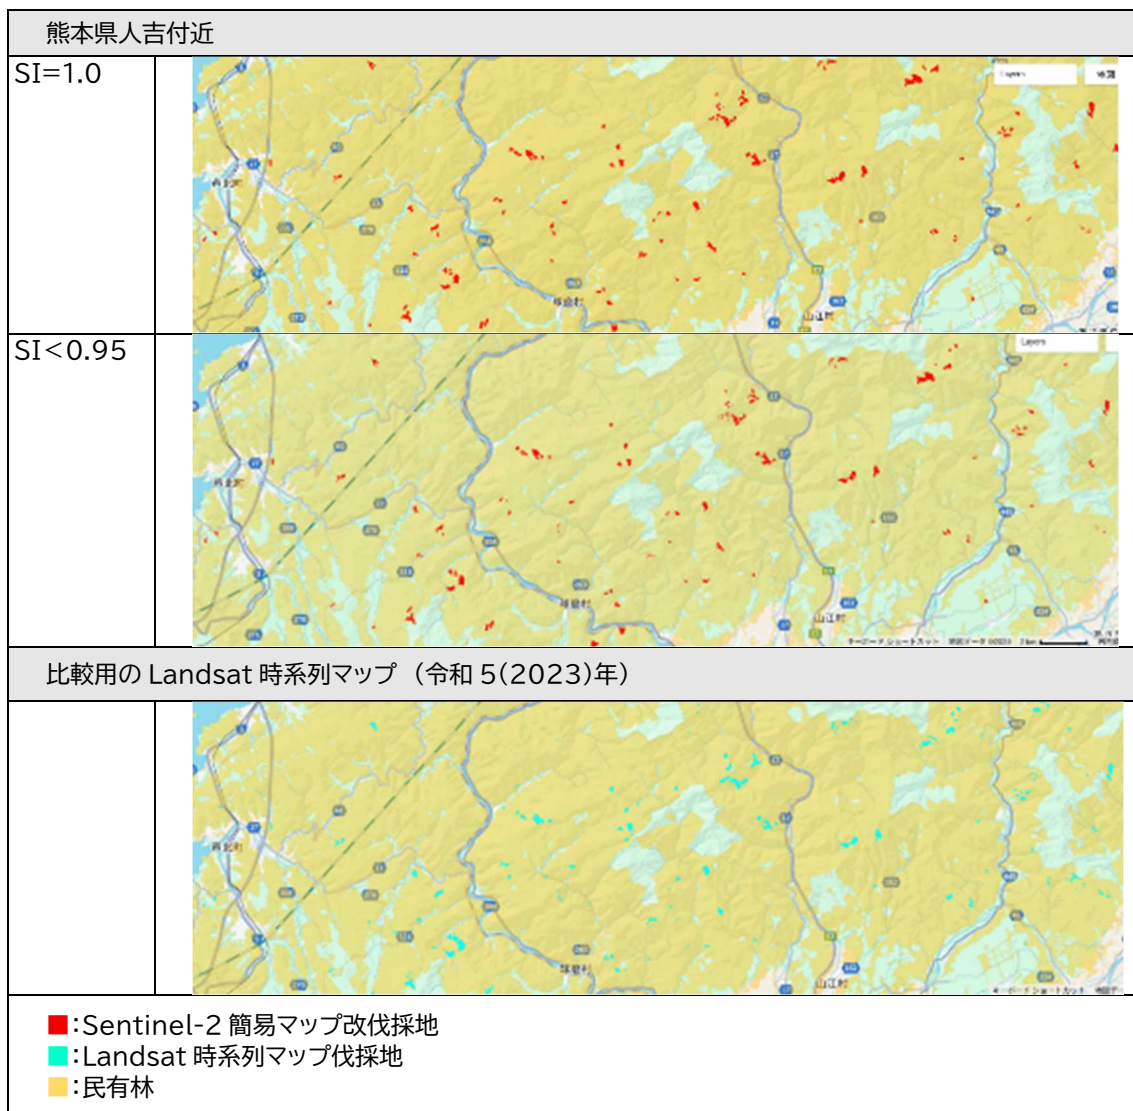


図 16 Shadow Index 適用後の熊本県人吉付近の伐採地(例 SI>1.0, 0.95)

### (3) 期首・期末フィルタ

Sentinel-2 簡易マップ改の作成において、落葉樹林、草地、湿地等の季節変化の影響を受けやすい植生では、差分指標のみでは伐採以外の変化を伐採として検出する誤検出が生じやすい。このため、本検討では、差分値ではなく期首 (BF) および期末 (AF) の値そのものに着目し、これらに閾値を設定することで、誤検出を減らす方法を試行した。

一般に、植生指標や各バンドの値は土地被覆の判別 (例: 森林と農地・草地の区別) に有効である。期首・期末の 2 時点の値を同時に用いることで、単純な差分では区別しにくい季節変化を含むピクセルを、機械抽出による伐採判定から除外できる可能性がある。

参照データ(正解データ)には、令和6年度調査で作成した令和3(2021)年、令和4(2022)年および令和6(2024)年の目視判読結果(伐採・非伐採)の約9万点を用いた。各指標または各バンドについて、期首(BF)および期末(AF)の値を説明変数、判読結果(伐採/非伐採)を目的変数として、ロジスティック回帰モデルを構築し、伐採である確率  $p$  を推定した。ロジスティック回帰はシグモイド関数により 0~1 の確率を直接モデル化する手法であり、期首(BF)・期末(AF)の2変数空間上に「伐採になりやすい領域/なりにくい領域」を分ける境界線(確率等高線)を与える(例 図17の散布図)。

モデルにより算出される確率  $p$  に閾値を設定し、 $p$  が閾値以上のピクセルを「伐採側」、それ未満を「非伐採側」として扱うことで、伐採マップの追加フィルタとして適用した。まず、 $p = 0.5$  は「伐採/非伐採を半数程度に分ける境界」に相当し、一般に誤検出を抑えやすい一方で、見逃しが増えやすい。実際、本検討でも  $p = 0.5$  相当の境界では目視判読で伐採だが非伐採と判定される地点(見逃し)が20~25%程度発生する傾向が確認された。このため、見逃しを抑える目的で  $p$  の閾値を下げ、見逃しとなる判読伐採サンプル点が除去される比率5%、10%、15%、20%の場合の  $p$  値を設定して比較した。

$p$  の計算式は以下のとおりである。

$$p = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \dots + \beta_i x_i)}}$$

試行した説明変数(指標・バンド)は、NDVI、NDMI、NBR、NBRT 変則、NDJI、ならびにタッセルドキャップ変換由来のTCB、TCG、TCW、TCA、さらに Sentinel-2 の Band1~9、Band11、Band12 である。各候補について、設定した  $P$  閾値を用いて Sentinel-2 簡易マップ改に対する再判定(フィルタリング)を行い、作成したマップを Sentinel-2 画像と比較して妥当性を確認した。

## ■ 結果

判読サンプル約9万点について、伐採確率  $p = 0.5$  での判読伐採が非伐採と判定される数(見逃し数)とその比率を指標別に示した(表11)。試行した指標のうち、Band12(SWIR2)は見逃し数629、比率19.0%と、比較的見逃しが少ない結果となった。

図17には、Band12を例として、期首(BF)と期末(AF)の散布図上に、判読での伐採判定が非伐採となる比率を5%、10%、15%、20%に固定した場合の境界線(確率等高線)を重ねて示す。比率を小さく設定する(見逃しを減らす)ほど、境界は非伐採側へ広がり、伐採と判定される領域が増える傾向となる。これは、見逃しを減らす代わりに、判読での非伐採を伐採とする誤検出も減らないことを意味する。

図18には、Shadow Index(SI)による影マスク(例:  $SI < 0.95$ )に加え、期首・期末フィルタ(ロジスティック回帰に基づく  $p$  閾値)を適用した北海道の一部の地域(日高山脈の高山域で人為攪乱が少ないエリア)について例を示す。このエリアは誤検出が特に顕著だが、

前節（２）の影マスクだけでは減らせなかった誤検出が期首・期末フィルタ（10%見逃し）を併用することで抑制されていることが確認された。

誤検出が比較的少ない熊本県人吉エリアを例として図 19 に示す。左図は Landsat 時系列マップによる令和 5（2023）年の伐採マップを黄緑で、右図の Shadow Index0.95 フィルタおよび Band12 の期首・期末フィルタをかけた後の伐採マップを水色で示しており、両者を比較すると、主要な伐採箇所が残存していることが確認された。

表 11 指標別の見逃し数とその比率

指標	判読伐採サンプルのうち見逃される数	判読伐採サンプル総数に対する比率
NDVI	820	24.8%
NDMI	750	22.7%
NBR	694	21.0%
NBRT 変則	678	20.5%
NDJI	654	19.8%
TCG	1436	43.5%
TCW	753	22.8%
TCA	742	22.5%
Band4(Red)	795	24.1%
Band5 (Red edge)	1319	39.9%
Band8 (NIR)	3299	99.8%
Band11 (SWIR1)	815	24.7%
Band12(SWIR2)	629	19.0%




図 17 適用した Sentinel-2 Band12 の期首に対する期末データ

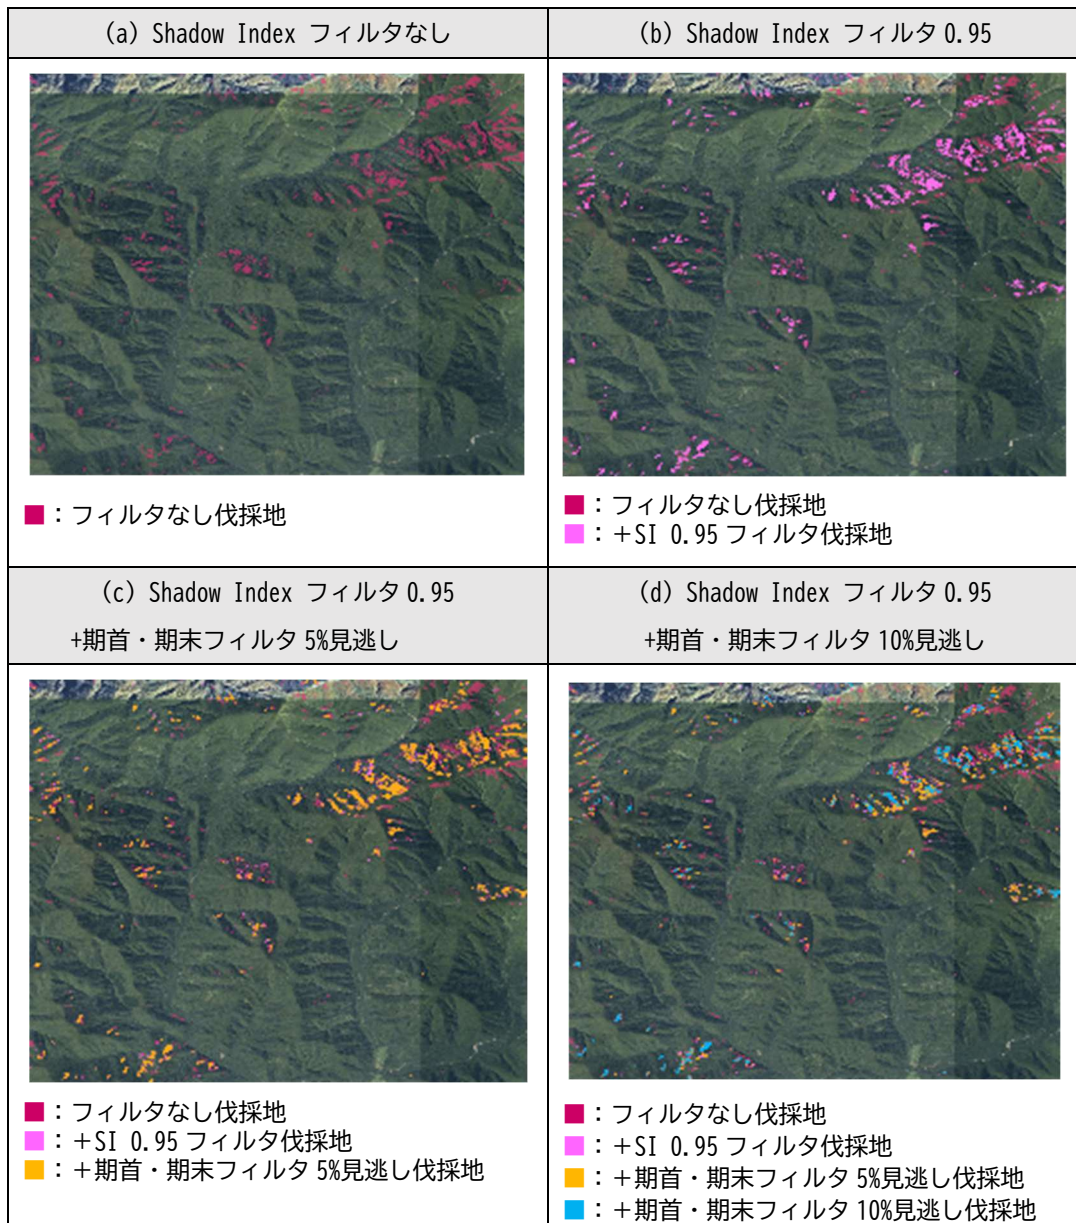


図 18 期首・期末フィルタを適用した例（北海道日高山脈）

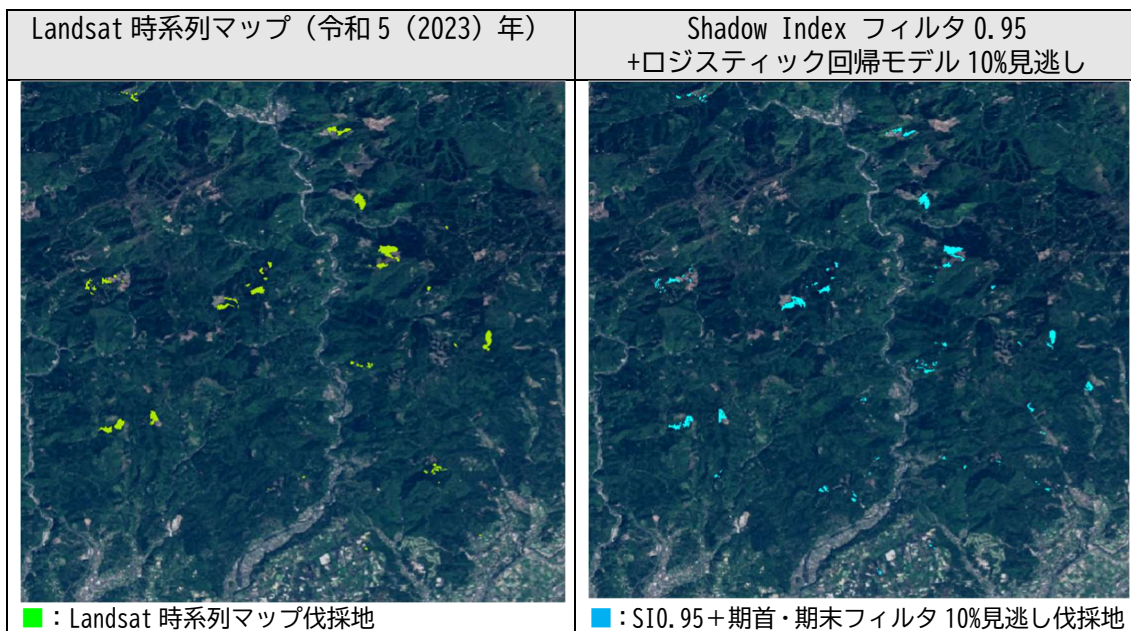


図 19 期首・期末フィルタを適用した例 (熊本県人吉)


#### (4) 最小面積の設定 : 0.1ha

抽出された伐採エリアについて、最小面積を 0.1 ha 以上とし、それより小さいエリアは伐採としての対象から除外した。これは、衛星画像の空間分解能や分類処理に伴うノイズ (境界のギザつき、影・裸地・作業道等による微小な誤検出) により、実際の伐採ではない小規模パッチが点在的に抽出されることがあるためである。

以上 4 つのフィルタリングを実行した。結果として、季節変化や森林以外の変化による誤検出を減らすため、Sentinel-2 Band12 (SWIR2) の期首・期末データを用いたフィルタリングが特に有効で、ロジスティック回帰モデルの確率閾値は、判読サンプルのうち伐採判読地点の 10% を見逃しとする  $p$  値を適用し、主要な伐採地を概ね維持しつつ誤検出を一定程度抑制できることを確認した。また、Shadow Index による影マスク ( $SI < 0.95$ ) でも一部の誤検出を減らすことができた。

#### vii. Sentinel-2 簡易マップ改の完成

以上の手順により、民有林域を対象とした Sentinel-2 簡易マップ改を作成した。以降の面積推定では、当該マップを用い、1. 変化なし、2. 伐採、3. バッファの 3 層からなる層化マップを作成し、①と同一の方法でサンプル抽出・目視判読・面積推定した。図 20 に層化マップの拡大図を示す。



- 2023-2024 年伐採
- 伐採箇所周囲 1 ピクセル (バッファ)
- 民有林で変化なし
- 民有林以外

図 20 Sentinel-2 簡易マップ改から作成の層化マップの拡大図 (約 8km 四方)

#### viii. 判読準備・判読・管理作業

層サンプル数は、①と同様に、95%信頼区間の幅を概ね±10%程度に抑えることを目標として n=31,000 点とした。層別のサンプル配分は層面積割合に応じて設定し (表 12)、各層内で無作為抽出した。サンプル地点を図 21 に示す。



図 21 令和 5 (2023) ・令和 6 (2024) 年判読用に抽出したサンプル (n=31,000) の位置 (茶色点)

表 12 民有林での令和 5（2023）・令和 6（2024）年伐採面積推定のための層化区分とサンプル数

層	マップ面積※(ha)	面積割合(%)	n
民有林で変化なし（変化なし）	17,739,056	99.3	27,170
令和 5(2023)・令和 6(2024)年伐採(伐採)	83,246	0.466	2,040
伐採箇所周囲 1 ピクセル（バッファ）	47,805	0.268	1,790

※マップ面積とは、伐採マップに占める各層のピクセルの面積を全て足し合わせたもの

判読セットの材料データの収集および作成、判読、判読管理については、③過去の伐採面積の推定（全国）と同じ手順・手法で作業を進めた。判読は、Sentinel-2 年次合成画像および NDVI 時系列推移等を材料とし、①と同様に判読者 3 名による判読と多数決により伐採・非伐採を確定した。

#### ix. 令和 5（2023）・令和 6（2024）年 伐採面積集計

伐採面積の推定の計算には、層化無作為抽出に基づく面積推定の計算式（詳細は令和 6 年度調査報告書を参照）を適用し、年ごとの伐採面積および 95%信頼区間を算出した。層化マップの Producer's 精度と User's 精度を表 13、推定結果を表 14、信頼区間を表 15 に示す。令和 5（2023）年の伐採面積は 49,969ha、令和 6（2024）年は 48,454ha で、95%信頼区間はそれぞれ±5,306ha、±4,664ha だった。95%信頼区間の伐採面積に対する比率は、それぞれ 10.6%、9.6%で、おおよそ 10%程度となった。

表 13 層化マップの Producer's 精度と User's 精度

層	Producer's 精度	User's 精度
変化なし	0.997	0.999
2017-20 伐採	0.829	0.622

表 14 令和 5 (2023) ・令和 6 (2024) 年の推定伐採面積の概要

層化区分	変化なし				2023-2024 伐採				バッファ				層化マップ 面積合計
	サンプル数		層化マップ面積		サンプル数		層化マップ面積		サンプル数		層化マップ面積		
	27,170 点		1,773.9 万ha		2,040 点		8.3 万ha		1,790 点		4.8 万ha		1,787.0 万ha
推定対象年	判読結果		平均 伐採 割合	推定 伐採面積	判読結果		平均 伐採 割合	推定 伐採面積	判読結果		平均 伐採 割合	推定 伐採面積	推定 伐採面積 合計
令和 5(2023)年	伐採	15 点	0.0005	9,718 ha	伐採	762 点	0.3952	32,901 ha	伐採	260 点	0.1538	7,350 ha	49,969 ha
	非伐採	2,7366 点			非伐採	1,166 点			非伐採	1,431 点			
令和 6(2024)年	伐採	11 点	0.0004	7,126 ha	伐採	783 点	0.4061	33,808 ha	伐採	266 点	0.1573	7,520 ha	48,454 ha
	非伐採	2,7370 点			非伐採	1,145 点			非伐採	1,425 点			

各層化区分の推定伐採面積は、層化マップ面積×平均伐採割合による求められる。

表 15 令和 5 (2023) ・令和 6 (2024) 年の信頼区間と伐採面積に対する比率

年	推定面積(ha)	95%信頼区間(ha)	伐採面積に対する比率
2023	49,969	5,306	10.6%
2024	48,454	4,664	9.6%

■ 令和 6 年度調査の令和 6 (2024) 年伐採面積推定結果との比較

ここで、令和 6 (2024) 年の伐採面積について、令和 6 年度調査では面積が 54,248ha で (図 22 のオレンジの丸)、本事業の推定値との差が +5,794 ha であった。この原因として、令和 6 年度調査の令和 6 (2024) 年伐採面積の推定では判読人数が 1 名/1 サンプル地点であり判読のブレやミスがあったと推察された。このことから、特に面積推定の寄与が大きい層化マップで非伐採かつ判読で伐採 (表 16) となったサンプル地点 53 点について、3 名で再度判読した。その結果、令和 6 年度調査の面積は 50,173ha となり本年事業結果との差は +1,719ha と小さくなった (図中の水色の丸)。なお、令和 6 年度調査時点の結果でも、信頼区間内に令和 7 年度の結果は入っている (図中のオレンジの縦点線)。

令和 7 年度の結果は、信頼区間の幅が狭くなっており、令和 6 年度成果ほどぶれは大きくはなく精度が高くなったといえる。判読においては、令和 6 年度調査報告書でも述べられているように、同じサンプル箇所を 3 人で判読すると判読誤差をかなり軽減できることが明示された。




図 22 衛星画像による伐採地の推定面積の推移

表 16 層別の判読結果における伐採推定面積への寄与  
(令和 6 年度調査の令和 6 (2024) 年推定の場合)

MAP 層	MAP 面積	サンプル数	目視判読結果		備考	
			非伐採	伐採	(1 点当たり面積重み)	
非伐採	17,843,937 ha	28,600 点	28,547 点	53 点	目視判読を 1 点間違うと約 600 ha ずれる (MAP 面積大)	624 ha/点
伐採	27,216 ha	1,400 点	84 点	1,316 点	目視判読を 1 点間違うと約 20 ha ずれる (MAP 面積小)	19 ha/点
計	17,871,153 ha	30,000 点	28,631 点	1,369 点		

## ■ 課題

本節での課題は、Sentinel-2 簡易マップ改に含まれる誤検出をいかに低減するかにあった。本年度は誤検出低減を目的として 4 種類のフィルタリングを適用したものの、一定の誤検出は残存した。特に令和 5 (2023) 年については、北海道の一部地域で誤検出が目立ち、夏季 (展葉期) 画像の取得数が限られたことが一因と考えられる。落葉樹林の場合、展葉期の

画像が不足すると落葉期の画像がコンポジット（合成画像）に混在しやすく、結果として季節変化が伐採と誤って判定される可能性がある。

このような季節性や観測機会の不足に起因する誤検出を抑制するためには、2時点の差分に基づく抽出に加えて、Landsat 時系列マップのように多時点の推移情報から伐採を判定する手法が有効と考えられる。多時点情報を用いることで、特定年の気象条件や画像不足に左右されにくい判定が可能となる一方、処理する画像枚数が増加するため計算資源を要し、運用コストが増大し得る点が課題である。

今後は、FAMOST を基盤としつつ、季節変化の影響を抑える追加的なフィルタリングや判定方法の改良、ならびに計算負荷を抑えた方法（軽量な時系列指標の導入等）の検討が課題対応として考えられる。

#### ⑤ FAMOST を活用した伐採面積の推定（スギ人工林伐採重点区域）

花粉発生源対策の推進に向けて把握が求められる「スギ人工林伐採重点区域<sup>13</sup>」を対象に、令和5（2023）年及び令和6（2024）年の伐採面積を推定した。伐採マップとして②で作成した Sentinel-2 簡易マップ改を使用し、①および②と同様、層化無作為抽出による目視判読点結果から伐採面積を推定した。

対象とした「スギ人工林伐採重点区域」は、林野庁により提供された都道府県別の「スギ人工林伐採重点区域」GIS ポリゴンデータを国土地理院が公表する民有林ポリゴン<sup>14</sup>でマスキングした。図 23 に示した黒いエリアが最終的な対象エリアである。

層化マップ各層の面積及び面積割合、ならびにサンプル数は表 17 のとおりである。図 24 にランダムに配置したサンプル地点を紫色で示す。

---

<sup>13</sup> 「スギ花粉発生源対策推進方針（平成 13 年 6 月 19 日付け 13 林整保第 31 号林野庁長官通知）」に基づき、各都道府県において設定された区域

（参考：[https://www.rinya.maff.go.jp/j/sin\\_riyou/kafun/attach/pdf/suishin-8.pdf](https://www.rinya.maff.go.jp/j/sin_riyou/kafun/attach/pdf/suishin-8.pdf)）

<sup>14</sup> 国土数値情報の森林地域ポリゴンデータのうち、「地域森林計画対象民有林」  
（<https://nlftp.mlit.go.jp/ksj/gml/datalist/KsjTmplt-A13.html>）



図 23 面積推定の対象としたスギ人工林伐採重点区域




図 24 スギ人工林伐採重点区域の令和 5 (2023) ・令和 6 (24) 年判読用に抽出したサンプル (n=31,000) の位置 (紫色の点)

表 17 スギ人工林伐採重点区域の令和 5 (2023) ・令和 6 (24) 年用の民有林での伐採面積推定のための層化区分とサンプル数

層	マップ面積※(ha)	面積割合(%)	n
民有林で変化なし (非伐採)	2,241,317	99.276	27,186
令和 5(2023)/令和 6(2024)年伐採 (伐採)	10,043	0.445	1,949
伐採箇所周囲 1 ピクセル (バッファ)	6,291	0.279	1,865

※マップ面積とは、伐採マップに占める各層のピクセルの面積を全て足し合わせたもの

## ■ 結果

層化マップの Producer's 精度と User's 精度を表 18、令和 5（2023）年と令和 6（2024）年の推定伐採面積を表 19、95%信頼区間を表 20 に示す。重点区域 GIS ポリゴン（民有林内）を基とした推定伐採面積は令和 5（2023）年が 6,733 ha、令和 6（2024）年が 7,362 ha となった。95%信頼区間はそれぞれ±728 ha、±764 ha、95%信頼区間に対する伐採面積の比率はそれぞれ 10.8%、10.4%でおよそ 10%程度であった。令和 6 年度調査では、限られたサンプル数（2,230）により推定された結果、令和 4（2022）年の推定面積 2,477ha±1,270ha（95%信頼区間、伐採面積に対する比率 51.3%）であったことと比較すると、必要サンプル数を確保した上で実施した、本事業での推定では精度が大幅に向上した。

## ■ 課題

本推定面積をスギ花粉発生源の減少量として適切に評価するためには、スギ人工林伐採重点区域の GIS ポリゴンの精度向上が求められる。GIS ポリゴンの精度は都道府県により異なり、提供された GIS データは、区域を広く指定している等重点区域以外も含まれていると思われる例も散見された。民有林ポリゴンでマスキングを行った上で伐採マップを作成したものの、このように区域が広域に設定されている場合、推定伐採面積には、スギ人工林伐採重点区域以外の伐採が含まれる可能性があることに留意する必要がある。

今後は、重点区域ポリゴンの面積の確認や、可能な都道府県においては属性に樹種区分を追加し、そこからスギ人工林を抽出してマスク条件として設定するといった検討が望ましい。

表 18 層化マップの Producer's 精度と User's 精度

層	Producer's 精度	User's 精度
民有林で変化なし（非伐採）	0.998	0.999
令和 5(2023)/令和 6(2024)年伐採（伐採）	0.778	0.671

表 19 スギ人工林伐採重点区域の令和 5（2023）・令和 6（2024）年の推定伐採面積の概要

層化区分	変化なし		2023-2024 伐採				バッファ				層化マップ 面積合計		
	サンプル数	層化マップ面積	サンプル数	層化マップ面積		サンプル数	層化マップ面積						
	27,186 点	224.1 万ha	1,949 点	1.0 万ha		1,865 点	0.6 万ha		225.7 万ha				
推定対象年	判読結果		平均 伐採 割合	推定 伐採面積	判読結果		平均 伐採 割合	推定 伐採面積	判読結果		平均 伐採 割合	推定 伐採面 積	推定 伐採面積 合計
令和 5(2023)年	伐採	18 点	0.0007	1,484 ha	伐採	789 点	0.4048	4,065 ha	伐採	351 点	0.1882	1,184 ha	6,733 ha
	非伐採	27,168 点			非伐採	1,160 点			非伐採	1,514 点			
令和 6(2024)年	伐採	20 点	0.0007	1,649 ha	伐採	888 点	0.4556	4,576 ha	伐採	337 点	0.1807	1,137 ha	7,362 ha
	非伐採	27,166 点			非伐採	1,061 点			非伐採	1,528 点			

各層化区分の推定伐採面積は、層化マップ面積×平均伐採割合による求められる。

表 20 スギ人工林伐採重点区域の令和 5（2023）・令和 6（2024）年の信頼区間と伐採面積に対する比率

年	推定面積(ha)	95%信頼区間(ha)	伐採面積に対する比率
令和 5（2023）	6,733	728	10.8%
令和 6（2024）	7,362	764	10.4%

## ⑥ 都道府県別の伐採面積推定に向けた検討

昨年度は、衛星画像を用いた伐採判読結果を基に、都道府県別の民有林伐採面積を推定するための必要サンプル数の算定方法について検討を行った。その結果、必要サンプル数は以下の要因に強く依存することが確認された。

1. 都道府県の民有林面積
2. 伐採面積割合
3. 伐採面積に対する誤差率の設定
4. 分類精度（Producer's 精度、User's 精度）

特に、伐採面積の 10%に相当する 95%信頼区間を達成する場合、伐採面積割合が小さい都道府県では必要サンプル数が大きく増加することが示された。このことから、全国一律に相対誤差を設定した場合では伐採面積割合が小さいにもかかわらず、実務的に過大なサンプル数を要する都道府県が生じる可能性がある。

そこで本年度は都道府県別の伐採面積を推定する場合に必要なサンプル数について、伐採規模に応じた 95%信頼区間を「伐採面積の $\pm\alpha\%$ （以下、相対誤差という）」や「 $\pm\beta$ ha（以下、絶対誤差という）」等で示し、都道府県規模に応じた合理的なサンプル数設定方法について検討した。本稿では、以下のステップで分析をする。

- i. 相対誤差の変化と、それに対応する誤差面積および必要サンプル数の関係
- ii. 絶対誤差（ha）を一定とした場合の必要サンプル数と伐採面積規模の関係
- iii. 伐採規模を踏まえた都道府県別精度設定の検討

### i. 相対誤差の変化と、それに対応する誤差面積および必要サンプル数の関係

単純無作為抽出における必要サンプル数は令和 6 年度調査報告書の式（15）～（34）に当てはめて求めることができる。本年度と昨年度の前提を示す（表 21）。前提条件のうち、本年度において変更したのは相対誤差の設定のみである。

表 21 必要サンプル数計算の前提

項目	本年度	昨年度
都道府県の民有林面積	昨年度データを利用	国土数値情報森林地域データを加工
伐採割合	昨年度データを利用	過去の衛星データでの推定値 (Shimizu & Saito 2021)
相対誤差	10~25%	10%
Producer's 精度	昨年度と同じ	80%
User's 精度	昨年度と同じ	90%

はじめに、相対誤差の設定を 10~25% に変化させ、都道府県別の必要サンプル数を求めた。都道府県別の必要サンプル数と相対誤差 (%) および誤差面積 (ha) の関係を以下に示す。誤差面積は伐採面積に対する誤差率から求められる。

$$\text{誤差面積 (ha)} = \text{推定伐採面積 (ha)} \times \text{相対誤差} \quad (1)$$

都道府県別の相対誤差の変化に伴う必要サンプル数および誤差面積の関係を 6 巻末資料 6.1 報告書付属資料に示した。

ここで、伐採割合・民有林面積が最も大きい北海道、伐採割合が最も小さい沖縄県、伐採面積が最も小さい大阪府の図を示す (図 25、図 26、図 27)。




図 25 必要サンプル数と相対誤差の関係の例




図 26 必要サンプル数と相対誤差および誤差面積の関係の例  
 (北海道：民有林面積 2,708,647ha, 民有林推定伐採面積 11,782ha, 伐採面積割合 0.43%)




図 27 必要サンプル数と相対誤差および誤差面積の関係の例  
 (大阪府：民有林面積 60,540ha, 民有林推定伐採面積 151ha, 伐採面積割合 0.25%  
 沖縄県：民有林面積 83,123ha, 民有林推定伐採面積 51ha, 伐採面積割合 0.06%)

相対誤差 (%) を小さくすると必要サンプル数は増加し、特に±10%付近では必要サンプル数が急激に増加する傾向が確認された。また、同じ誤差率であっても、伐採面積の大きい都道府県（例えば北海道）ほど許容面積誤差は大きくなり、逆に伐採面積の小さい都道府県（例えば大阪府）では許容面積誤差は小さくなる。このことが、相対誤差方式において伐採面積の小さい県で必要サンプル数が増加する主因である。

## ii. 絶対誤差 (ha) を一定とした場合の必要サンプル数と伐採面積規模の関係

次に、絶対誤差 (ha) を固定した場合の必要サンプル数を検討した。図 28 は、絶対誤差を±200ha とした場合における、都道府県別の推定伐採面積と必要サンプル数の関係を示したものである（伐採面積の大きい北海道、宮崎県、岩手県は図の視認性の観点から除外している）。




図 28 絶対誤差を±200ha とした場合における都道府県別の推定伐採面積と必要サンプル数の関係

(伐採面積の大きい北海道、宮崎県、岩手県は図の視認性の観点から除外し、下表に示す)

参考値	推定伐採面積 (ha)	必要サンプル数
北海道	11,782	659,157
宮崎県	5,139	44,608
岩手県	4,865	78,892

図 28 より、絶対誤差 (ha) を固定した場合、伐採面積が小さい都道府県では比較的少ないサンプル数で目標とする 95%信頼区間幅 ( $\pm 200$ ha) を達成できる一方、伐採面積の大きい都道府県では同一の信頼区間幅を達成するために非常に多くのサンプル数を要することが確認された。

これは、絶対誤差を一定に保つ場合、伐採面積が大きいほど結果として相対誤差が小さくなり、より厳しい精度条件を満たす必要 (= サンプル数の増加) が生じるためである。

以上の結果から、相対誤差方式と絶対誤差方式は、都道府県の伐採規模によって有利・不利が逆転する構造を持つことが明らかとなった。整理すると次のとおりである (表 22)。

表 22 伐採規模と精度設定の関係

精度設定	小規模県	大規模県
相対誤差	不利	有利
絶対誤差	有利	不利

すなわち、相対誤差を基準とする場合は伐採規模の小さい都道府県でサンプル数が増加し、絶対誤差を基準とする場合は伐採規模の大きい都道府県でサンプル数が増加するというトレードオフの関係が存在する。

### iii. 伐採規模を踏まえた都道府県別精度設定の検討

以上の分析から、相対誤差方式と絶対誤差方式は、都道府県の伐採規模によって有利・不利が逆転する構造を持つことが明らかとなった。すなわち、全国一律にいずれかの方式を採用する場合、必然的に一部の都道府県に過大なサンプル数負担が生じることになる。

本事業で実施した判読サンプル数は約 30,000 点 (4.1 衛星画像等のリモートセンシング技術を活用した推定手法の精緻化参照) である。本項では、その数を上限と仮定し、この制約条件の下で、都道府県別にどの精度設定がより適切かを整理する。精度目標としては、4.1 で実施した全国の伐採面積の推定と同様、推定伐採面積に対する相対誤差 $\pm 10\%$ を第一目標とした。

その上で、各都道府県について表 23 の通り整理した。その手順を以下に示す。

- ① まず相対誤差 $\pm 10\%$ で必要サンプル数計算
- ② サンプル数 30,000 点以内なら A グループに分類
- ③ 相対誤差 $\pm 10\%$ を超える県は サンプル数 30,000 点制約時下の誤差面積を計算
- ④ ③で計算した誤差面積を推定伐採面積で割り、相対誤差 (%) を算出する。
- ⑤ 以下の基準で、都道府県を以下の 3 グループに分類した。

### A グループ

#### 「30,000点以内で相対誤差±10%を達成可能な都道府県」

これらの都道府県については、当初の目標である±10%をそのまま採用する。すなわち、統一的な相対誤差基準を維持しつつ、実務的にも実現可能な範囲に収まる県である。

### B グループ

#### 「30,000点では±10%は達成できないが、実質誤差が10~15%の範囲に収まる都道府県」

これらの都道府県では、30,000点に固定した場合に達成可能な95%信頼区間幅を逆算し、その結果として得られる実質的な相対誤差を評価した。その誤差が10~15%の範囲に収まる場合には、実務上許容可能な水準と判断し、この水準を当該県の現実的な精度目標と位置付けた。

### C グループ

#### 「30,000点に固定した場合でも実質誤差が15%を超える都道府県」

これらの都道府県では、相対誤差±10%の達成は物理的に困難であり、30,000点という制約下では一定の誤差拡大を受け入れざるを得ない。したがって、本設計では、30,000点において実現可能な95%信頼区間を当該県の達成可能水準として整理した。

表 23 サンプル数 30,000 点制約下における都道府県別精度区分

都道府県	グループ	相対誤差±10% を達成するた めに必要な サンプル数	推定伐採面積 (ha)	サンプル数 30,000点制約 下の誤差面積 (ha)	相対誤差 (%)
北海道	A	18,993	11,782.40	-	10.00
福岡県	A	17,307	1,007.57	-	10.00
大分県	A	11,496	3,005.38	-	10.00
栃木県	A	16,561	1,102.14	-	10.00
茨城県	A	18,536	720.51	-	10.00
福島県	A	29,159	1,639.93	-	10.00
熊本県	A	15,239	2,304.15	-	10.00
秋田県	A	17,978	2,100.83	-	10.00
宮城県	A	15,586	1,598.46	-	10.00
岩手県	A	13,332	4,865.30	-	10.00
青森県	A	11,688	1,957.64	-	10.00
宮崎県	A	6,756	5,139.39	-	10.00
鹿児島県	A	16,204	2,460.25	-	10.00
島根県	B	30,917	1,263.01	128.22	10.15
千葉県	B	31,620	442.27	45.40	10.27
高知県	B	31,632	1,174.35	120.59	10.27
広島県	B	31,947	1,431.91	147.76	10.32
大阪府	B	32,672	150.57	15.71	10.44
山口県	B	35,444	968.92	105.32	10.87
和歌山県	B	36,644	773.80	85.52	11.05
徳島県	B	37,086	631.23	70.18	11.12

都道府県	グループ	相対誤差±10% を達成するた めに必要な サンプル数	推定伐採面積 (ha)	サンプル数 30,000点制約 下の誤差面積 (ha)	相対誤差 (%)
三重県	B	37,445	753.22	84.15	11.17
群馬県	B	40,899	428.85	50.07	11.68
岡山県	B	42,454	849.07	101.00	11.90
山形県	B	47,469	541.52	68.12	12.58
東京都	B	48,690	123.06	15.68	12.74
京都府	B	50,528	519.29	67.39	12.98
愛媛県	B	51,115	602.78	78.68	13.05
静岡県	B	51,485	667.27	87.41	13.10
埼玉県	B	53,020	166.03	22.07	13.29
長崎県	B	56,061	351.40	48.04	13.67
佐賀県	B	58,231	152.45	21.24	13.93
長野県	B	58,530	853.97	119.28	13.97
岐阜県	B	60,936	827.59	117.95	14.25
山梨県	B	61,120	427.91	61.08	14.27
鳥取県	B	64,352	276.49	40.49	14.65
愛知県	C	69,436	236.60	35.99	15.21
兵庫県	C	69,976	587.14	89.67	15.27
香川県	C	72,361	96.34	14.96	15.53
石川県	C	76,171	261.92	41.74	15.93
滋賀県	C	79,540	177.58	28.92	16.28
富山県	C	86,760	143.57	24.42	17.01
奈良県	C	109,788	190.46	36.43	19.13
神奈川県	C	113,757	58.87	11.46	19.47
沖縄県	C	130,011	50.55	10.52	20.82
新潟県	C	140,467	307.42	66.52	21.64
福井県	C	148,224	138.48	30.78	22.23

A グループは相対誤差±10%達成可能のためサンプル数 30,000 点制約下の誤差面積は算出していない。

本検討では、相対誤差方式および絶対誤差方式の双方について必要サンプル数の構造を整理し、さらに全国判読数 30,000 点という実務制約を踏まえた分析設計を行った。

その結果、本年度の分析からは以下の点が明らかとなった。

1. 相対誤差方式と絶対誤差方式は、都道府県規模によって有利・不利が逆転する構造を持つ。
2. 全国一律の精度設定は、必然的に一部の都道府県に過大なサンプル数負担を生じさせる。

3. 相対誤差±10%を基本目標としつつ、達成困難な都道府県については、30,000点制約下で実現可能な相対誤差水準（例えば10～15%、15%超）に基づき段階的に整理する方法が合理的であると考えられた<sup>15</sup>。

## ⑦ A I 技術等活用による推定の省力化に向けた検討

伐採面積推定に必要なサンプル地点の目視判読の一部の自動化等による作業時間の削減を目的として、衛星画像の時系列情報と機械学習（AI）による、伐採・非伐採の分類手法の適用可能性を整理した。

### i. 検討方法

#### ■ 使用データ

本検討で用いたデータ条件を表 24 に示す。全国一律で取得可能な衛星データを用い、雲量率の低い観測のみを利用した。

表 24 データ条件

衛星データ	Landsat、Sentinel-2
指標	NDVI、NBR
空間単位	10m メッシュ（全国一律条件）
時系列期間	以下の2つの期間で、月次で検討 ・2019年～2022年（48ステップ） ・2016年～2022年（84ステップ）
雲量条件	雲量率10%以下、90%以下の2つのパターン 試す（図29、本文中の説明参照）
備考	指数は物理範囲外（-1～1外）を除去

※NDVIは植生活性、NBRは焼失・伐採等の変化検出で利用されることが多い指標である。

<sup>15</sup> Cグループについては誤差面積が小さいので、絶対誤差を精度設定に利用することも考えられる。

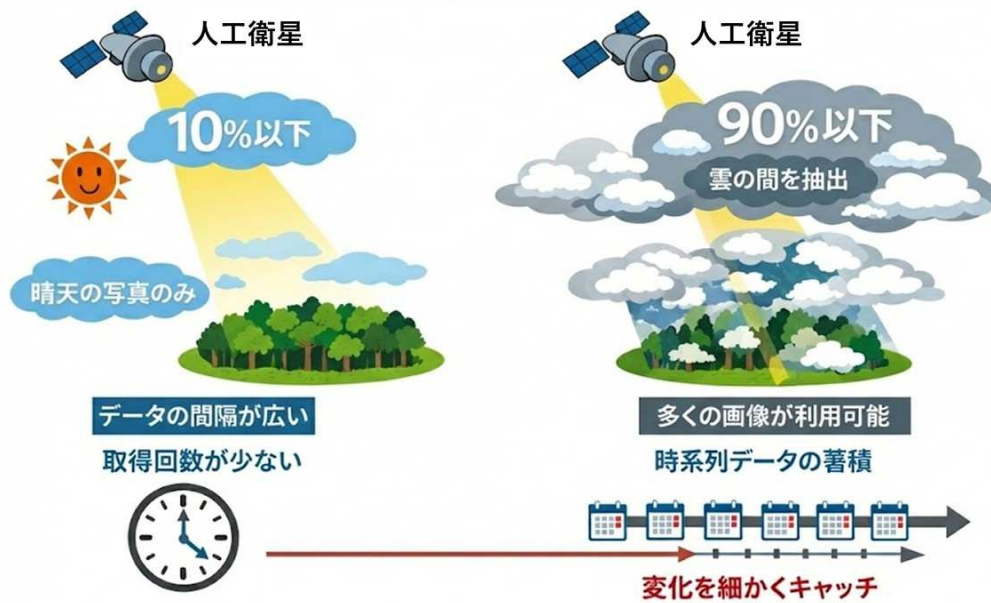


図 29 雲量率 10%以下と 90%以下の違い

図 29 は、雲量率 10%以下と 90%以下の違いを、単画像の見え方の差ではなく、時系列解析で利用可能な観測データ量の差として示したものである。雲量率 90%以下では雲を含む画像も対象となるが、時系列でみると雲のない観測部分を積み上げることができるため、利用可能なデータ量が増え、変化把握の精度向上につながる場合がある。

#### ■ 前処理（時系列化・欠損処理）

各地点について、衛星画像から算出した NDVI/NBR の観測値を月次で集計し、時系列データとして整理した。本検討では、外れ値の影響を受けにくいことから、月内の代表値として中央値 (median) を採用した。雲・雲影・雪などの影響を低減するため、各衛星プロダクトに付随する品質バンド (Quality band) を用いて該当画素をマスクし、解析対象から除外した。指数の物理範囲 (-1~1) を外れる値は、計算誤差やノイズの可能性が高いため欠損値として扱い除外した。

各月の有効観測回数 (n) を付加し、観測密度 (観測の多さ/少なさ) の違いをモデル入力に反映した。具体的には、n を  $\log_{1p}(\log(1+n))$  変換してスケール差を緩和し、観測回数が多き月と少ない月の情報を学習に取り込めるようにした。

図 30 は、対象地点における NDVI の月次推移を示したグラフの例である。青点は Landsat、橙点は Sentinel-2 の観測値を表す。両衛星の観測が得られる期間では、同一月に複数の観測値がプロットされており、衛星間の差異や観測タイミングの違いを確認できる。折れ線は、本検討の時系列解析で用いた月次代表値 (その月の全衛星観測データの中央値) を示している。これにより、植生活性の季節変動 (高 NDVI 期・低 NDVI 期) や年ごとの変動傾向を把

握ることが可能である。なお、雲・雲影等の影響により有効観測が得られない月は欠損として扱うため、観測点の密度には月・年によってばらつきが生じる。

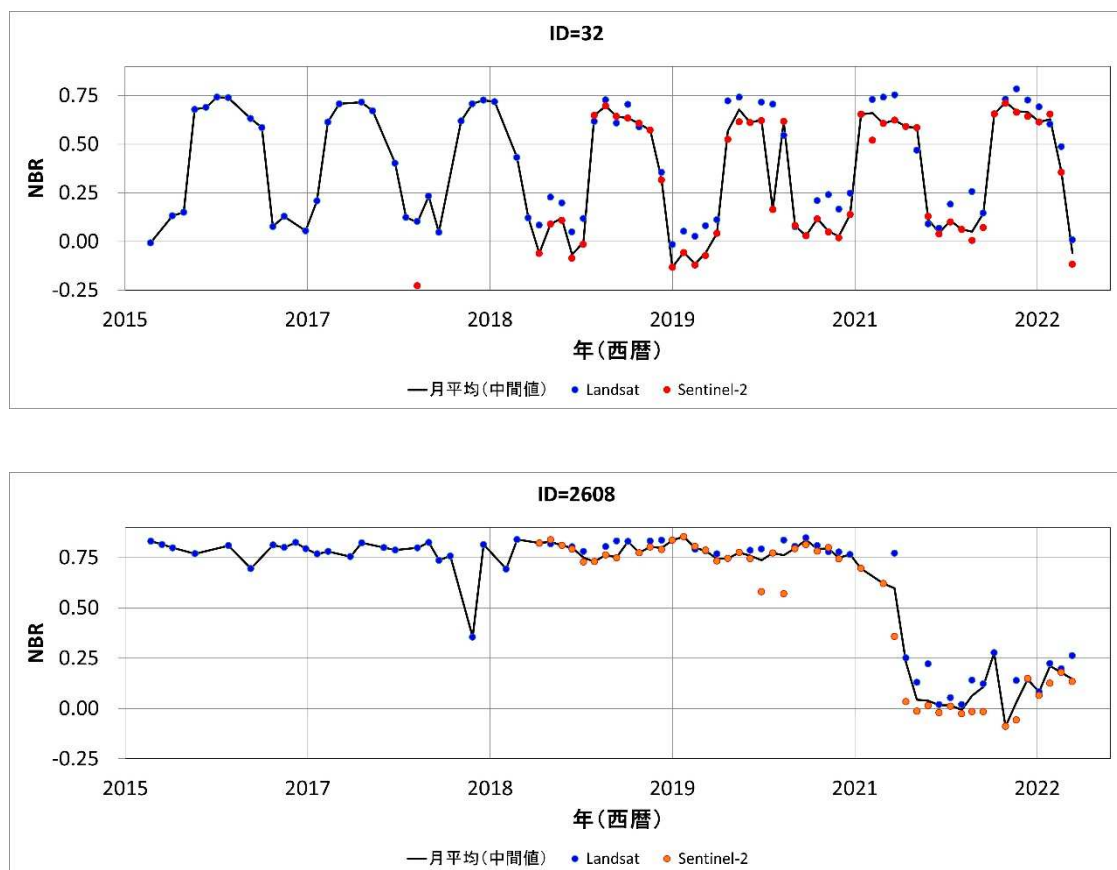


図 30 NDVI の月次時系列グラフ

青点は Landsat、橙点は Sentinel-2 の各月の観測値、折れ線は全観測の中央値を示す。

上：森林サイト、下：伐採サイト

### ■ カテゴリ定義と教師データ

本検討では、令和 6 年度調査において実施された、目視判読による 32,000 地点の 7 クラス分類結果を、教師/評価データとして用いた。その上で、実運用における判別目的（森林か否か）を明確化するため、表 25 に示す 2 クラス（森林/その他）へ再編し、二値分類として解析を行った。ここで「その他」には、伐採（帯状択伐を含む）に加え、伐採以外の森林変化、非森林、判読不能等を含めている。

また、32,000 地点のうち品質面の観点から一部データを除外した上で、**14,004 地点 (ID: 偶数)** を教師データ、**15,489 地点 (ID: 奇数)** を評価データとして用いた。教師データと評価データを ID の偶奇で分割することで、データの重複や偏りを抑えつつ、独立した検証が可能となるよう配慮した。

表 25 カテゴリ定義

区分	定義
変化なし	2021年・2022年ともに伐採等の森林変化がなかった地点
伐採等	伐採：2021年または2022年に伐採（帯状択伐を含む）
	その他：2021年または2022年に伐採以外の森林変化、非森林、判読不能等を含む

## ■ 方法

### ・分類手法① LSTM Autoencoder（教師なし）

教師なし学習として、時系列の再構成誤差を用いて異常（変化）を検知する LSTM<sup>16</sup> Autoencoder を試行した。伐採のような急変を「異常」とみなす想定である。

しかし、本データ条件ではクラス分離が十分でなく、実運用に耐える精度を得ることができなかった。要因として、(i) 雲等による欠損の影響、(ii) 伐採以外の変化が多様であること、(iii) 教師なしでは閾値調整が難しいこと、などが考えられる。LSTM モデルについての詳細な説明と、簡単な結果を⑦-iv 付録に示す。

### ・分類手法② 1D CNN（教師あり・1次深層学習）

教師あり学習として、月次時系列を入力とする 1次元 CNN（1D CNN）<sup>17</sup>を用いて分類を行った。1D CNN は計算が軽く、大量データに適用しやすい利点がある。入力には各月の指数値（標準化）に加え、観測回数（n）および欠損マスクをチャンネルとして付与した（時系列長 T×チャンネル数 C のテンソル）。学習・評価は、地点 ID の偶奇などで訓練/検証に分割する方式を参考にしつつ、実データでは訓練 80%、検証 20%のホールドアウトを基本とした。1D CNN モデルについての詳細な説明と結果を⑦-iv 付録に示す。

## ■ 閾値運用（精度優先の考え方）

本検討では、AI 判定の確率（確信度）に対して閾値を設定し、誤判定を極力抑える運用を想定した。たとえば「〔変化なし〕と判定する場合は非常に高い確信度が得られた地点のみ自動確定」とし、それ以外は目視判読に回すことで、全体作業量を削減しつつ品質を担保する。

<sup>16</sup> 時系列の「前後関係」を覚えて読む AI（例：今の値だけでなく、「その前に何が起きていたか」も見て判断する）

<sup>17</sup> 時系列データ（時間の順に並んだデータ）から、「似た変化の形」や「特徴的な動き方」を自動で見つける AI 手法。たとえば、植生指数の値そのものだけでなく、「いつ下がったか」「どれくらい急に変わったか」「その後どう戻ったか」といった変化のパターンを捉えて、分類に活用する。

## ii.結果

### ■ 検証データ概要

検証に用いた地点数は 15,489 である。衛星 (Landsat、Sentinel-2) の双方を利用し、平成 28 (2016) /令和元 (2019) ~令和 4 (2022) 年の月次時系列を作成した。

### ■ 主要結果 (精度優先の判定例)

表 26 に、平成 28 (2016) ~令和 4 (2022) 年のデータを使って得られた結果を示す。判定閾値の設定により、「〔変化なし〕として自動判定できる地点数 (自動確定数)」と「〔変化なし〕判定の確からしさ」のバランスは大きく変化する。代表例として、NBR (雲量 90% 以下) を用いた場合、次の傾向が確認された。

- **User's 精度 (森林判定の確からしさ) を最優先**した閾値設定では、森林として自動判定できる地点数は限定される一方、森林判定の適合率は 100% となった。例えば、NBR を用い、雲量 90% 以下の時系列データを入力とした条件では、森林サイト 13,986 地点のうち 1,700 地点を誤判定なし (確度 100%) で森林として検出できた。
- **全体精度を重視**した閾値設定では、森林と自動判定される地点数が 13,749 点と増加し、森林判定の適合率は 97.1% となった。

実運用においては、目視判読に回す地点数 (作業量) と、誤判定リスク (取り違い) の許容範囲を踏まえ、目的に応じて判定閾値を設計・調整する必要がある。また、雲量条件を **10% 以下** と **90% 以下** で比較した。雲量率 90% 以下では雲を含む画像も対象となるが、時系列でみると雲のない観測部分を積み上げることができるため、利用可能なデータ量が増え、変化把握の精度向上につながる場合がある (図 29)。今回のケースでは、雲量率、90% 以下のデータまで利用した方が、全体精度としては **やや良好** な結果が得られた。一方で、約 31,000 地点の NBR 時系列データを Google Earth Engine 上で作成する処理時間は、雲量 10% 以下では概ね **1~2 日程度** であるのに対し、雲量 90% 以下では **2~4 日程度** と増加する。これは、利用対象となる画像数 (処理対象データ量) が増加するためである。したがって、雲量条件の設定にあたっては、得られる精度向上の程度と処理時間 (運用負荷) を比較し、**時間対効果を考慮した運用設計** を行うことが重要である。

表 26 雲量条件別検出結果

		目視判 読結果	NBR (雲量 10%以下)			NBR (雲量 90%以下)		
			検出		P. 精度*	検出		P. 精度
			森林	非森林		森林	非森林	
User's 精度 優先	森林	13,986	1,506	12,480	10.8%	1,700	12,286	12.2%
	非森林	1,503	0	1,503	100%	0	1,506	100%
	U. 精度**	-	100%	10.7%	19.4% (全体精度)	100%	10.9%	20.7% (全体精度)
	閾値***	-	0.902			0.99993		
全体 精度 優先	森林	13,986	13,685	301	97.8%	13,749	237	98.3%
	非森林	1,503	402	1,101	73.3%	414	1,092	72.5%
	U. 精度	-	97.1%	78.5%	95.5% (全体精度)	97.1%	82.2%	95.8% (全体精度)
	閾値	-	0.533			0.246		

\* P. 精度：Producer's 精度 \*\* U. 精度：User's 精度 \*\*\* 1D CNN が出力する「森林である確率（スコア）」に対する判定境界。スコアが閾値以上の地点を「森林」、未満を「その他」と判定した。

## ■ 考察

### (1) 指標 (NDVI/NBR) による差

NDVI を用いた場合の結果を表 27 (NDVI、解析期間：平成 28 (2016)～令和 4 (2022)年) に示す。NBR を用いた場合 (表 26) と比較すると、判別性能はやや低下した。NBR は近赤外 (NIR) と短波赤外 (SWIR) の反射特性を組み合わせた指標であり、伐採や焼失に伴う植生量の減少や含水状態の変化を捉えやすい特性を持つ。このため、伐採等の森林変化を含むクラス判別において、NDVI よりも有利に作用した可能性がある。

表 27 NBR と NDVI データを用いた結果比較

		目視判読結果	• NBR • 雲量 10%以下 • 解析期間：2016～2022 年			• NDVI • 雲量 10%以下 • 解析期間：2016～2022 年		
			検出		P. 精度	検出		P. 精度
			森林	非森林		森林	非森林	
全体精度優先	森林	13,986	13,685	301	97.8%	13,906	80	99.4%
	非森林	1,503	402	1,101	73.3%	1,194	309	20.6%
	U. 精度		97.1%	78.5%	95.5% (全体精度)	92.1%	79.4%	91.8% (全体精度)

### (2) 時系列長の影響

解析期間を令和元（2019）～令和 4（2022）年に短縮した場合の結果を表 28（NBR、雲量 10%以下）に示す。平成 28（2016）～令和 4（2022）年の時系列を用いた場合（表 26）と比較して、性能が数%程度低下する傾向が確認された。要因としては、①解析対象期間が短くなることで長期的な季節変動・年変動の情報量が減少すること、②教師データにおいて令和元（2019）年以前の有効観測（学習に寄与する時系列情報）が相対的に少なく、結果としてモデルが「森林らしい時系列パターン」を十分に学習しにくくなる可能性があること、が考えられる。

表 28 平成 28（2016）～令和 4（2022）年と令和元（2019）～令和 4（2022）年時系列データを用いた結果比較

		目視判読結果	• NBR • 雲量 10%以下 • 解析期間：2016～2022 年			• NBR • 雲量 10%以下 • 解析期間：2019～2022 年		
			検出		P. 精度	検出		P. 精度
			森林	非森林		森林	非森林	
全体精度優先	森林	13,986	13,685	301	97.8%	13,587	397	98.3%
	非森林	1,503	402	1,101	73.3%	423	1,078	72.5%
	U. 精度		97.1%	78.5%	95.5% (全体精度)	97.0%	73.1%	94.7% (全体精度)

### (3) 教師データの品質

ラベル誤りや判読が困難な地点（境界域、混合画素等）が混在すると、学習が不安定になり、閾値を厳しく設定しても誤判定が残る可能性がある。教師データの品質管理（判読困難点の除外、ラベル再点検等）は、精度向上の前提条件となる。

#### (4) 衛星差と観測密度：

Landsat と Sentinel-2 は空間分解能・観測頻度が異なり、月によって有効観測数に偏りが生じる。観測回数 (n) を入力に含める設計は、観測密度の違いをモデルが考慮できる点で、両衛星の差異や欠損の影響を吸収するうえで有効である可能性がある。

#### ■ 省力化効果の概算

本節では、AI 判定を業務フローに組み込んだ場合に期待される省力化効果について、概算の考え方を整理する。実際の省力化量は、対象地域の特性、目視判読ルール、判定閾値の設定、ならびに後工程での差し戻し（再確認）の発生状況等によって変動するため、最終的には運用試行を通じて把握・確定する必要がある。

基本方針としては、(i) 誤判定リスクを抑える観点から、AI により高い確度で判定できる地点のみを「自動確定」とし、(ii) **それ以外の地点は従来どおり目視判読に回す運用**を想定する。すなわち、AI は「すべてを代替する」ものではなく、**確度の高い地点を先に確定して目視対象を絞り込むための補助**として位置付ける。

##### 省力化の評価指標（例）

- **自動確定率**：全地点のうち、AI で自動確定できる割合
- **目視削減率**：目視判読の対象から除外できた割合（多くの場合、自動確定率と同義）
- **自動確定の誤判定率**：自動確定した地点における誤判定の割合（= 1 - User's 精度）
- **再判読率**：後工程で差し戻しとなり、追加確認が必要となった割合（運用により計測）

表 29 は、判定閾値の設定によって「自動確定数（＝目視削減の規模）」と「想定精度（Precision）」がどのようにトレードオフとなるかを、**目視判読に要する時間の概算**として示したものである。「全て目視判読」は AI を用いない基準ケースであり、総判読時間が最大となる一方、判読精度は目視判読ルールに依存する（人的ミスは 0% になり得ないため約 99% 程度と記載）。これに対し、「User's 精度優先」では自動確定数は限定されるが、森林判定の確からしさ（User's 精度）を 100% に近づけられる。一方、「Producer's 精度考慮」では自動確定数が大幅に増え、目視判読時間の削減効果は大きい。しかし、User's 精度は 97.1% に留まり、特に非森林層での誤判読は推定結果への影響が大きく（P53 表 16 参照）、目視判読の代替手段として用いるには、精度面で課題が大きい。

いずれの用途においても、実運用に向けては、さらなる精度向上が必要となるが、例えば User's 精度と Producer's 精度のバランスする閾値を求められれば、将来的なピクセルカウントによる面積推定に繋がることも期待される。

#### 概算例

検証データ 15,489 地点に対し、精度最優先の閾値設定により森林と自動判定できた地点数が 1,700 地点であった場合（表 29、NBR(雲量 90% 以下)のケース）、自動確定率は約 11.0% となる。ここで、業務全体で扱う判読対象が 32,000 地点、1 地点あたりの目視判読

時間を平均 30 秒と仮定すると、削減可能な作業時間は約 29.3 時間 (= 32,000 × 0.110 × 30 秒) と概算される (表 29)。

一方で、判定閾値を緩めて自動確定数を増やせば、目視削減効果は拡大する可能性があるが、同時に誤判定リスク (= 1 - User's 精度) も増大し得る。したがって、実運用では、誤判定の許容度 (業務要件) と目視削減効果 (省力化量) のバランスを踏まえ、閾値を段階的に調整しつつ、再判読率や後工程での差し戻し状況も含めて評価することが重要である。

なお、User's 精度と自動確定数の関係は図 31 のとおりであり、仮に User's 精度 99% (仮) までは許容すると仮置けば自動確定率は 84.9% 程度となり、判読時間削減効果は大きくなる。人的ミスが 0% になり得ないことを鑑み、どこかで割切することも目視判読の省力化に向けて必要な観点の一つと考えられる。




図 31 User's 精度と自動確定数の関係

表 29 参考：閾値設定による省力化のイメージ（例）

シナリオ	自動 確定数	自動 確定率	目視判読 想定時間 (時間)	削減可能 時間 (時間)	想定精度
全て目視判読	0	0	266.7		~99%
一部 AI/Us 精度優先	3,512	11.0%	237.4	29.3	100%
閾値で Us 精度 99%に調整	27,170	84.9%	40.3	226.4	99%
閾値で Us 精度 98%に調整	28,042	87.6%	33.0	233.7	98%
一部 AI/Ps 精度考慮	28,405	88.8%	30.0	236.7	97.1%

### iii. 課題

本手法を実運用へ展開するためには、主に以下の課題への対応が必要である。

1. 教師データ品質が精度を大きく左右するため、誤ラベル、位置ずれ、判読不能点などの管理を徹底し、学習データからの除外・再ラベリングを含む品質管理プロセスを確立する必要がある。
2. AI で判読が難しい地点が目視でも判読困難であるかを分析し、判読困難点の抽出や優先度付けに活用できる枠組みを整えることが重要である。
3. 1 ピクセル点の時系列情報のみでは伐採境界や小規模変化の表現に限界があるため、周辺テクスチャを含む時系列チップを入力とした 2 次元 CNN 等への拡張を検討し、空間情報を取り込んだ精度向上を図る必要がある。
4. 運用設計として、閾値ごとの「自動確定率」「目視削減率」「誤判定率」を整理し、業務要件（誤判定許容度、見落とし許容度、処理量）に合致する設定を定量的に提案できるようにすることが求められる。加えて、実際の業務フローに適用した際の作業時間削減量を定量評価し、省力化効果を根拠として提示できるようにすることが期待される。

### iv. 付録

#### ■ LSTM Autoencoder（教師なし）手法と結果

図 32 に、本検討で用いた LSTM Autoencoder のアーキテクチャを示す。本手法は、NDVI/NBR などの時系列データ（系列長 T、特徴量数 F）を入力として受け取り、時系列パターンを一旦圧縮（エンコード）したうえで復元（デコード）することで、入力系列が「学習し

た典型的パターン（本検討では主に森林に相当）」にどの程度適合するかを、復元誤差に基づく異常度（異常スコア）として評価する仕組みである。すなわち、復元誤差が小さいほど森林の時系列パターンに近く、誤差が大きいほど森林以外（伐採・その他等）の可能性が高いと解釈される。

入力時系列はまず Masking 層により欠損（雲・雲影・雪等により値が得られない月）を 0 として扱い、欠損値の影響を受けにくい形で学習を行う。エンコーダ側では LSTM（64 ユニット→32 ユニット）により時系列情報を段階的に要約し、次元 32 の潜在空間(latent space)へ圧縮する。デコーダ側では RepeatVector によって潜在表現を系列長 T に展開した後、LSTM（64 ユニット）および TimeDistributed Dense により各時刻の値を復元し、再構成系列を出力する。損失計算では、雲マスク<sup>18</sup>等に基づく重み付け（sample\_weight）を用いることで、欠損月の寄与を実質的に除外した「マスク付き損失（Masked Loss）」により復元誤差を算出する。

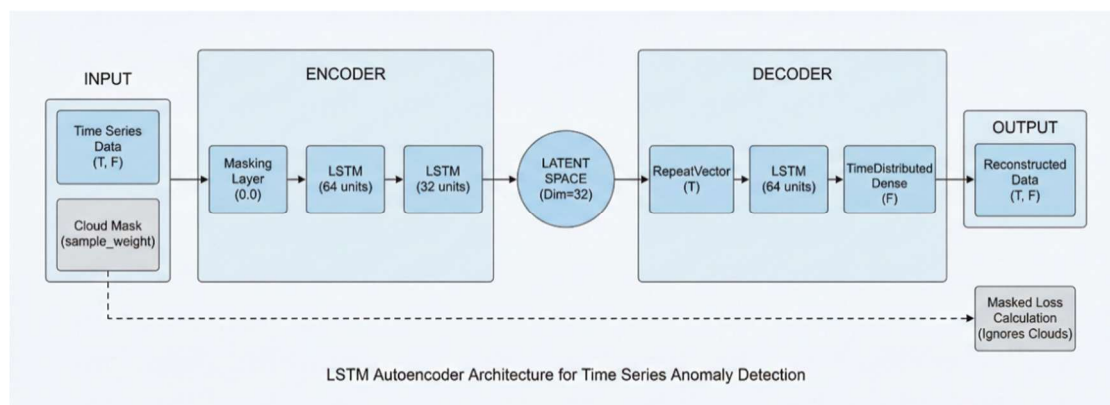


図 32 LSTM Autoencoder アーキテクチャ

図 33 は、クラス別（森林／伐採／その他）における復元誤差（異常スコア）の分布をヒストグラムで示したものである。一般に、スコアが 0 に近いほど入力系列が典型パターンに適合し、森林である可能性が高いと期待される。一方、伐採やその他は森林の時系列パターンから外れる場合が多く、相対的に高い誤差側へ分布が広がる傾向が見られる。ただし、本結果では森林とそれ以外の分布が一部重なっており、赤の破線で示すような閾値を設定しても誤判定（取り違え）が一定程度生じ得る。このことから、復元誤差のみを用いた単純な閾値判定では、十分に高い分類精度を得ることは難しいと結論付ける事ができる。

<sup>18</sup> 衛星データの品質情報を用いて雲・影・雪等の影響を除外する処理




図 33 分類別の異常スコアのヒストグラム

■ 1D CNN (教師あり)

図 34 に、本検討で用いた一次元畳み込みニューラルネットワーク (1D CNN) のアーキテクチャを示す。入力は、各地点の NDVI または NBR の月次時系列であり、期間平成 28 (2016) /令和元 (2019) ~令和 4 (2022) 年に対応する系列長は **T=84/48** である。モデル前半では、**Conv1D 層 (Filters=32, Kernel=3)** により、3 か月程度の短い時間窓で生じる変化パターン (急激な低下や回復など) を抽出する。続く **Conv1D 層 (Filters=64,**

**Kernel=3**) は、より多様で複雑な局所パターンを捉える役割を担い、特徴表現を強化する。次に **Global Average Pooling** により、時系列方向に分布する特徴量を平均化して固定長ベクトルへ集約し、入力長に依存しない表現へ変換する。最後に **Dense (Sigmoid)** を用いて 0~1 の出力を得て、二値分類（森林／その他）を行う。Conv1D を用いることで、季節変動に重なる伐採等の変化（局所的な落ち込み・回復）を効率的に学習できる点が特徴である。また、時系列を直接入力できるため、複雑な特徴量設計を最小限にしつつ判別モデルを構築できる。




図 34 1 DCNN アーキテクチャ

## 4.2. 行政情報の集計等による推定手法との比較検証

昨年度と同様に、伐採面積の推定方法のうち、従来から用いられている行政情報を用いた民有林の伐採面積を推定する以下 2 通りの方法について整理した。

### (ア) 行政手続の積み上げによる推計

都道府県毎に集計した、森林法に基づく伐造届出書等（伐造届出書、緊急伐採の事後の伐採届出、経営計画に基づく伐採届出、保安林立木伐採許可・事前届出、林地開発許可）の行政手続に記載された主伐面積の積み上げにより推計する方法である。なお、重複計上を回避するため、経営計画に基づく伐採届出のうち、保安林立木伐採許可・事前届出の面積は、積み上げから除外している。

### (イ) 木材供給量からの推計

木材需給表の「国内生産」を基に、間伐材利用量・国有林出材量を差し引いて算出した民有林主伐材積から、別途得られた平均蓄積を換算係数として割り戻すことにより伐採面積を推計する方法であり、森林・林業統計要覧において「立木伐採面積」として公表されている。

### ① 伐採造林届出等の行政情報に基づく推定

林野庁において整理された平成 28 (2016) 年度から令和 5 (2023) 年度までの推計結果を表 30 に示す。期間を通して概ね 50,000~55,000ha の値で推移している。

行政情報の積み上げによる集計方法は、実際の伐採が行政手続を行った翌年以降に行われる「時間差」や、手続を行ったものの伐採は実行されない「不実行」といった、不確実な要素が一定数含まれ、実際に生じている伐採面積との乖離は必ず生じる。このうち「時間差」については、毎年度の発生割合が一定と仮定すれば、年度間で相殺すると考えることも可能だが、「不実行」については年度間で相殺されることはないため、推計値はその分過大となっている可能性がある。

特に宮崎県・鹿児島県など南九州地域では、無届伐採を回避するため、伐採する可能性のある箇所について幅広く伐造届出を出す傾向にあり、地域別に評価する場合には過大傾向となる点に留意が必要である。

また、行政手続のうち伐採造林届出に記載する面積は、実測面積とはされていないことから、実際に生じている伐採面積をどの程度的確に捉えられているかは不透明である。

表 30 伐採造林届出等の行政手続きの積み上げによる推計結果

推計方法	平成 28 (2016)	平成 29 (2017)	平成 30 (2018)	令和元 (2019)	令和 2 (2020)	令和 3 (2021)	令和 4 (2022)	令和 5 (2023)	令和 6 (2024)
行政手続 積み上げ ベース	49,871	50,139	52,263	52,082	48,211	51,558	49,412	46,086	47,908

## ② 木材供給量からの換算による推定

手順は以下の通りである。

- ・ 木材需給表における国内生産量から間伐材利用量を差し引き、主伐材積を計算
- ・ 主伐材積から国有林分を差し引き、民有林主伐材積を計算
- ・ 民有林主伐材積を、林野庁業務参考資料から推定した単位面積当たりの立木材積（ $\text{m}^3/\text{ha}$ ）で割り戻し、民有林の主伐面積を推計する

森林・林業統計要覧から平成 28（2016）年度～令和 5（2023）年度の民有林における立木伐採面積を抜粋すると、表 32 の上段のとおりである。概ね 70,000～90,000ha の間で推移しており、①行政手続積み上げベースの推計値に比べ、20,000 ha 程度大きく推計されている。

昨年度の検討では、この要因として、主伐材積を面積に割り戻すための換算係数として用いている単位面積当たり立木材積が、現地実態にくらべて過小であることが指摘されており、現地実測データである森林生態系多様性基礎調査（NFI）のデータを用いて見直しを検討している。

具体的には、NFI 第 3 期、第 4 期、第 5 期の 11 齢級以上の人工林の平均蓄積を算出し、各年に割り当てる換算蓄積については、以下のように処理した。

- ① 各期の平均蓄積を、調査期の中間年である各期の 3 年目に位置づける（例：第 4 期であれば平成 28（2016）年度）
- ② 各期の 1 - 2 年目は、前期と今期の差分を 5 か年で按分した値を前年値に加算する（例：第 4 期の 1-2 年目（平成 26（2014）、平成 27（2015）年度）は、第 4 期平均蓄積 483.7 m<sup>3</sup>/ha と第 3 期平均蓄積 459.0 m<sup>3</sup>/ha の差分 24.7 m<sup>3</sup>/ha を、平成 26(2014)年度は第 3 期平均蓄積 459.0 m<sup>3</sup>/ha に 3/5、平成 27（2015）年度は 4/5 それぞれ加算する）
- ③ 各期の 4 - 5 年目は、今期と次期の差分を 5 か年で按分した値を前年値に加算（例：第 4 期の 4-5 年目（平成 29（2017）、平成 30（2018）年度）は、第 5 期平均蓄積 521.7 m<sup>3</sup>/ha と第 4 期平均蓄積 483.7 m<sup>3</sup>/ha との差分 38.0 m<sup>3</sup>/ha を、平成 29（2017）年度は第 4 期平均蓄積 483.7 m<sup>3</sup>/ha に 1/5、平成 30（2018）年度は 2/5 それぞれ加算する）
- ④ 5 期の 4 - 5 年目は、次期（6 期）の値がないことから、第 4 期～第 5 期の蓄積増減の傾向がそのまま続くものとして、②の方法で暫定的に外挿処理

その結果を踏まえて見直した換算係数（表 31）により再度推計した結果を表 32 の下段に示している。NFI 換算係数を用いた推計値は 50,000～60,000 ha と、行政手続ベースの推計値や衛星判読による推定値と同程度か、やや大きい傾向となり、従来の換算係数に比べ、主伐対象林分の立木材積を的確に捉えていると考えられる。

表 31 年別の NFI 蓄積による換算値


NFI 調査期	各期の調査年目	年	NFI 蓄積換算地 (m <sup>3</sup> /ha)	前期との差分	処理方法
3 期	1 年目	平成 21(2009)	-		-
3 期	2 年目	平成 22(2010)	-		-
3 期	3 年目	平成 23(2011)	459.0	-	①
3 期	4 年目	平成 24(2012)	463.9		③
3 期	5 年目	平成 25(2013)	468.9		③
4 期	1 年目	平成 26(2014)	473.8		②
4 期	2 年目	平成 27(2015)	478.8		②

4期	3年目	平成28(2016)	483.7	24.7	①
4期	4年目	平成29(2017)	483.7		③
4期	5年目	平成30(2018)	483.7		③
5期	1年目	令和元(2019)	491.3		②
5期	2年目	令和2(2020)	498.9		②
5期	3年目	令和3(2021)	521.7	38.0	①
5期	4年目	令和4(2022)	529.3		④
5期	5年目	令和5(2023)	536.9		④

表 32 木材供給量からの推計結果

推計方法	平成28 (2016)	平成29 (2017)	平成30 (2018)	令和元 (2019)	令和2 (2020)	令和3 (2021)	令和4 (2022)	令和5 (2023)	令和6 (2024)
木材供給量 ベース (従来)	66,753	73,508	76,100	77,577	79,365	82,122	87,835	81,969	NA
木材供給量 ベース (NFI換算)	46,543	52,122	54,251	53,740	56,669	59,034	62,550	59,485	NA

### 4.3. 衛星判読による推定と行政情報の比較検証



衛星画像 R6+7 事業成果の各年度に示されている縦線は 95%信頼区間における誤差面積

図 35 推計/推定伐採面積の推移

#### ① 年次推移の全体像

図 35 は、2017 年（平成 29 年。以下 H29（2017）という）から 2024 年（令和 6 年。以下 R6（2024）という）までの以下の推計/推定伐採面積を併せて示したものである。

- 行政情報を用いた推計値【行政手続きベース】
- 森林・林業統計要覧での伐採立木面積【木材供給量ベース（従来）】
- R6 事業と本年度調査を統合した衛星画像による推定値【衛星画像 R6+7 事業成果】
- 森林・林業統計要覧での伐採立木面積を、NFI 換算係数を用い調整した値【木材供給量ベース（NFI 換算）】
- メリーランド大学地利科学科に設置された研究所（Global Land Analysis and Discovery (GLAD)）が提供している Global Forest Change データセットの森林被覆減少データ【GLAD】

まず概観すると、

- 行政手続きベースによる推計値は比較的安定し推移
- 木材供給ベース（NFI 換算）は安定的に概ね上昇傾向。
- 衛星推定値は年ごとの増減がやや大きい
- GLAD の森林被覆減少データは、衛星推定値と類似した変動傾向を示していることが確認できる。

## i. H29（2017）年の衛星推定値の解釈

H29（2017）の衛星推定値は他の推計/推定値と比較して特出して低い。この要因としては、実際の年変動の可能性もあるが、判読に用いる画像が十分に確保できなかったことの影響が大きいと考えられる。

本事業では Sentinel-2 画像を用いて H29（2017）-R2（2020）の伐採/非伐採を判読したが、Sentinel-2A は 2015 年 6 月、Sentinel-2B は 2017 年 3 月打上げであり、H29（2017）は観測機会が相対的に少なく、判読に必要な前年（H28（2016））の画像はさらに限られていた。すなわち、H29（2017）は判読に必要な画像条件が十分に整っていなかった年である。

その結果、H29（2017）の 95%信頼区間の幅は推定面積に対して 14%と、他年（概ね 12%程度）より大きく、不確実性も相対的に高い。以上より、H29（2017）の本事業の衛星利用による推定値については、画像の制約により精度が低下している可能性が高い。

## ii. 各推計/推定値の年毎の変動傾向の類似・相違の解釈

### ■ 衛星推定値と GLAD データとの類似性

GLAD が提供する Global Forest Change データセットは Landsat を用いて森林変化を抽出したものである。なお、当該データセットの森林被覆減少面積は、機械判読により森林被覆が減少したと判読された箇所の面積を単純に積み上げる方法（ピクセルカウント）により算出されていることから、中央値の比較には留意が必要であるが、年次毎の変動傾向の比較には一定の有効性があるものとする。

図 35 を見ると衛星推定値と森林被覆減少データの動きは、

- 年ごとの上下動の方向性
- R3（2021）前後の落ち込み
- R4（2022）以降の回復傾向

について、概ね整合的である。森林被覆減少データが、本事業とは

- 異なるアルゴリズム、
- 異なるデータ処理体系

に基づいて作成されているにもかかわらず、衛星推定と類似したトレンドを示していることは、単なる統計的偶然ではなく、一定の実態変動を反映している可能性がある。

### ■ 行政手続データと衛星推定値の相違性

一方で、行政手続きベースの推移は、衛星推定値と比較すると、変動幅が小さく、相対的に平滑な推移を示している。また、変動幅には差があるものの、変動方向に着目すると、以下の点が観察される。

- 行政手続きベースの推計では、H30（2018）から R2（2020）にかけて緩やかに減少し、R3 に増加に転じている。
- 衛星推定値では、R1（2019）から R3（2021）にかけて減少し、R4（2022）に増加に転じている。

以上のところから、衛星推定値の変動傾向は行政手続きベースに 1 年遅れて表れているようにも観察できる。この差の背景として、以下の構造的要因が考えられる。

#### (1) 年度区切りの違い

- 行政データは年度集計（4 月～翌年 3 月）
- 本事業の衛星推定は展葉期（主に 5～10 月）の合成した衛星画像の比較に基づいており、推定期間は概ね 11 月～翌年 10 月となる。

例えば、同じ「R3（2021）」として比較しても、実質的比較している期間には必ずずれが生じる（図 35 参照）。

#### (2) 冬季伐採の翌年反映

R6 年度調査における R3（2021）～R4（2022）年の推定に際し、目視判読結果から伐採月の発生頻度を整理したところ、伐採は 1～3 月に多く、7～9 月は少ない傾向が確認された（図 36）。すなわち、伐採活動は冬季に集中する傾向がある。

次に、衛星推定、木材供給ベース、行政手続きベースの推計対象期間を比較すると（図 36）、同一年次における対象期間の始期は、衛星推定→木材供給ベース→行政手続きベースの順で遅くなる構造となっている。

この結果、特に伐採が集中する 1～3 月の伐採の含まれる年次が推定/推計方法間で異なり、具体的には、R4（2022）年 1～3 月の伐採は、行政手続きベースでは R3（2021）年推計値に含まれる一方、衛星推定では R4（2022）年推定値に含まれる。このため、冬季（1～3 月）の伐採面積に年次間の差が大きい場合、行政手続きベースの変動が R3（2021）年推計値として現れ、衛星推定では R4（2022）年推定値として、見かけ上遅れて現れることになる。

これは前述の、図 35 において、衛星推定値の変動傾向が行政手続きベースに 1 年遅れて表れて観察されて見えることと整合的である。

さらに、行政手続きベースには事前届出に基づく集計が約半数を占めており、実際の伐採実施時期よりも早い年度に計上される傾向があり、行政推計値が衛星推定値に先行して変動する傾向を強める要因となり得る。




図 36 衛星推定、木材供給ベース、行政手続ベースの推計対象期間と伐採発生頻度

以上より、図 35 において観察される推計/推定値による年変動の違いは、冬季伐採の年次配分の違いに起因する構造的なずれとして説明できる。

特に R3 (2021) は、コロナ禍およびいわゆるウッドショック期に該当し、近年の木材市場の動きとしては特異的な時期だったことに注目したい。図 37 に示すとおり、R3 (2021) 年 4 月以降、スギ原木価格は急騰し、その高値は R4 (2022) 年 3 月においても継続している。

## 木材価格情報-1 スギ原木の主要市場価格

- 例年であれば春から梅雨時期にかけては原木価格が下落する時期にもかかわらず、2021年に入ってから4月以降、価格が上昇。その後も高い水準で推移。
- 直近のスギ原木価格は、前年同期比116%から137%となっている。




図 37 スギ原木の需要価<sup>19</sup>

伐採が集中する傾向にある1～3月を比較すると、R4（2022）年1～3月は高値水準が維持されていた期間にあたり、前年同期に比べ伐採量が増加していた蓋然性が高いと考えられる。このため、R3（2021）における衛星推定値と行政手続きベースの変動の相違は、ウッドショックによる価格急騰期の伐採動向が反映されたものとすると考えて矛盾はない。

なお、ウッドショックのような急激かつ大幅な材価変動は希有な事象であり、通常想定される範囲の材価変動に伴う伐採量の増減であれば、1～3月期の年次間の伐採量の違いは年次間で相殺されると考えられる。この点において、本事業で試行した衛星推定値が実際の伐採傾向を捉えられているかの評価にあたり、偶然ではあるが、正に好機であったといえる。

以上のことから、行政手続きベースの推計値と衛星推定値の違いを以下のように整理する。

1. 衛星推定値は、行政手続きベースよりも年変動が大きい。
2. GLADの森林被覆減少データと衛星推定値は、類似の変動傾向を示す。

<sup>19</sup> 林産物に関するマンスリーレポート R4（2022）年4月No.7（林野庁）

3. 行政手続きベース推計値と衛星推定値の差は、行政年度と衛星観測期間との違いに起因する場合がある。
4. 実際の伐採傾向の補足の程度の評価に当たっては、単年次での評価ではなく、複数年の変動傾向から評価することが適切である。

ただし、木材供給ベースの推計値を見ると H28 (2016) ~R4 (2022) まで、安定的な上昇傾向にあり、行政手続きベース推計値や衛星推定値の変動傾向と明らかに一致しない点についても注視する必要がある。木材供給ベースの推計は、市場の木材出荷量から推計しており、算出過程は多くの仮定を置いているものの、変動傾向には伐採実態と一定の整合性があると考えられる。

このため現状では、行政手続きベース推計と衛星推定の変動傾向が類似していることのみをもって、これらが実際の伐採の動向を捉えられているかについては、予断を持って判断しがたい。

#### 4.4. マニュアル等の整備

##### ① 目視判読マニュアルの作成

目視判読を行う際の判読者の違いによる誤差は、伐採面積の推定精度への影響が大きいことから、判読する際の留意事項や、判断が難しい場合の対処方法等について整理した判読者向けの目視判読マニュアルを作成した。

マニュアルでは、判読者が変わったとしても実施できるよう目視判読が難しい箇所を例示、目視判読の際のコツや判断に迷った時の決め方などを記載した。なお、マニュアルの内容には伐採マップの作成、判読材料の作成、面積計算は含まれていない。

タイトルは「衛星画像 Sentinel-2 を使った主伐地の目視判読マニュアル」で、6 巻末資料 6.2 目視判読マニュアルに記載した。

##### ② FAMOST 活用マニュアルの作成

FAMOST について、個々の技術者が自ら衛星画像の分析等が可能なオープンプラットフォーム上でも運用できるよう、具体的な手順等について整理したマニュアルを作成した。

マニュアルでは、Google Earth Engine (以下 GEE) Code Editor 上での実行、結果の出力の手順をまとめた。

タイトルは、「Google earth engine での FAMOST 伐採マップの作成マニュアル」で、6 巻末資料 6.3FAMOST 活用マニュアルに記載した。

#### 4.5. 衛星画像等のリモートセンシング技術を活用した更新状況の把握に向けた検討

衛星画像等のリモートセンシング技術を活用して、伐採跡地における「更新（再造林・自然回復等）の進捗状況」を広域かつ効率的に把握するための手法について、試行結果を整理した。

##### ① 検討方法

###### i. 使用データ

(衛星) Landsat 5/7/8/9 Surface Reflectance (空間解像度 30 m) を使用し、各伐採地について伐採前 5 年から、伐採後 5 年および 10 年までの期間を解析対象とした。

(参照) 航空機搭載 LiDAR (DCHM) から推定した樹高を参照データとして用いた。Landsat データにより伐採が確認されたポリゴンを対象に、令和 2 (2020) -令和 3 (2021) 年に取得された LiDAR データから各ポリゴン内の樹高分布を算出した。樹高はポリゴン内の樹高ヒストグラムから代表値を算出し、ヒストグラムのピーク値 (最頻階級)、中央値 (第 50 パーセンタイル<sup>20</sup>) および各パーセンタイル (第 60 パーセンタイル～第 95 パーセンタイル) を樹高指標として採用した。

(地物・対象地) 対象地は、大分県内で航空機 LiDAR (DCHM) データが取得された地域 (令和 2 (2020) 年・令和 3 (2021) 年) とした (図 38)。伐採跡地ポリゴンは、Shimizu and Saito (2021)<sup>21</sup> の手法により作成された伐採情報 (4.1①過去の伐採面積の推定で用いた Landsat 時系列マップと同じ情報) から抽出し、機械学習により伐採と検出された面積 2 ha<sup>22</sup>以上の伐採跡地 (以下、サイトという。) を選定し、サイトごとに樹高と NDVI の平均値を求めた。解析対象とした伐採年は、LiDAR 取得年に対して約 5 年前 (平成 27 (2015) -平成 28 (2016) 年) および約 10 年前 (平成 22 (2010) -平成 23 (2011) 年) である (図 39)。

---

20 パーセンタイルについて、例えば第 50 パーセンタイルについては、図表では P50 と表記する。

21 Shimizu K, Saito H. (2021) Country-wide mapping of harvest areas and post-harvest forest recovery using Landsat time series data in Japan. *Int J Appl Earth Obs Geoinf.* 104:102555.

22 仕様書に例示された 5ha では、対象とするポリゴン数が少なくなるため、2ha とした




図 38 対象地

赤枠内（大分県）のうち航空機 LiDAR（DCHM）データが取得された地域（黒く見える箇所）



図 39 利用データタイムライン

## ii. 冬季 NDVI 代表値の算出

本検討では、季節変動の影響をできるだけ抑えて経年変化を安定的に捉えることを重視し、NBR 等に比べて冬季でも値が比較的安定しやすい NDVI を採用した。草本植生が衰退する冬季データを用いることで、草本性植生の季節的な増減の影響を相対的に小さくし、木本性植生の回復状況をより直接的に評価できる。

各年の冬季代表値は、12月～4月に取得された複数の Landsat 画像を対象に、各伐採ポリゴン内の NDVI を算出した上で、年内の観測値から「上位 40%の中央値(top-fraction median)」を採用した。これは、残存する雲・影・積雪等に起因する外れ値の影響を低減し、少数の異常値に左右されにくい頑健な年代代表値を得ることを目的としている。

冬季 NDVI の集計期間については、1月～3月や 12月～3月など複数の候補も試行したが、サイトによって RI(次節で説明)のばらつきが改善する場合と悪化する場合が混在し、一貫した改善傾向は確認できなかった。このため、本報告書では暫定的に 12月～4月を冬季期間として設定した。なお、Landsat Collection 2 Level-2 の品質情報(QA\_PIXEL)を用いて、雲、雲影、積雪等の影響を受けた画素を除外(マスク)した上で NDVI を集計した。

### iii. 回復評価指標 RI (Recovery Indicator)

RI は、伐採後の回復度合いを 0～1 (超) で表す指標で、以下で定義する。

$$RI(t) = (NDVI(t) - NDVI_{post\_min}) / (NDVI_{base} - NDVI_{post\_min})$$

- NDVI<sub>post\_min</sub> : 伐採直後(概ね 1-2 年)の最小値
- NDVI<sub>base</sub> : 伐採前 5 年間の冬季 NDVI 中央値
- NDVI(t) : 日時 t に観測された NDVI 値、RI=1 は伐採前の基準値に到達したことを意味し、RI>1 は伐採前以上に回復している可能性を示す。

#### iv. LiDAR 樹高指標 (参照値)

航空機 LiDAR 由来の樹高 (DCHM) を伐採跡地ポリゴンで切り出し、ポリゴンごとに樹高ヒストグラムを作成したところ樹高ヒストグラムには、①単独の最頻値 (ピーク値) を持つものと、②複数のピーク (多峰性) をもつものが確認され、これらの違いについて、Google Earth にて公開されている高解像の衛星画像により目視で確認した。

その結果、①単独ピークのヒストグラムとなるサイトは、伐採後に更新された樹木の成長のみを捉えられていると判断できる一方、②多峰性をもつヒストグラムでは、航空機 LiDAR に比べて空間分解能の低い衛星画像を用いることに起因して、機械判読時に位置ずれが生じる場合があり、その結果、サイト外周の立木が混入する、または、伐採区域内の残置森林等の樹高が含まれる事で、伐採後に更新された樹木以外の樹高成分が反映されている可能性があると考えられた。

これを踏まえて、RI を閾値とした更新状況把握方法を的確に評価するため、樹高ヒストグラムを元に以下2つの考え方で整理し、参照データとして用いた。

- 【①単独ピーク限定 (最頻値樹高)】 LiDAR データから得られる樹高分布が、単独ピークを持ち、伐採後に更新された樹木の成長のみを捉えられていると判断できるサイトのみ、Google Earth により目視で選別したうえで、ヒストグラムの最頻値 (ピーク値) を樹高指標として採用し評価する。
- 【②全サイト (パーセンタイル樹高)】 複数のピーク (多峰性) をもつものも含めた全サイトを対象に、樹高分布の第 50~第 95 パーセンタイルを樹高指標として採用し評価する。

各パターンで選別されたサイト数を表 33 に示す。

表 33 各パターンで選別されたサイト数

LiDAR 観測より	全サイト数 (単独ピーク・ 複数ピーク含む)	単独ピーク限定サイト数 (単独ピークとならないサイトを GE で除外後)
伐採後 5 年	300	88
伐採後 10 年	191	62

図 40 に、樹高ヒストグラムが単独ピークとなる例を示す。では、サイト内で更新した樹木の成長を代表する平均樹高として、ヒストグラムの最頻値 (ピーク値) を採用し、評価を行った。

図 41 に、ヒストグラムが複数のピーク (多峰性) を示す例を示す。単一の代表値のみで成長状況を適切に表現しにくい場合が確認され、DCHM の樹高ヒストグラムと、パーセンタイル値による樹高指標設定例とを併せて示す。




図 40 単独ピークの樹高ヒストグラム例。




図 41 複数ピークの樹高ヒストグラム例

(DCHM；第 50 パーセンタイル～第 95 パーセンタイルの位置を併記)

■ 分類 (≤1m、1-5m、>5m) と精度評価

参照クラスは、各ポリゴンの樹高指標から以下で定義した。

- ・ ≤1m：低い植生（草本中心または未回復を含む）

- ・ 1-5m：低木～若齢木（更新途上）
- ・ >5m：高木（相対的に回復が進んだ状態）

RI を使って得られた分類クラスは、RI を 2 つの閾値  $t_1, t_2$  で区切り、3 クラスに分類した ( $RI < t_1, t_1 \leq RI < t_2, RI \geq t_2$ )。  $t_1, t_2$  は固定値ではなく、候補となる組合せを総当たりで試し、その中で F1 が最も高くなる組合せを採用した。併せてサイトの樹高の指標として、どのパーセンタイル値を用いるのが適しているかを検討するために、適合率/再現率を算出した。混同行列は 列=参照データ、行=RI を使って得られた分類結果 とした。

本節では、回復指標 RI から樹高クラス ( $\leq 1m, 1-5m, >5m$ ) を推定する 3 分類の成立性と精度を整理する。

参照は航空機 LiDAR (DCHM) 由来の樹高指標を高さ閾値 ( $\leq 1m, 1-5m, >5m$ ) で区分したものとした。予測は、RI を 2 つの閾値  $t_1, t_2$  により 3 区分 ( $RI < t_1, t_1 \leq RI < t_2, RI \geq t_2$ ) として比較した。なお、混同行列は 列=参照データ（樹高）、行=RI を使って得られた分類結果 とする。

## ■ サイト数とクラス構成（サイト数の違い・偏りの影響）

解析では、評価に使用できるサイト数 (N) は 伐採後 5 年（以下、 $ri_{5y}$  と表記。） が 300、伐採後 10 年（以下、 $ri_{10y}$  と表記。） が 191 であった。解析では、 $ri_{5y}$  と  $ri_{10y}$  を別々のデータセットとして作成・評価しているため、両者で解析対象となるサイト集合が異なる。その結果、 $ri_{5y}$  と  $ri_{10y}$  で利用可能なサイト数 (N) が一致しない点に留意が必要である。

また、高パーセンタイル（第 90/95 パーセンタイル）を参照樹高に用いた場合、Reference が >5m に偏り、 $\leq 1m$  および 1-5m の検証対象がほとんど存在しないケースがある。この場合、F1 が高く見えても、3 分類の識別性能を表していないため、運用判断では注意が必要である。

## ② 結果

### i. 冬季 NDVI による評価

樹高ヒストグラム、樹高が得られた令和 2（2020）年頃の Google Earth 画像、NDVI 時系列プロットの例を図 42 に示す。冬季 NDVI は夏季に比べて草本性植物の有無や季節変動の影響を受けにくく、木本性植物の回復の進行に伴い緩やかに増加する傾向が確認された。

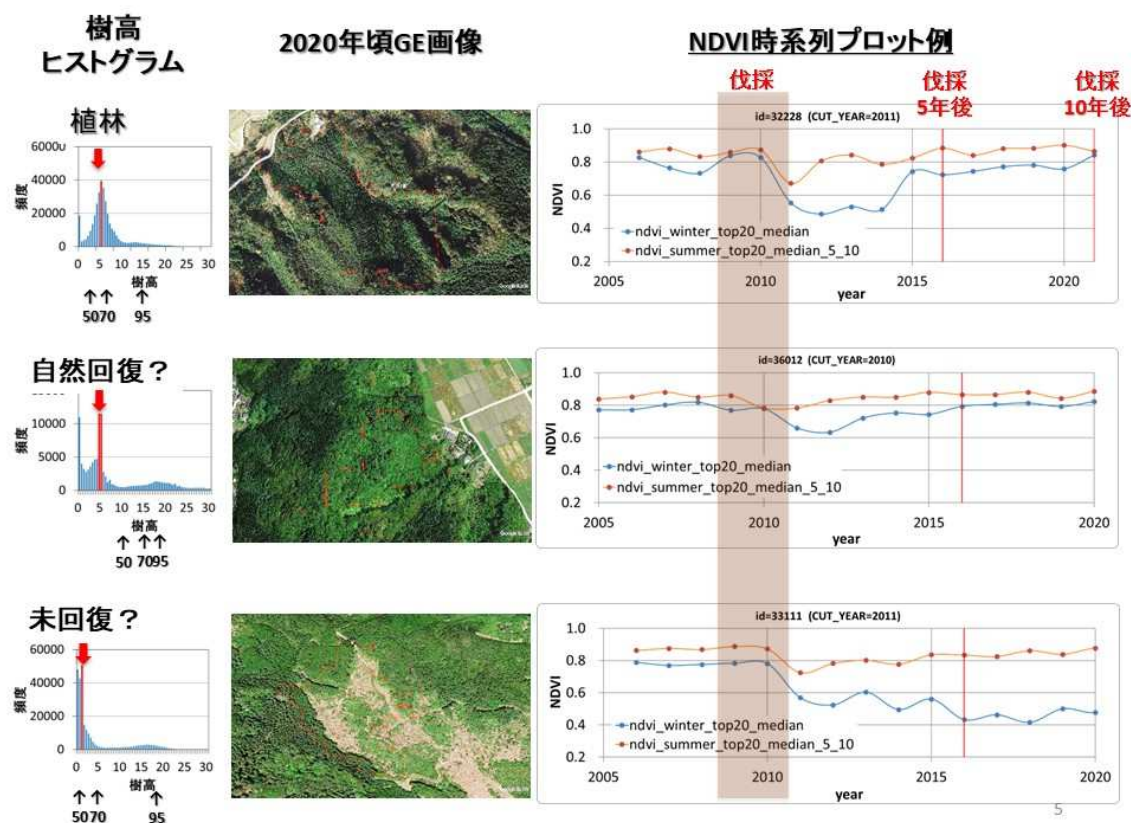


図 42 樹高ヒストグラム・Google Earth 画像・NDVI 時系列プロットの例  
 (伐採年 平成 22 (2010) 年、橙：夏季 NDVI 時系列プロット、  
 青：冬季 NDVI 時系列プロット)

## ii. RI を用いた分類の LiDAR 樹高指標による評価

### ■ ①単独ピーク限定 (最頻値樹高)

LiDAR データから得られる樹高分布が、単独ピークを持ち伐採後に更新された樹木の成長のみを捉えられていると判断できるサイトのみを参照し評価を行った。

回復指数 RI (5/10 年) を使って樹高を推定した結果を表 34、表 35 に示す。RI (回復指数) 5 年では、未回復場所 ( $\leq 1\text{m}$ ) の検出精度は 90%程度、5m 以上のサイト (2 か所) は検出できなかった。RI (回復指数) 10 年では、未回復場所を精度 100%で検出、5m 以上のサイトも、精度 83%で 12 か所中 5 か所検出した。これより、伐採後に更新された樹木の成長のみを捉えられていると判断できるサイトでは、伐採後の更新された樹木の成長を評価できる可能性が示唆された。

表 34 RI（回復指数）5年を使った分類結果

	≤1m	1-5m	>5m	参照区分計	Producer's 精度
≤1m	59	2	0	61	<u>96.7</u>
1-5m	9	15	1	25	60.0
>5m	0	2	0	2	<u>0</u>
分類結果計	68	19	1	88	-
User's 精度	<u>86.8</u>	79.0	<u>0</u>	-	<u>84.1</u> (全体精度)

表 35 RI（回復指数）10年を使った分類結果

	≤1m	1-5m	>5m	参照区分計	Producer's 精度
≤1m	15	0	0	15	<u>100</u>
1-5m	0	34	1	35	97.1
>5m	0	7	5	12	<u>41.7</u>
分類結果計	15	41	6	62	-
User's 精度	<u>100</u>	82.9	<u>83.3</u>	-	<u>87.1</u> (全体精度)

■ ②全サイト（パーセンタイル樹高）

複数のピーク（多峰性）をもつものも含めた全サイトを参照し評価を行った。

図 43、図 44 に、RI（伐採後 5 年、10 年）と樹高指標（第 50 パーセンタイル～第 95 パーセンタイル）の関係（散布図）を示す。樹高指標として第 70 パーセンタイル～第 80 パーセンタイルを用いた場合、低い樹高から高い樹高までを一定程度カバーし、分類に利用しやすいことが示唆された。




図 43 RI (伐採後 5 年) と樹高の関係 (散布図)

(樹高は各サイトの DCHM 分布から第 50 パーセンタイル～第 95 パーセンタイルを用いて算出した)

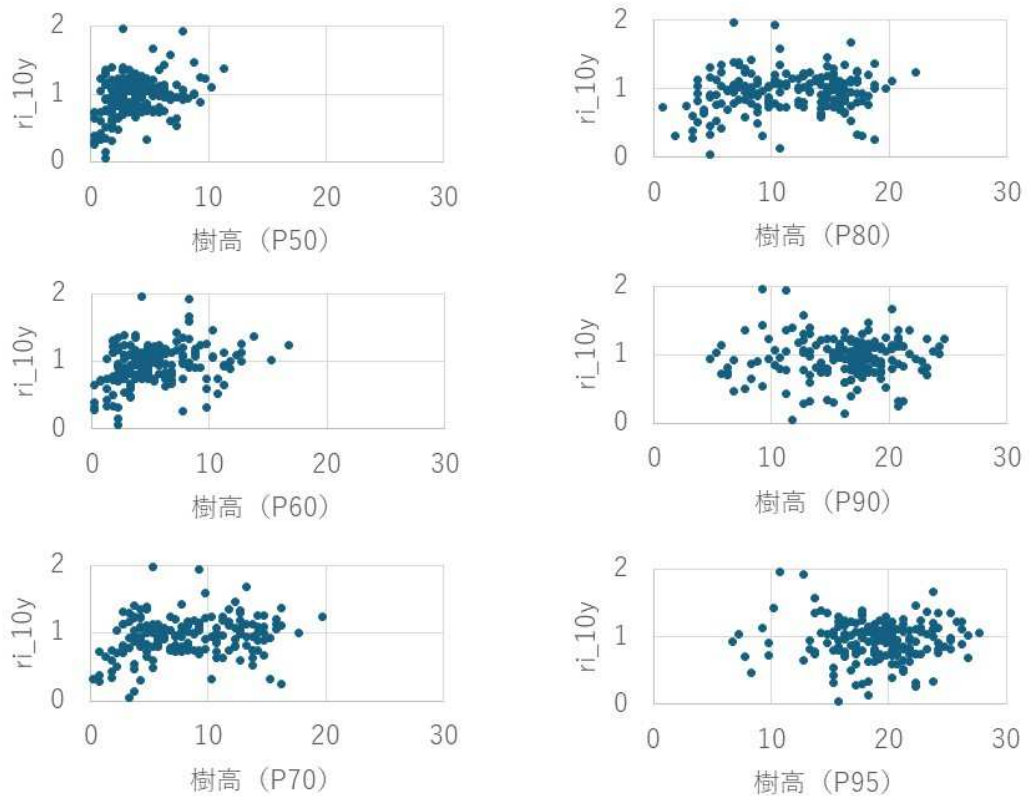


図 44 RI (伐採後 10 年) と樹高の関係 (散布図)

(1) 閾値 (t1, t2) と精度の概要

表 36 に、2 (RI) × 6 (樹高指標) の計 12 通りについて、最適閾値 (t1, t2) と精度指標 (F1、Balanced accuracy: BA<sup>23</sup>) を整理した。BA は参照クラス別の再現率の平均であり、クラス不均衡の影響を受けにくい指標として位置づけられる。

<sup>23</sup> 再現率の平均 (クラス不均衡の影響を緩和)。

表 36 閾値 (t1, t2) と精度の概要

RI	hist_metric	N	t1	t2	F1	BA
ri_10y	hist_P50_x	191	0.4494	1.4146	71.7%	54.2%
ri_10y	hist_P60_x	191	-0.1156	0.9442	57.6%	48.1%
ri_10y	hist_P70_x	191	-0.1156	0.5666	71.2%	44.2%
ri_10y	hist_P80_x	191	-0.1156	0.0991	89.0%	53.0%
ri_10y	hist_P90_x	191	-0.2520	-0.1156	98.4%	49.5%
ri_10y	hist_P95_x	191	-0.2520	-0.1156	99.0%	99.0%
ri_5y	hist_P50_x	300	0.5885	1.3223	60.0%	44.3%
ri_5y	hist_P60_x	300	0.2364	1.3223	48.3%	37.9%
ri_5y	hist_P70_x	300	-0.2840	0.4383	49.0%	39.3%
ri_5y	hist_P80_x	300	-1.4415	-1.0186	76.3%	33.8%
ri_5y	hist_P90_x	300	-1.4415	-1.0186	90.3%	33.1%
ri_5y	hist_P95_x	300	-1.4415	-1.0186	94.7%	33.1%

(2) 精度の傾向 (F1/BA)

組み合わせ別の F1 および BA を図 45、図 46 に示す。F1 はクラス構成 (>5m 偏り等) の影響を受けやすいため、BA (クラス平均の再現率) も併せて確認することが重要である。




図 45 F1 (組み合わせ別)




図 46 Balanced accuracy (組み合わせ別)

(3) 混同行列 (rows=Reference、cols=Predicted (RI)) の例

表 37 に、3 クラスが成立している例として ri\_10y\_hist\_P50\_x の結果を示す (t1=0.4494, t2=1.4146, N=191, F1=71.7%, BA=54.2%)。

表 37 混同行列と精度 (ri\_10y\_hist\_P50\_x)

	≤1m	1-5m	>5m	計	再現率
≤1m	9	7	0	16	56.25%
1-5m	5	122	5	132	92.42%
>5m	0	37	6	43	13.95%
計	14	166	11	191	
適合率	64.29%	73.49%	54.55%		

本結果では、参照クラス「1-5m」の再現率が 92.42%と高い。一方、「>5m」および「≤1m」の再現率が低い(13.95%, 56.25%)。更新が確実に起こった場所(>5m)は、43 か所中、37 か所見落としている。また、更新が起こっていない場所 (≤1m) は、16 か所中 7 か所見落としている。

参考として、F1 が高く出やすい組み合わせの例として ri\_10y\_hist\_P80\_x を表 38 に示す (t1=-0.1156, t2=0.0991, N=191, F1=89.0%, BA=53.0%)。“F1”値は、ri\_10y\_hist\_P50\_x よりも高いが、≤1m の未更新地は、2 か所中 1 か所検出 (1 か所見落とし) となっており、F1 の解釈には注意が必要である。

表 38 混同行列と精度 (ri\_10y\_hist\_P80\_x)

	≤1m	1-5m	>5m	計	再現率
≤1m	1	0	1	2	50.00%
1-5m	1	2	19	22	9.09%
>5m	0	0	167	167	100.00%
計	2	2	187	191	
適合率	50.00%	100.00%	89.30%		

### iii. 小括（解析結果からの示唆）

解析結果から、以下の点が示唆された。

- (1) 伐採後に更新された樹木の成長のみを捉えていると判断できる伐採跡地（サイト）に限定した場合、冬季 NDVI 時系列から算出した RI により、更新木の成長（回復）の進行を評価できる可能性が示された。
- (2) 伐採後 10 年までの衛星時系列データを用いた場合は、5 年までの場合に比べ、BA (Balanced accuracy: 各クラスの再現率の平均) が高い組み合わせが得られやすかった。
- (3) サイト外周の立木やサイト内の残置森林等の影響を含むサイトも含めて評価した場合、精度検証には以下の留意点が確認された。
  - ・ 第 50 パーセンタイルではサイトの約 7 割が「1-5m」に、第 80 パーセンタイルではサイトの約 9 割が「>5m」に分類されており、必ずしも伐採後に更新された樹木の成長を的確に評価できていない可能性が示唆された。
  - ・ 参照樹高に高パーセンタイル（第 90/第 95 パーセンタイル）を用いるとクラス不均衡が強まり、F1 や OA (Overall accuracy) が高く見えても、必ずしも 3 分類性能を適切に表さない場合がある。
  - ・ 実運用では、F1 や OA だけでなく、適合率/再現率 (UA/PA) に加えて、クラス別件数（分類結果・参照区分）を併記したうえで、指標や判定閾値を選定する必要がある。

以上より、冬季 NDVI の時系列データから算出した RI による更新状況の把握は有効性が高い一方で、精度検証の基準となる LiDAR 参照樹高データの作成・処理方法に課題が残ることが明らかとなった。

### iv. 課題

本手法の更なる検討を進めるためには、主に以下の課題への対応が必要である。

1. **参照データ (LiDAR 由来の樹高) の品質確保**：伐採地ポリゴン端部の混入 (エッジ影響) により参照樹高が実態より高く見積もられると、RI との対応が崩れ、推定精度が低下する。可能であれば、同一地域で複数時期に取得された LiDAR を用いて、回復している樹木のみの変化量から参照樹高を推定するなど、より頑健な参照値の作成も検討すべきである。
2. **外部検証による汎用性評価**：今回の検証地域 (大分県) 以外でも同様の評価を行い、樹種・気候・地形・施業条件の差が精度へ与える影響を定量化する必要がある。
3. **転用地の扱い**：太陽光パネルや茶畑等の土地利用転用が混在すると、植生回復 (樹高) と RI の関係が単純ではなくなるため、土地被覆分類等の補助データにより除外・別分類する運用設計が必要となる。
4. **衛星データおよび判定アルゴリズムの高度化**：Sentinel-2 (10m) の高頻度観測を取り入れることで、伐採直後の変化や回復初期の検出精度向上が期待される。また、季節別 NDVI や地形 (傾き等) の追加特微量、対話型 AI の活用、機械学習による判定ロジックの導入により、特に未回復の検出精度改善が課題となる。
5. **広域・長期の衛星時系列を扱うための計算基盤整備**：Google Earth Engine 等のクラウド基盤は実用的選択肢となる一方、運用段階では利用料が発生するため、地方自治体が直接活用する場合には、費用対効果と予算措置を含めた導入判断が必要である。

## 5. まとめと課題

本事業では、民有林での伐採面積を推定する手法やAI技術活用の活用等について整理・検討し、以下の結果が得られた。課題についても併せて記載する。

### 5.1. 過去の伐採面積の推定（全国）

全国の民有林を対象に、既存の伐採マップ（Landsat 時系列伐採マップ）を層化情報として用い、層化無作為抽出に基づく面積推定手法により2017～2020年の年次伐採面積を推定した。

具体的には、伐採マップに基づき層（伐採域、非変化域等）を設定し、各層からサンプル地点を抽出したうえで、Sentinel-2 画像を判読材料として伐採／非伐採を判定し、層内の伐採判読割合と層面積を組み合わせて年の推定値を算出した。推定の結果、伐採面積は平成29（2017）年：41,529 ha、平成30（2018）年：53,058 ha、令和元（2019）年：56,683 ha、令和2（2020）年：50,942 ha となった。95%信頼区間はそれぞれ5,900 ha、6,628 ha、6,945 ha、6,461 ha であり、推定面積に対する比率は12～13%程度で推移した。ただし平成29（2017）年は信頼区間比率が14.2%と相対的に大きく、同年は判読に利用可能なSentinel-2 画像に限られること等により、判読・推定の不確実性が増大し得る点に留意が必要である。

今後の課題としては以下が挙げられる

1. 利用する画像の不確実性：衛星アーカイブや判読材料の制約が大きい期間では推定精度が低下し得るため、対象期間に応じた不確実性評価（例えば合成画像の期間のうち雲なし（または雲少）画像が確保できた頻度）を示す

### 5.2. FAMOST を活用した伐採面積の推定（全国）

最新年のLandsat 時系列伐採マップが未整備となる状況を想定し、2時点差分により森林変化点を抽出するFAMOST を用いて伐採マップを作成し、全国の民有林における令和5（2023）年および令和6（2024）年の伐採（主伐）面積を推定した。従来のFAMOST は誤検出が少ない一方で見逃しが多い点が課題とされていたため、本年度は見逃しを抑制する方向で閾値等を調整したSentinel-2 簡易マップ改を整備し、4.1①と同様の層化無作為抽出と目視判読により面積推定を実施した。推定の結果、伐採面積は令和5（2023）年：49,969 ha、令和6（2024）年：48,454 ha となり、95%信頼区間はそれぞれ5,306 ha、4,664 ha、信頼区間比率は令和5（2023）年10.6%、令和6（2024）年9.6%であり、全国推定として一定の精度水準を確保した。

今後の課題としては以下が挙げられる

1. 未だ残る誤検出のフィルタリングの検討：季節性の影響を抑えることや、影・土地被

覆に応じた閾値の検討、計算負荷ができる限り低くなる時系列情報の活用等により、FAMOST の誤検出と見逃しを低減する伐採マップ作成手法へ改良

2. 判読体制：過年度推定（例：令和 6（2024）年の推定値）との間に差が生じた事例もあり、判読体制（判読者数・手順）等が推定値に影響し得ることから、4.4①で整備した目視判読マニュアル等による、判読手順の標準化と品質管理の継続が重要

### 5.3. FAMOST を活用した伐採面積の推定（スギ人工林伐採重点区域）

スギ人工林伐採重点区域（民有林）を対象に、4.1②で作成した Sentinel-2 簡易マップ改を用い、全国推定と同一の推定手順で令和 5（2023）年および令和 6（2024）年の伐採面積を推定した。推定の結果、重点区域における伐採面積は令和 5（2023）年：6,733 ha、令和 6（2024）年：7,362 ha となった。また、95%信頼区間はそれぞれ±728 ha（信頼区間比率 10.8%）、±764 ha（同 10.4%）だった。R6 調査では推定面積 2,477ha±1,270ha（95%信頼区間）であったことと比較すると、推定精度は大幅に向上した。

今後の課題としては、スギ人工林重点区域 GIS ポリゴンの精度の確保がある。その対応として以下が挙げられる。

1. 重点区域以外が含まれていないことを確認：都道府県から送付されるポリゴンデータと重点区域の面積を比較
2. 座標系情報の確保：道府県から提出される GIS データは、使用している座標参照系が都道府県ごとに異なる場合がある。座標系情報が付与されていないデータでは、投影変換や重ね合わせが適切に行えず、位置ずれや統合処理の不確実性が生じる。このため、GIS ファイル一式の提出に際しては、座標系ファイル(ESRI 形式の場合は \*.prj)を必須とするか、座標参照系の名称（例：JGD2011 / 平面直角座標系〇系、EPSG コード等）を併せて提出してもらう。

### 5.4. 行政情報の集計等による推定手法との比較検証

本調査では、衛星画像判読に基づく主伐面積推定値と、行政手続きベースおよび木材供給量ベースの統計値を比較検証した。その結果、木材供給ベースの推計のみ安定した上昇傾向を示したが、衛星推定値と行政手続きベースの推計では、単年度では差異が見られるものの、複数年の傾向としては概ね整合していることが確認された。特に、GLAD が提供する森林被覆減少データと本事業の衛星推定値は、異なるアルゴリズムおよび処理体系に基づくにもかかわらず、年次方向性において類似した変動を示しており、衛星観測に基づく年変動には一定の実態が反映されている可能性が示唆された。

一方、行政手続きベース推計値と衛星推定値との間には、年次変動の位相差が観察された。この差は、主に推定/推計対象期間の違いに起因する構造的要因によるものと考えられる。衛星推定は概ね 11 月～翌年 10 月を対象とするのに対し、行政手続きベースは 4 月～翌年 3

月を対象とするため、特に伐採が集中する冬季（1～3月）の年次配分が異なる。この結果、同一の冬季伐採が行政では前年度、衛星では翌年度に計上される構造となり、衛星推定値は行政値に対して1年遅れて変動しているように観察される。

また、令和3（2021年）のウッドショック期のように原木価格が急騰した局面では、価格上昇期の冬季伐採が行政と衛星で異なる年次に計上されることにより、両者の差が顕在化した可能性がある。ただし、こうした急激な価格変動は例外的であり、通常の価格変動範囲では年次配分の違いは長期的に相殺されると考えられる。

本分析により衛星推定値、木材供給量ベースのそれぞれの特徴と差異は整理されたが、これらの数値をもとに、どのように主伐面積として利用する数値を計算するかについては、なお検討の余地がある。

## 5.5. AI技術等活用による推定の省力化に向けた検討

本検討では、伐採マップ作成およびサンプル地点の目視判読に要する作業時間を削減することを目的として、衛星画像の時系列情報と機械学習（AI）による分類手法の適用可能性を整理した。全国一律条件で取得可能な Landsat および Sentinel-2 を対象に、平成28（2016）/平成29（2019）～令和4（2022）年の NDVI および NBR の月次時系列を1ピクセル点単位で整備し、教師なし（LSTM Autoencoder）および教師あり（1DCNN）を試行した。その結果、教師なし LSTM Autoencoder では、実運用に耐えうる精度を得る事は出来なかった。一方、教師あり 1DCNN では NDVI より NBR を用いた場合に高い判別性能が確認され、閾値設定を全体精度重視とすることで森林を97.1%の確度で判定できた（時系列データ、平成28（2016）～令和4（2022）年利用の場合）。また、User's 精度重視の閾値設定では、森林判定の誤判定を生じさせずに森林サイトの一部（1,700地点）を確度100%で自動検出できることが示された。以上より、目的に応じた閾値調整により、判別精度と自動確定件数のバランスを柔軟に制御し、目視判読を段階的に削減できる可能性が示唆された。

本手法を実運用へ展開するためには、主に以下の課題への対応が必要である。

1. 教師データ品質が精度を大きく左右するため、誤ラベル、位置ずれ、判読不能点などの管理を徹底し、学習データからの除外・再ラベリングを含む品質管理プロセスを確立する必要がある。
2. AIで判読が難しい地点が目視でも判読困難であるかを分析し、判読困難点の抽出や優先度付けに活用できる枠組みを整えることが重要である。
3. 1ピクセル点の時系列情報のみでは伐採境界や小規模変化の表現に限界があるため、周辺テクスチャを含む時系列チップを入力とした2次元CNN等への拡張を検討し、空間情報を取り込んだ精度向上を図る必要がある。
4. 運用設計として、閾値ごとの「自動確定率」「目視削減率」「誤判定率」を整理し、業務要件（誤判定許容度、見落とし許容度、処理量）に合致する設定を定量的に提案

できるようにすることが求められる。加えて、実際の業務フローに適用した際の作業時間削減量を定量評価し、省力化効果を根拠として提示できるようにすることが期待される。

## 5.6. 衛星画像等のリモートセンシング技術を活用した更新状況の把握に向けた検討

本検討では、衛星画像等のリモートセンシング技術を用いて、伐採跡地における更新（再造林・自然回復等）の進捗状況を広域かつ効率的に把握するための手法について、試行結果を整理した。検討では、Landsat(30m)の冬季NDVI時系列から回復指標(RI: Recovery Indicator)を算出し、航空機LiDAR(DCHM)から得られる樹高分布参照データとして、RIから樹高クラス(≤1m、1-5m、>5m)を推定可能か評価した。混同行列(rows=Reference、cols=Predicted)により User's 精度および Producer's 精度を算出し、性能指標として Balanced accuracy (各クラスの Producer's 精度の平均)を用いて比較した。航空機LiDAR(DCHM)から得られる樹高分布から、伐採後に更新された樹木の成長のみを捉えられていると考えられる①単独ピーク限定(最頻値樹高)と、サイト外周の立木や残置森林等も含んだ②全クラス(パーセントイル樹高)の2パターンの参照データに分けて評価した。

①単独ピーク限定(最頻値樹高)を参照指標とした結果、RI(回復指数)5年では、未回復場所(≤1m)の検出精度は90%程度、RI(回復指数)10年では、未回復場所を精度100%で検出した。これより、伐採後に更新された樹木の成長のみを捉えられていると判断できるサイトでは、伐採後の更新された樹木の成長を評価できる可能性が示唆された。

②全クラス(パーセントイル樹高)では、参照指標としては中央値～中位パーセントイル(例:p70～p80)が低木から高木までの分布を反映しやすく、評価に適する傾向が確認された。また、複数条件の中では ri\_10y×hist\_p50\_x が Balanced accuracy 最大となり、BA=54.2% (OA=71.7%、N=191)を示した。一方で、伐採地ポリゴンの端部に未伐採樹冠が混入するエッジ影響や、伐採後に太陽光パネル・茶畑等へ転用された箇所の混在により、RIと樹高の対応関係が崩れ、分類精度が低下するケースが確認された。以上より、衛星時系列に基づくRIは更新状況の概況把握に有用である一方、参照データの整備と対象地の条件整理を行うことで、実運用に耐える精度へ改善できる余地が大きいことが示唆された。

実運用に向けては、以下の課題に体系的に対応する必要がある。

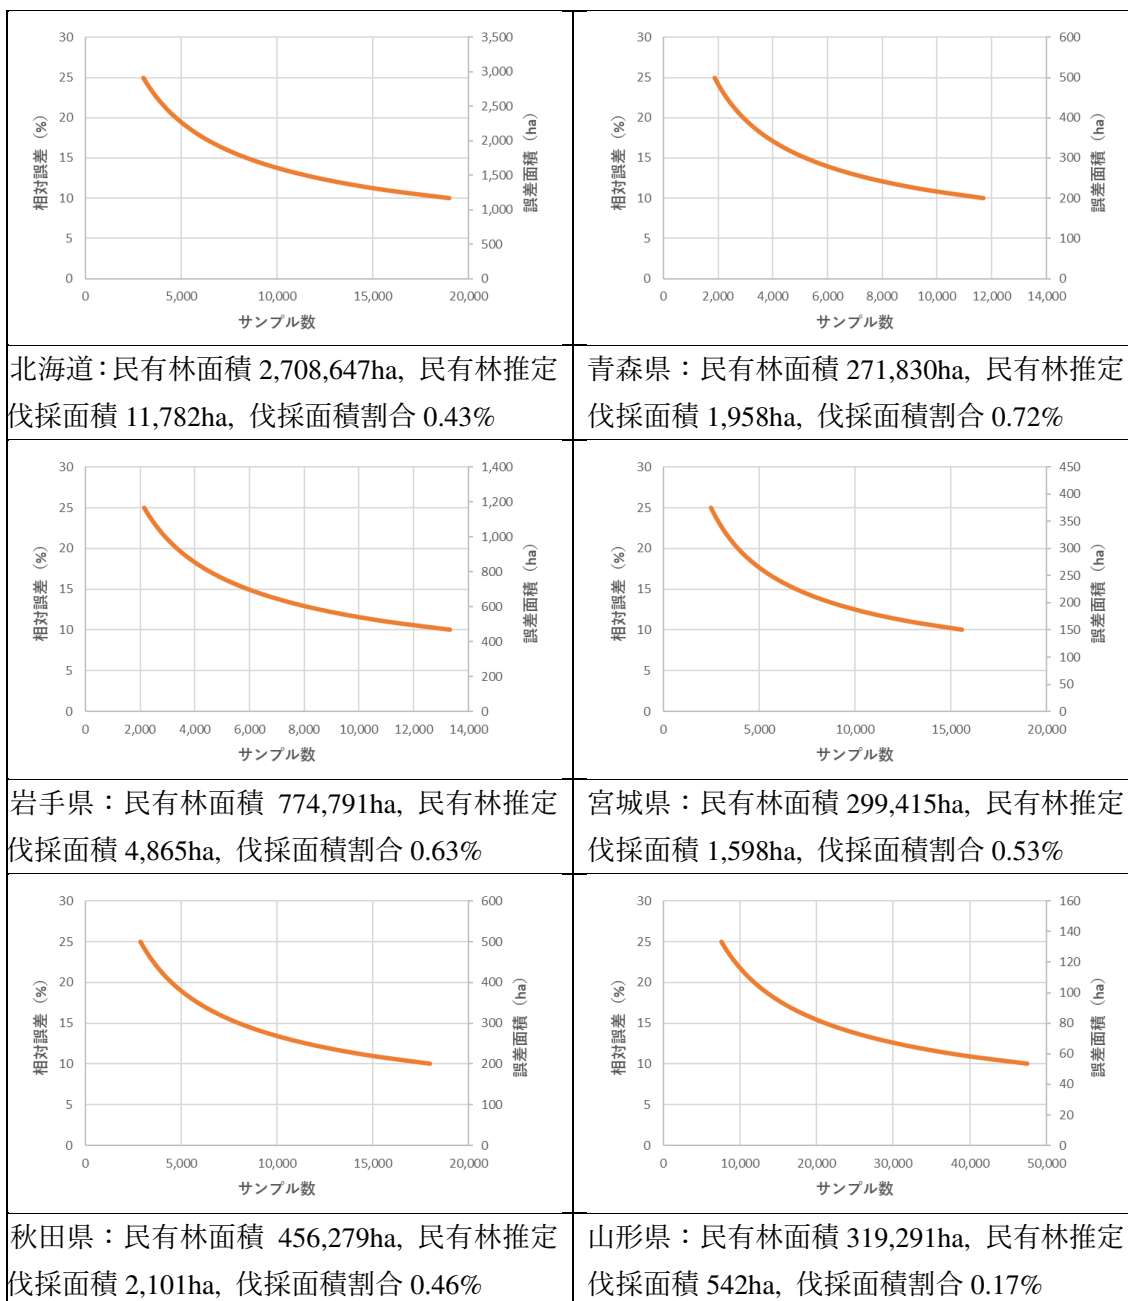
1. **参照データ(LiDAR由来の樹高)の品質確保**: 伐採地ポリゴン端部の混入(エッジ影響)により参照樹高が実態より高く見積もられると、RIとの対応が崩れ、推定精度が低下する。可能であれば、同一地域で複数時期に取得されたLiDARを用いて、回復している樹木のみの変化量から参照樹高を推定するなど、より頑健な参照値の作成も検討すべきである。
2. **外部検証による汎用性評価**: 今回の検証地域(大分県)以外でも同様の評価を行い、樹種・気候・地形・施業条件の差が精度へ与える影響を定量化する必要がある。
3. **転用地の扱い**: 太陽光パネルや茶畑等の土地利用転用が混在すると、植生回復(樹高)

と RI の関係が単純ではなくなるため、土地被覆分類等の補助データにより除外・別分類する運用設計が必要となる。

4. **衛星データおよび判定アルゴリズムの高度化**：Sentinel-2（10m）の高頻度観測を取り入れることで、伐採直後の変化や回復初期の検出精度向上が期待される。また、季節別 NDVI や地形（傾き等）の追加特徴量、対話型 AI の活用、機械学習による判定ロジックの導入により、特に未回復の検出精度改善が課題となる。
5. **広域・長期の衛星時系列を扱うための計算基盤整備**：Google Earth Engine 等のクラウド基盤は実用的選択肢となる一方、運用段階では利用料が発生するため、地方自治体が直接活用する場合には、費用対効果と予算措置を含めた導入判断が必要である。

## 6. 巻末資料

### 6.1. 報告書付属資料




<p>福島県：民有林面積 586,631ha, 民有林推定伐採面積 1,640ha, 伐採面積割合 0.28%</p>	<p>茨城県：民有林面積 161,515ha, 民有林推定伐採面積 721ha, 伐採面積割合 0.45%</p>
<p>栃木県：民有林面積 219,855ha, 民有林推定伐採面積 1,102ha, 伐採面積割合 0.5%</p>	<p>群馬県：民有林面積 217,101ha, 民有林推定伐採面積 429ha, 伐採面積割合 0.2%</p>
<p>埼玉県：民有林面積 109,611ha, 民有林推定伐採面積 166ha, 伐採面積割合 0.15%</p>	<p>千葉県：民有林面積 171,950ha, 民有林推定伐採面積 442ha, 伐採面積割合 0.26%</p>
<p>東京都：民有林面積 74,467ha, 民有林推定伐採面積 123ha, 伐採面積割合 0.17%</p>	<p>神奈川県：民有林面積 84,540ha, 民有林推定伐採面積 59ha, 伐採面積割合 0.07%</p>

<p>新潟県：民有林面積 546,806ha, 民有林推定 伐採面積 307ha, 伐採面積割合 0.06%</p>	<p>富山県：民有林面積 156,577ha, 民有林推定 伐採面積 144ha, 伐採面積割合 0.09%</p>
<p>石川県：民有林面積 250,213ha, 民有林推定 伐採面積 262ha, 伐採面積割合 0.1%</p>	<p>福井県：民有林面積 260,103ha, 民有林推定 伐採面積 138ha, 伐採面積割合 0.05%</p>
<p>山梨県：民有林面積 326,629ha, 民有林推定 伐採面積 428ha, 伐採面積割合 0.13%</p>	<p>長野県：民有林面積 623,664ha, 民有林推定 伐採面積 854ha, 伐採面積割合 0.14%</p>
<p>岐阜県：民有林面積 629,763ha, 民有林推定 伐採面積 828ha, 伐採面積割合 0.13%</p>	<p>静岡県：民有林面積 427,500ha, 民有林推定 伐採面積 667ha, 伐採面積割合 0.16%</p>

<p>愛知県：民有林面積 205,680ha, 民有林推定 伐採面積 237ha, 伐採面積割合 0.12%</p>	<p>三重県：民有林面積 348,346ha, 民有林推定 伐採面積 753ha, 伐採面積割合 0.22%</p>
<p>滋賀県：民有林面積 177,283ha, 民有林推定 伐採面積 178ha, 伐採面積割合 0.1%</p>	<p>京都府：民有林面積 326,376ha, 民有林推定 伐採面積 519ha, 伐採面積割合 0.16%</p>
<p>大阪府：民有林面積 60,540ha, 民有林推定伐 採面積 151ha, 伐採面積割合 0.25%</p>	<p>兵庫県：民有林面積 514,466ha, 民有林推定 伐採面積 587ha, 伐採面積割合 0.11%</p>
<p>奈良県：民有林面積 263,842ha, 民有林推定 伐採面積 190ha, 伐採面積割合 0.07%</p>	<p>和歌山県：民有林面積 350,014ha, 民有林推 定伐採面積 774ha, 伐採面積割合 0.22%</p>

<p>鳥取県：民有林面積 222,436ha, 民有林推定 伐採面積 276ha, 伐採面積割合 0.12%</p>	<p>島根県：民有林面積 479,842ha, 民有林推定 伐採面積 1,263ha, 伐採面積割合 0.26%</p>
<p>岡山県：民有林面積 446,581ha, 民有林推定 伐採面積 849ha, 伐採面積割合 0.19%</p>	<p>広島県：民有林面積 562,635ha, 民有林推定 伐採面積 1,432ha, 伐採面積割合 0.25%</p>
<p>山口県：民有林面積 423,549ha, 民有林推定 伐採面積 969ha, 伐採面積割合 0.23%</p>	<p>徳島県：民有林面積 289,060ha, 民有林推定 伐採面積 631ha, 伐採面積割合 0.22%</p>
<p>香川県：民有林面積 87,349ha, 民有林推定伐 採面積 96ha, 伐採面積割合 0.11%</p>	<p>愛媛県：民有林面積 383,346ha, 民有林推定 伐採面積 603ha, 伐採面積割合 0.16%</p>

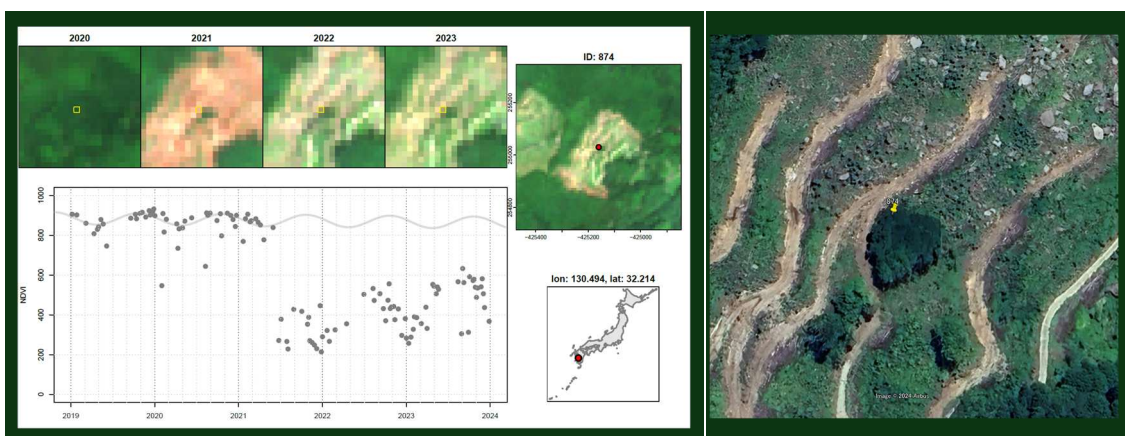
<p>高知県：民有林面積 456,756ha, 民有林推定伐採面積 1,174ha, 伐採面積割合 0.26%</p>	<p>福岡県：民有林面積 210,381ha, 民有林推定伐採面積 1,008ha, 伐採面積割合 0.48%</p>
<p>佐賀県：民有林面積 110,754ha, 民有林推定伐採面積 152ha, 伐採面積割合 0.14%</p>	<p>長崎県：民有林面積 245,587ha, 民有林推定伐採面積 351ha, 伐採面積割合 0.14%</p>
<p>熊本県：民有林面積 421,629ha, 民有林推定伐採面積 2,304ha, 伐採面積割合 0.55%</p>	<p>大分県：民有林面積 410,153ha, 民有林推定伐採面積 3,005ha, 伐採面積割合 0.73%</p>
<p>宮崎県：民有林面積 401,824ha, 民有林推定伐採面積 5,139ha, 伐採面積割合 1.28%</p>	<p>鹿児島県：民有林面積 479,803ha, 民有林推定伐採面積 2,460ha, 伐採面積割合 0.51%</p>



沖縄県：民有林面積 83,123ha, 民有林推定伐採面積 51ha, 伐採面積割合 0.06%

図 47 相対誤差の変化に伴う必要サンプル数および誤差面積の関係（都道府県別）

## 6.2. 目視判読マニュアル



# 衛星画像 Sentinel-2 を使った主伐地の 目視判読マニュアル

林野庁

令和8年3月

## 目次

1	はじめに .....	112
1.1	背景 .....	112
1.2	マニュアルの位置づけ.....	112
1.3	本マニュアルでの前提事項.....	112
2	判読体制 .....	114
3	判読の流れ .....	115
4	判読の基準 .....	116
4.1	基本的な判定区分.....	116
4.1.1	伐採の判定基準.....	116
4.1.2	森林の判定基準.....	117
4.1.3	伐採年の判定方法.....	117
4.1.4	使用画像と補助資料.....	117
4.1.5	注意事項 .....	117
4.2	代表的な判読例.....	117
4.2.1	伐採地の例.....	119
4.2.2	非伐採地の例.....	121
4.3	判読が難しい場合にどうするか.....	122
4.3.1	伐採年が決められない.....	122
4.3.2	位置が境界でどちらか決められない.....	123
4.3.3	過去の変化から判断が難しい.....	127
4.3.4	誤判断しやすい.....	129
4.3.5	能登崩壊地 GIS ポリゴンエリア外の伐採判断 .....	131
5	管理者の役割 .....	133
6	最後に .....	134

# 1 はじめに

## 1.1 背景

我が国の森林資源は本格的な利用期を迎えており、適正な伐採と再造林の確保を両立しながら、持続的な森林資源の循環利用を進めることが重要である。そのためには、伐採、特に主伐の発生状況を的確に把握し、伐採面積を適切に推定できる仕組みが求められる。従来の統計・行政情報に基づく推計には、仮定の多さや手続きと実施の時間差等により、実態を的確に捉えにくい課題がある。

近年、衛星画像を活用した伐採面積の推定手法も多いが、推定で必須となる衛星画像の目視判読は判読者間の判断の違いが推定精度に影響し得るため、判断をできる限り統一し、再現性を高めることが重要である。

## 1.2 マニュアルの位置づけ

本マニュアルは、判読時の留意事項や、判断が難しい場合の対処方法等を整理した、判読者向けの引ききである。判読者が変わっても対応できるようにすることを目的に、目視判読の際のコツや、判断に迷ったときの決め方、決められない場合の対応を記載し、また典型的な伐採・非伐採地、目視判読が難しい箇所も含めた多くの事例を掲載した。

## 1.3 本マニュアルでの前提事項

- ❖ 本マニュアルで使用する衛星画像は、Sentinel-2 画像の年合成画像（以下コンポジット画像とする）である。具体的には、毎年春から秋に撮影された雲マスク後の画像群を収集し、それらの中央値（median）で合成した画像を判読の主対象として用いる。これにより、雲の影響を低減しつつ、対象年の地表状態を代表する画像として判読に供する。
- ❖ 本マニュアルで参照する NDVI（正規化植生指数：Normalized Difference Vegetation Index）の推移は、同じく Sentinel-2 画像から得られる値に基づく。NDVI は植生の活性の変動を把握するうえで有用な補助情報となる。
- ❖ 本マニュアルは、抽出点等の個別地点における伐採／非伐採の判定に関する留意事項を対象とし、伐採マップ作成や面積計算の手順は対象外とする。

- ❖ 判読は Sentinel-2 年合成画像を優先して伐採／非伐採を決定する。NDVI の推移を示すグラフ、Google Earth の高解像度画像、その他の補助資料は判断の裏づけとして用いる。
- ❖ 判読結果の一貫性を担保するため、判読の前に判定基準・迷いやすい事例・記録方法について共通認識を形成し、判読中は原則として各判読者が独立に判断できる運用を前提とする（体制・手順の詳細は後章で示す）。

## 2 判読体制

判読作業は、結果の客観性および推定面積の精度を確保するため、必ず3名以上で実施する。

単独判読では、入力ミスが発生しやすいことに加え、判読者個人の判断基準や経験に起因して判定結果に偏りやばらつきが生じる可能性がある。3名が独立して判読を行うことで、入力ミスや判断の偏りを相互に検出・補正でき、最終的な推定面積の精度向上が期待できる。

加えて、判読結果の取りまとめ、判読者間で差異が生じた箇所の確認・調整、ならびに最終判断の記録・管理を行うため、判読管理者を置く。

なお、判読を実施するにあたっては、実施前にトレーニングを行い判読基準および判読が難しい箇所の判断方針について共通認識を持つ。一方で、判読中は相互に相談・協議を行わず、各判読者が独立して判読を実施する。

### 3 判読の流れ

判読の流れを以下に示す。



- (1) 資料準備：判読対象地点、衛星画像、Google Earth Pro 等の判読に必要な資料・環境を準備する。
- (2) 判読者トレーニング：判読開始前に、判読基準・手順・留意事項を共有し、練習用のサンプル地点を用いて判読者のトレーニングを実施する。
- (3) 本判読：各判読者が独立して判読を実施し、所定の様式に結果を記録する。
- (4) 管理者確認・修正：判読管理者が判読結果を取りまとめ、判読者間の差異や不整合がある箇所を確認のうえ、必要に応じて修正・再確認を行う。
- (5) 判読結果の確定：最終的な判読結果を確定し、成果物として保存・共有する。

## 4 判読の基準

本章では、伐採／非伐採の判読基準を示す。

### 4.1 基本的な判定区分

本マニュアルにおける判読は、衛星画像や空中写真等を参照し、対象地点が「伐採」または「非伐採」、「判読不能」のいずれかに該当するかを判定するものである。判読クラスごとの土地被覆の状況の例を表1に示す。

表1：判読クラスとその内容

コードとクラス名	土地被覆の状況	例
0 非伐採	森林のまま変化なし	針葉樹、広葉樹、伐採跡地、樹冠被覆率 30%以上を目安とする
	伐採以外の変化	間伐、崩壊地、風倒、森林火災、0.1 ha 未満の作業道開設
	森林以外のまま変化なし	裸地（崩壊地含む）、農地、果樹園、河川、住宅、太陽光パネル、道路、樹冠被覆率 30%未満の笹地
1 伐採	皆伐地、開発地	人為的に木を切ったところ、林業的伐採箇所 0.1 ha 以上の作業道開設
	帯状択伐	伐採面積が 0.1 ha 以上の列状伐採
2 判読不能	衛星画像に起因する判読不能地点	雲、陰、ハレーション

#### 4.1.1 伐採の判定基準

伐採は森林が主伐された土地被覆変化であり、最低面積は 0.1 haとする。Sentinel-2 画像においては概ね 10 ピクセル相当を目安とする。北海道で見られる列状の伐採地については、伐採面積が 0.1 ha 以上の場合に伐採として判定する。ピクセル単位では樹木が残存している場合であっても、周囲が伐採地に囲まれており、かつ当該残存部の面積が 0.3 ha 未満の場合

は伐採として扱う。

#### 4.1.2 森林の判定基準

森林として判定するための面積は 0.3 ha 以上、林分高は 5m 以上、樹冠被覆率は 30% 以上を基準とする<sup>1</sup>。これに満たない森林は、独立した森林としては扱わない。

#### 4.1.3 伐採年の判定方法

伐採年は Sentinel-2 コンポジット画像<sup>2</sup>を基準として判定する。NDVI 図は補助的な参考資料として用い、伐採年の最終判断は行わない。例えば、コンポジット画像において 2020 年に伐採が確認できる場合、NDVI 図では 2019 年 12 月時点に変化が示されていても伐採年は 2020 年と判定する。

#### 4.1.4 使用画像と補助資料

伐採と思われる判読地点については、必ず Google Earth で確認する。判読に使う Sentinel-2 画像のプロダクトレベルが低いと、詳細な判読が困難な場合がある。その際も Google Earth 画像を参照し、視覚的な補完を行う。

#### 4.1.5 注意事項

判読作業では、色調の認識差等により、判読者間で意見が相違する場合がある。そのため、3 名の判読者による複数判読を行い、判読管理者 1 名が結果を比較・再確認し、判読結果を確定する。

### 4.2 代表的な判読例

本マニュアルでは以下の材料を判読資料として使用しており、後述の代表的な例もこれに合わせて示す。

- ❖ 各年の Sentinel-2 コンポジット画像（小）：伐採を判断したい対象年の前後の年も含めて表示。中心の小さな四角の中を判読し、年による変化や土地被覆の状況を把握す

---

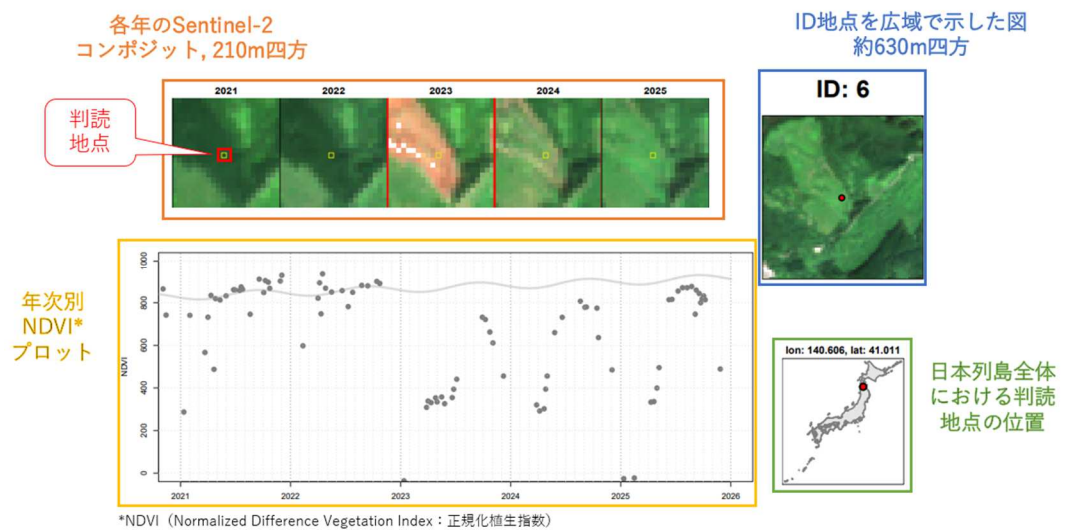
<sup>1</sup> 環境省, 「日本国の割当量に関する報告書」(2007), <https://www.env.go.jp/content/900447745.pdf>, p18 II. 京都議定書第 3 条 3,4 に基づく吸収源活動について

<sup>2</sup> 対象年の前後の状態が判読の判断で有効であるため、コンポジット画像を伐採対象年の前後も含めて作成する

る。

- ❖ 年次別 NDVI (正規化植生指数) プロット: 撮影日ごとの NDVI の推移を示したグラフで、その地点の植生の活性変動パターンが 1 年だけでなく複数年分を見ることができる。常緑樹林は比較的 NDVI が高いまま推移し、落葉樹林の場合は変動が大きい。伐採が発生すると NDVI が大落ち込むことが多い。ただし落葉樹林の場合は伐採が発生していても変化しないケースもある。
- ❖ Sentinel-2 コンポジット画像の広域図: 周辺環境および土地利用の状況を示す。Sentinel-2 コンポジット画像 (小) のうち最新年の画像を示す。
- ❖ 日本列島全体における判読対象地点の位置図: どの地点に落ちているかで、地域別の植生のイメージがとりやすい。また、地震や森林火災等の自然災害発生地域との位置関係を把握できる。
- ❖ Google Earth の併用: 伐採イベントがあるかを確定させるために Google Earth の高分解能画像を利用する。そのほか、高解像度画像による地形・形状の確認を実施し、詳細な地形条件や現地状況の補足確認を行う。

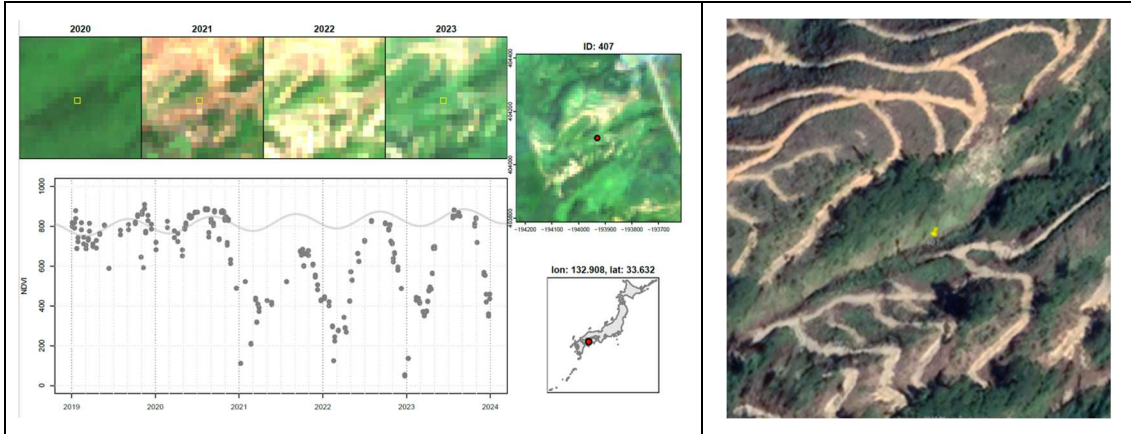
各判読対象地点の資料は、判読結果およびその妥当性を確認できるよう、各資料を下図のとおり構成して作成している。



## 4.2.1 伐採地の例

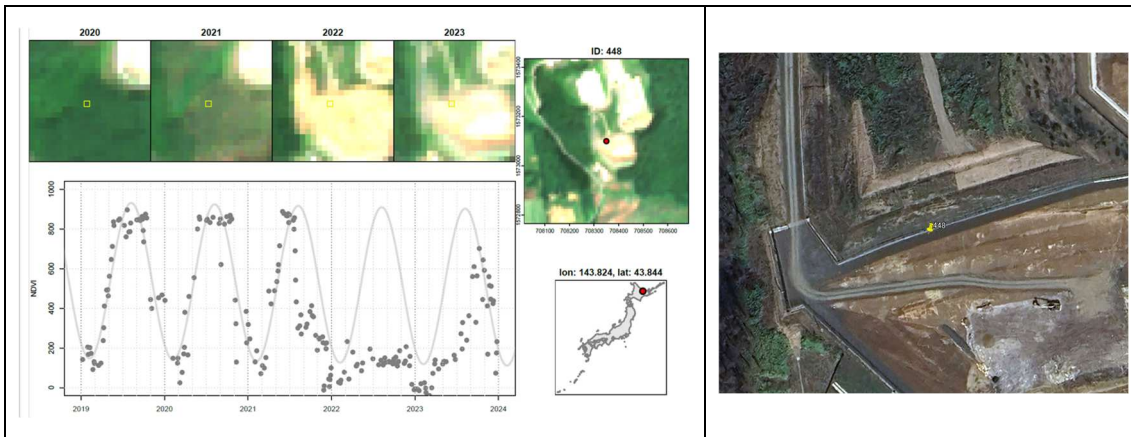
### ■ 皆伐地

2021年に森林から伐採へ変化。下部参考画像の場合、NDVIの伐採年は2020年11月だが、Sentinel-2画像を優先して2021年に伐採と判定する。



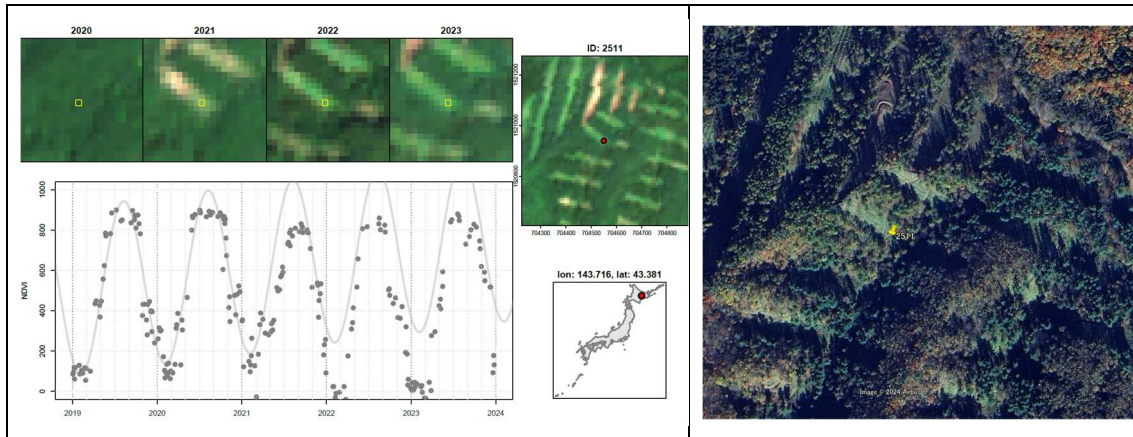
### ■ 開発地

土地転用である場合も伐採とする。



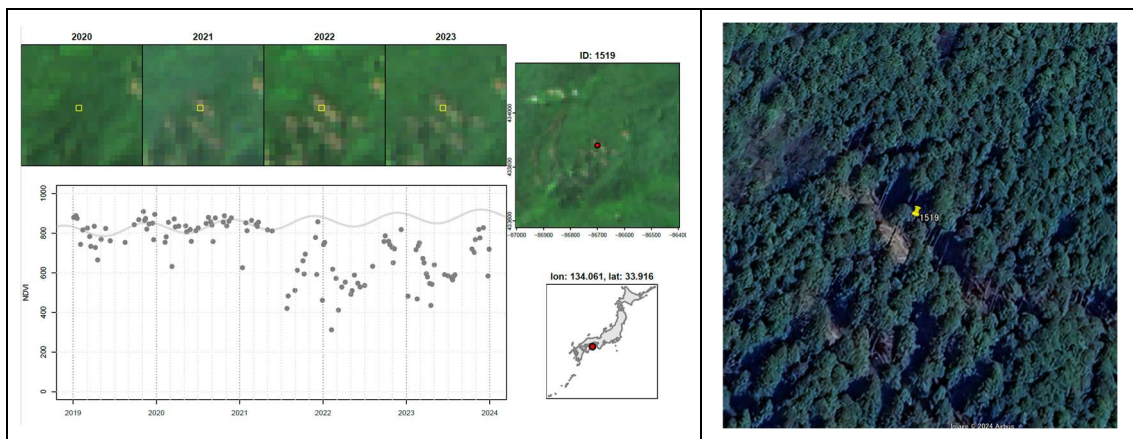
## ■ 帯状択伐

帯状の伐採（帯状択伐）の場合も伐採とする。



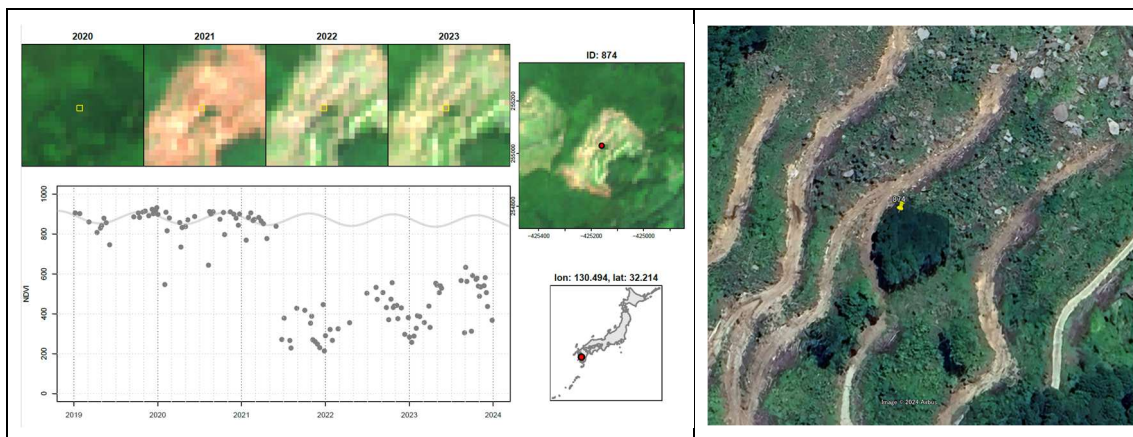
## ■ 作業道

間伐地でも、0.1 ha 以上の作業道開設は伐採とする。



## ■ 周囲主伐地

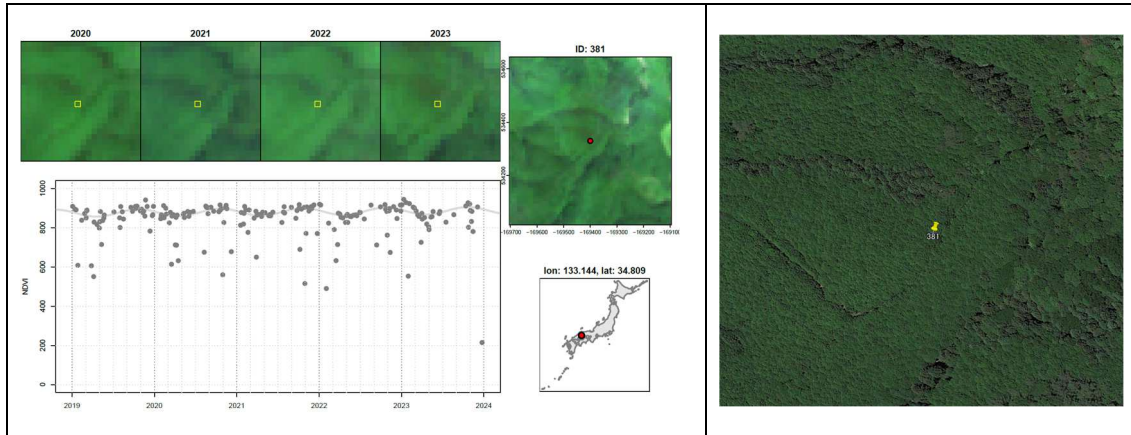
判読箇所が樹木であっても周囲が伐採されており、樹木の面積が 0.3 ha 未満であるため伐採とする。



## 4.2.2 非伐採地の例

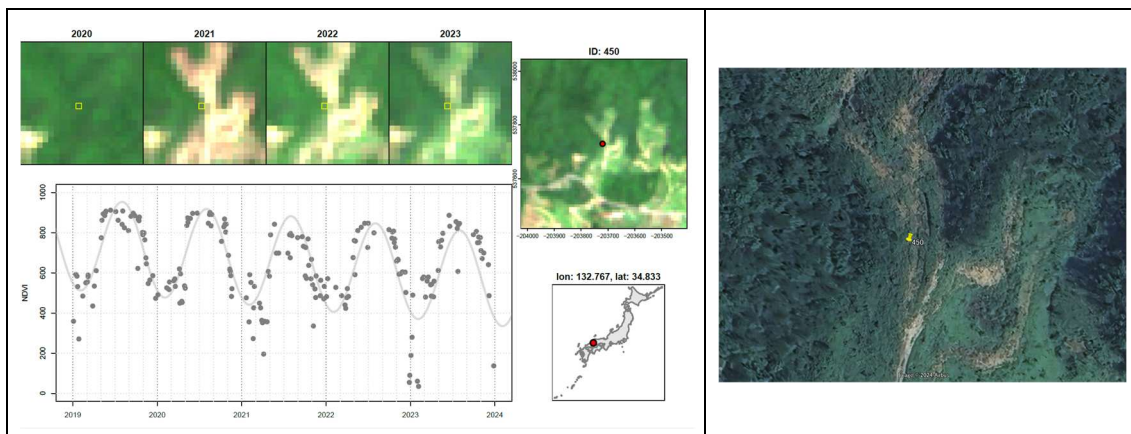
### ■ 森林のまま変化なし

伐採は確認されず、いずれの年も森林状態であるため、非伐採とする。



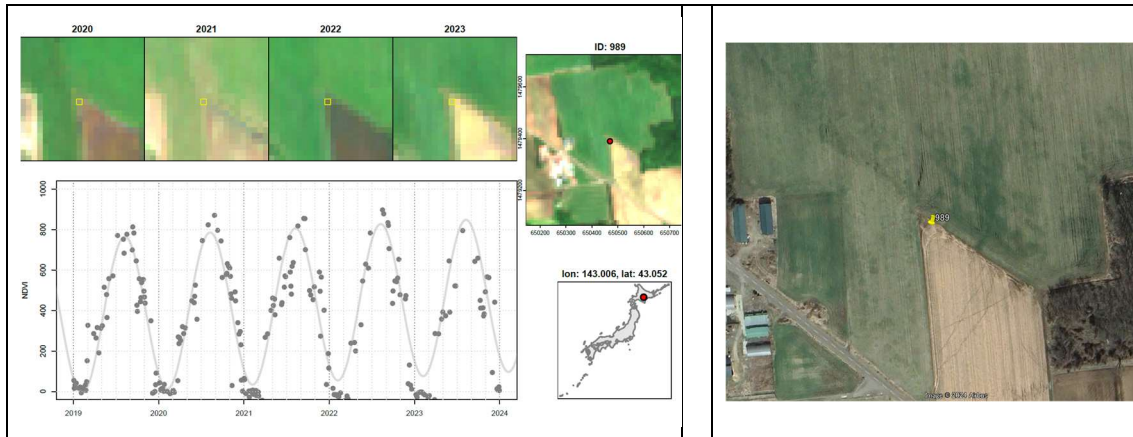
### ■ 森林のまま変化なし（境界付近）

森林伐採境界付近だが、NDVI プロットや Sentinel-2 画像を踏まえて非伐採とする。Google Earth では伐採箇所のようにも見える。



■ 森林以外のまま変化なし

土地被覆は耕作地、裸地と変化はあるが、土地利用上は農地のままで非伐採とする。



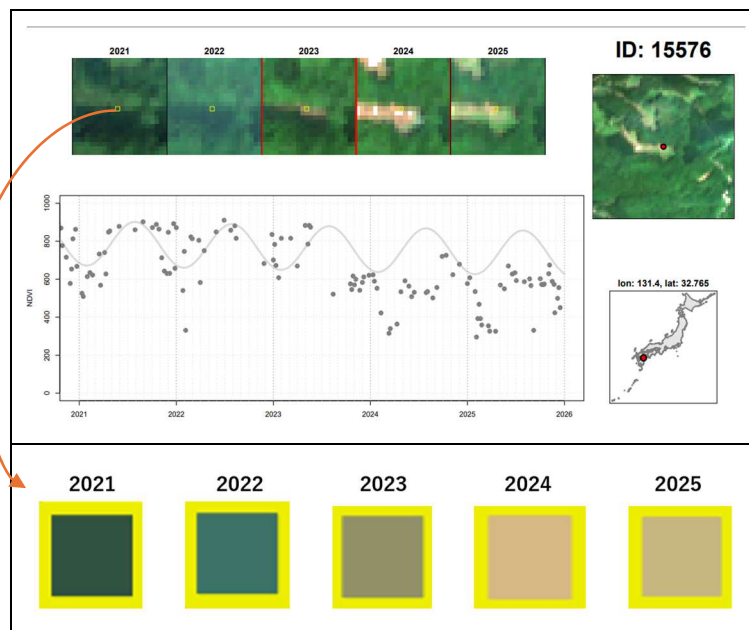
### 4.3 判読が難しい場合にか

伐採は樹冠の消失・林冠の開放等により視覚的に把握できる一方、季節変化による落葉や崩壊地など、伐採と誤認しやすい事象が存在する。以下に、判定が難しい代表例を示す。

#### 4.3.1 伐採年が決められない

■ 例1：複数年度にわたり、伐採作業が継続的に実施されている場合（伐採ケース）

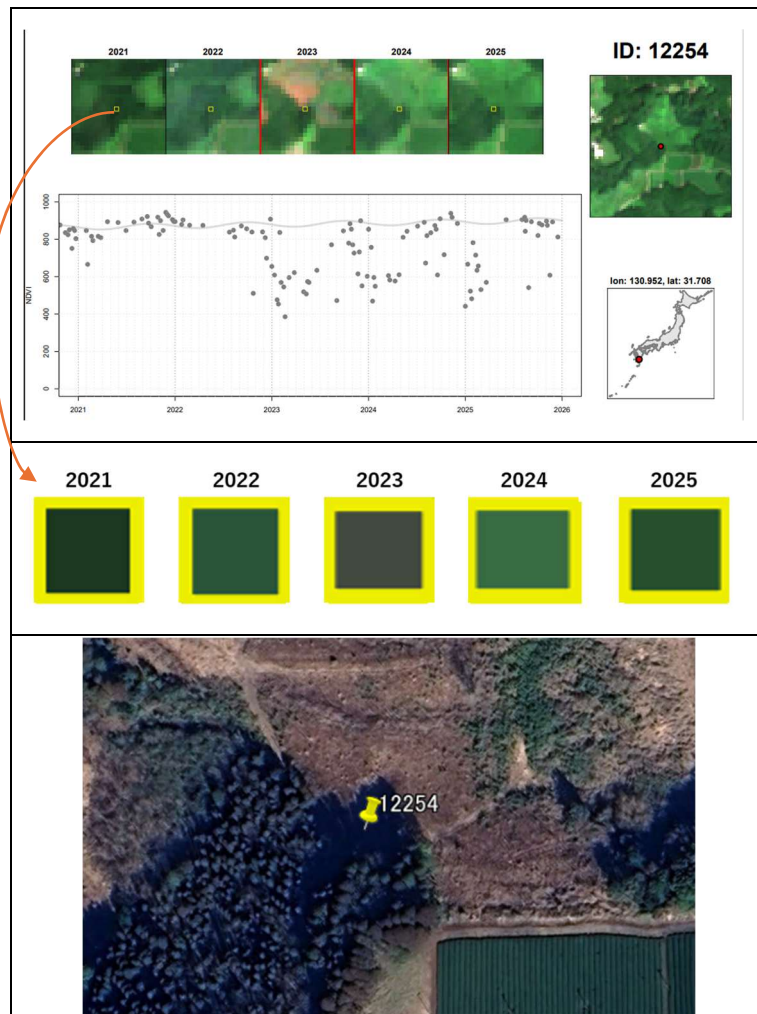
Sentinel-2 画像における色調変化を比較し、伐採後の地表状態を反映した色味が最も顕著な年を選定する。下部参考画像は 2023 年伐採とする。



### 4.3.2 位置が境界でどちらか決められない

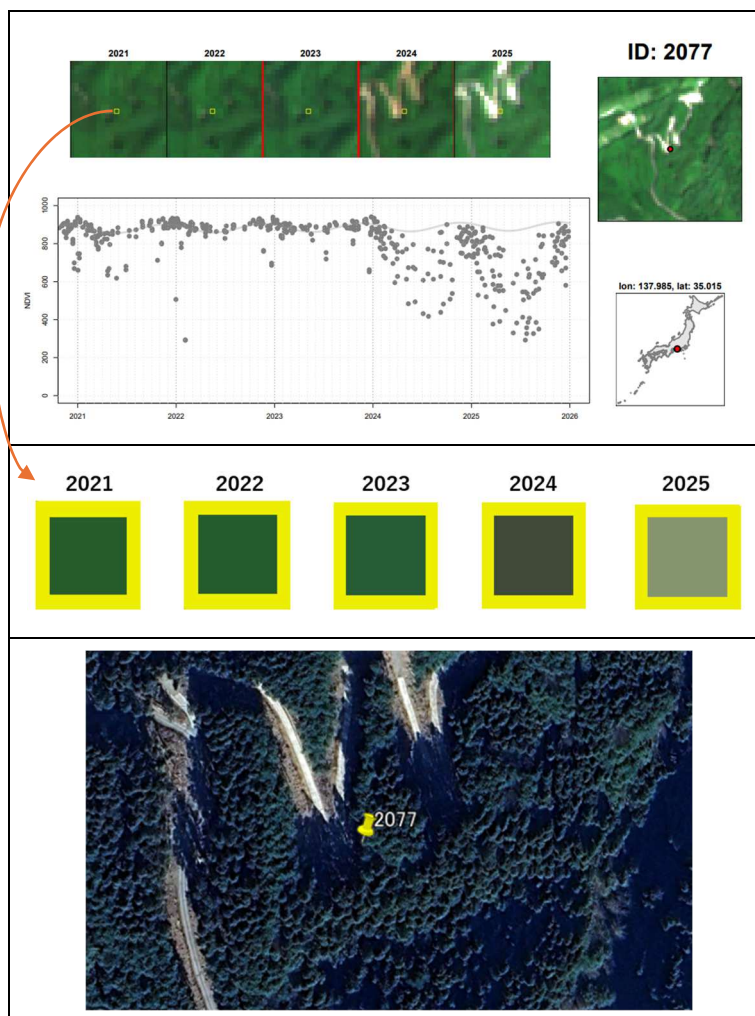
#### ■ 例1：森林に見えるが判読地点が影となっていて伐採と判断する場合（伐採ケース）

伐採地側の北側や西側は樹木の影により色味が森林に見え、伐採／非伐採の判断が難しい場合がある。NDVI プロットで明らかな落ち込みがあった場合は伐採とする。



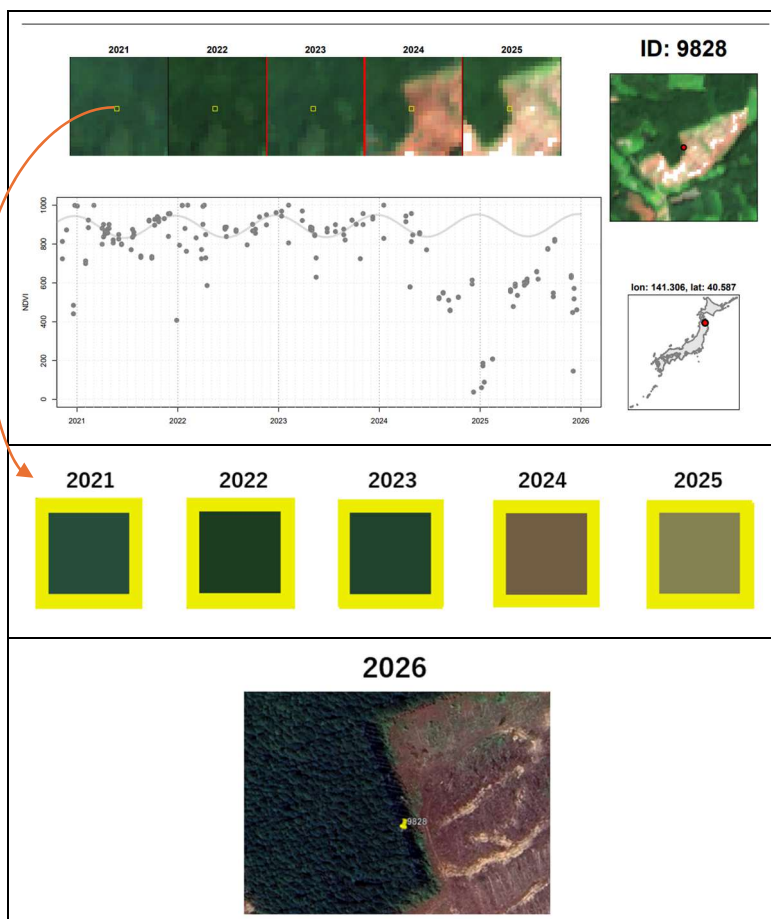
■ 例2：伐採境界付近だが、影で見えにくく NDVI プロットの落ち込みから伐採と判断する場合（伐採ケース）

作業道の境界に判読地点があり、樹木の影により、伐採／非伐採の判断が難しい例。前の例と同じく、NDVI プロットで明らかな落ち込みがあった場合は伐採とする。



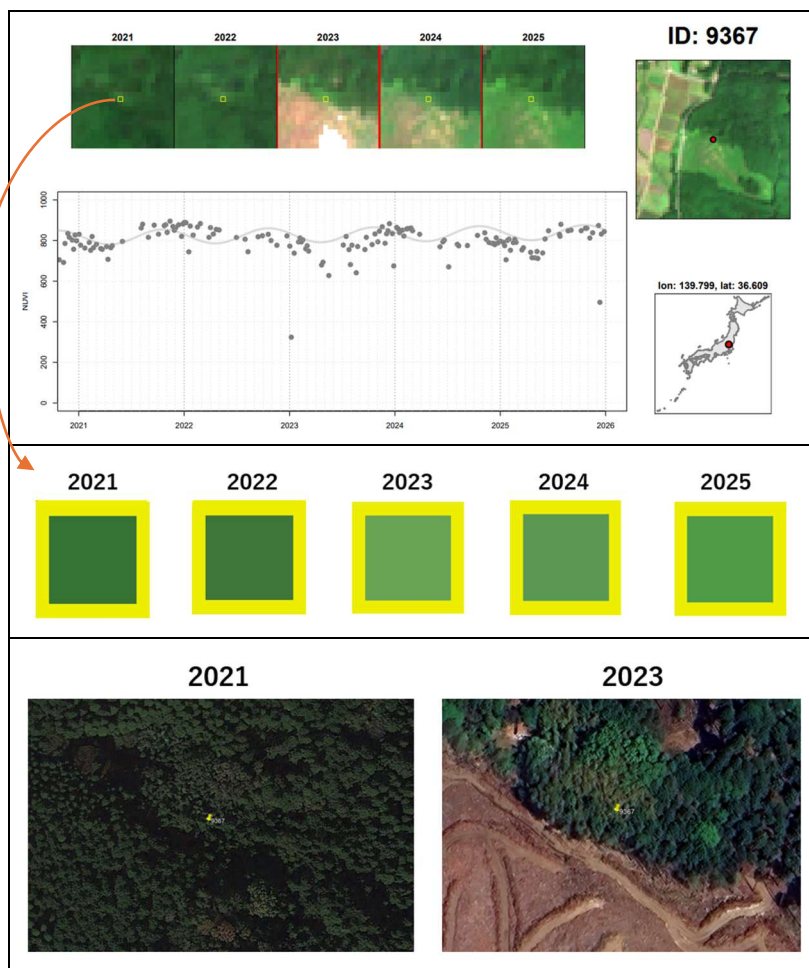
■ 例3：Google Earth 画像と Sentinel-2 画像がずれている場合（伐採ケース）

Google Earth 画像は、判読地点と完全には一致しない場合があることから補助資料として位置づけ、Sentinel-2 衛星画像を主たる判読資料とする。



#### ■ 例4：境界線を樹種別でみて判断できる場合（非伐採ケース）

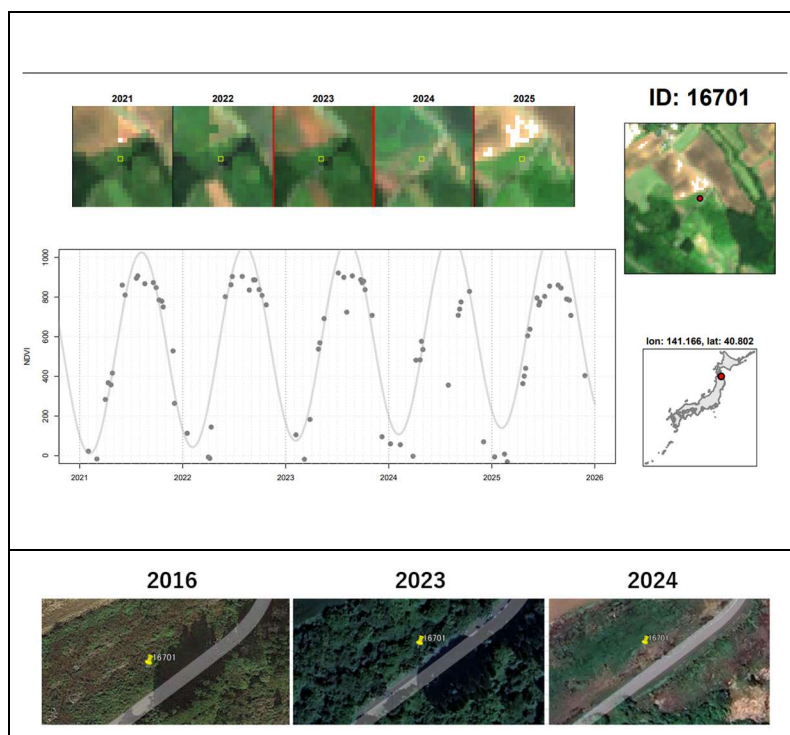
下の参考画像はスギ人工林に隣接するヒノキ林で、スギ林側が伐採されヒノキ林は残存している例。伐採前の画像でスギとヒノキ林の色味が異なることが分かる。また、Google Earthでもヒノキ林の残存が確認できる。



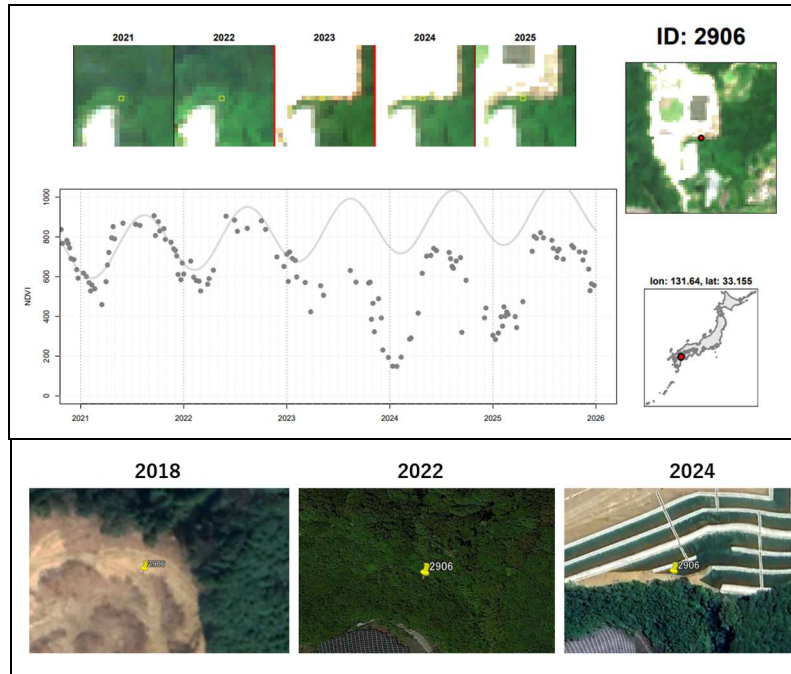
### 4.3.3 過去の変化から判断が難しい

#### ■ 例1：一度伐採が実施され、数年を経て再度伐採された場合（伐採ケース）

森林定義を満たす条件まで回復しているかを確認し、伐採の有無を判断する。例えば、再植林されていれば5年程度で樹高5m、天然更新であれば10年程度で5m程度成長していると想定し、森林として扱う。ただし、立地環境によって樹高成長の程度は異なるため、明らかに樹高が伸びていない場合は非森林扱いとする。



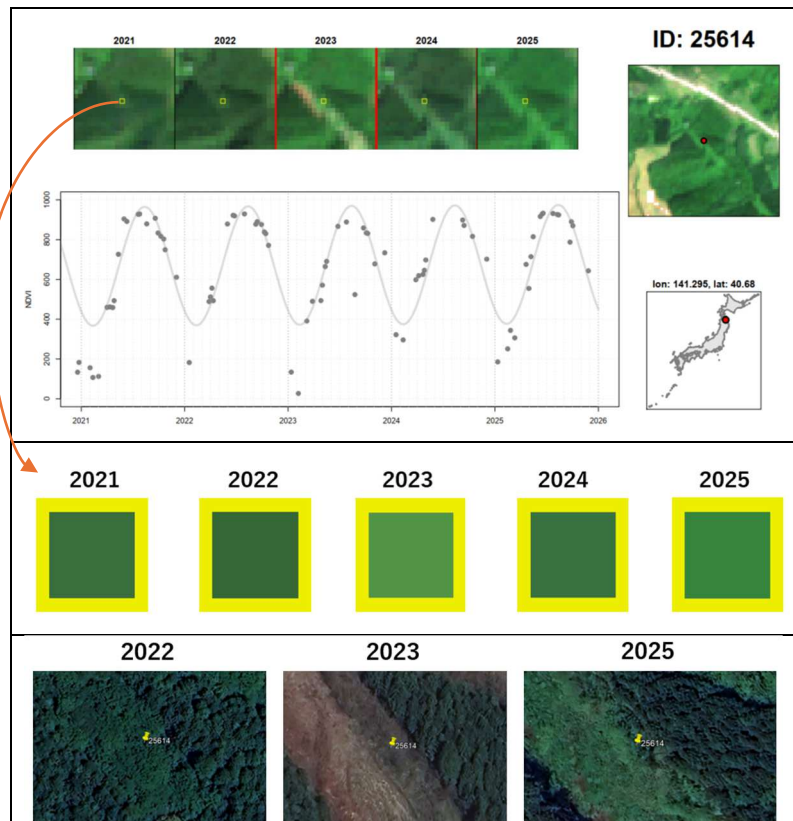
- 例2：一度伐採が実施され、数年を経て再度伐採された場合（非伐採ケース）  
森林定義を満たすまで回復しておらず非伐採と判断する。



#### 4.3.4 誤判断しやすい

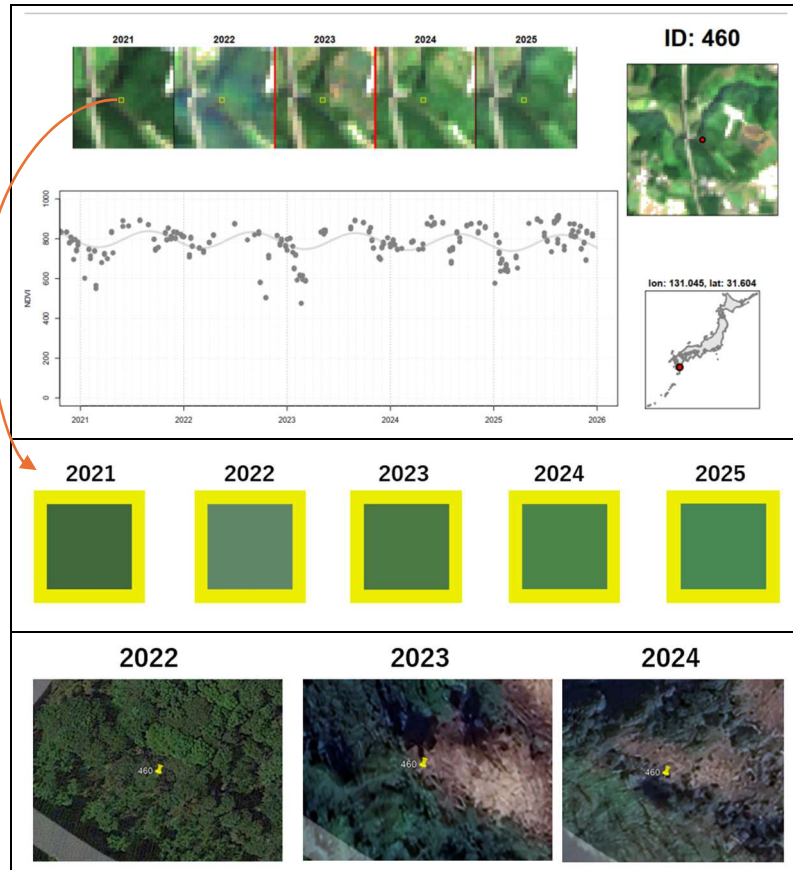
##### ■ 例 1：落葉樹の季節変化を伐採と判断しやすい場合（非伐採ケース）

2023 年の伐採に隣接する落葉樹林で、2023 年の Google Earth 画像では一見伐採に見えるが、落葉している状態の森林である。



■ 例 2：常緑樹で NDVI の大きな変化がみられない場合（伐採ケース）

落葉樹林ではなく常緑樹でも NDVI に大きな変化がないケースも稀にある。

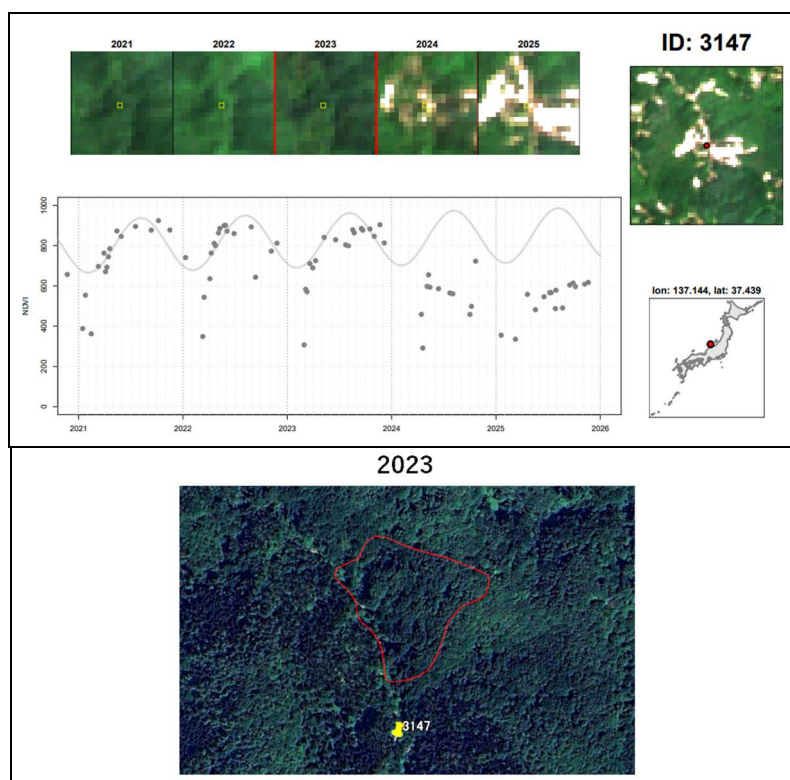


### 4.3.5 崩壊地 GIS ポリゴンエリア外の伐採判断

災害により崩壊地が多発している場合、国土地理院などから崩壊地ポリゴンが提供されており、伐採／非伐採の判定に有効である。ここでは能登半島における崩壊地ポリゴンを使った場合の伐採／非伐採判定が難しかった例を示す。

#### ■ 例1：崩壊地 GIS エリア外で、森林変化後の Google Earth 画像がなく、伐採のような場所が確認できる場合

下の例では、開発地近くであったため伐採の可能性もあるとして伐採判定とした。



なお、崩壊地の関わるケースについては、機械的に「伐採」または「非伐採」と一律に判定することは適切ではなく、対象地点の状況に加え、周辺の土地利用状況や地形条件等を踏まえた総合的な判断が必要である。

崩壊地に該当する場合、崩壊後は複数年にわたり裸地状態が継続することが多く、衛星画像上では白色系の色調が複数年連続して確認される傾向がある。また、伐採地とは異なる特徴的な形状（例：扇状に広がる裸地、谷地形に沿って樹木が消失している形状等）が認められる場合には、斜面崩壊や地すべり等による崩壊地と判断し、非伐採として区分する（図1）。



図1 斜面崩壊と土石流

(出典) GeoInformation Portal Hub (GIPH)「土砂災害全般について(地質の解説)」

[https://www.web-gis.jp/GS\\_Topics/Doshasaigai/Doshasaigai1.html](https://www.web-gis.jp/GS_Topics/Doshasaigai/Doshasaigai1.html)

## 5 管理者の役割

判読管理者は、各判読者が提出した判読結果を取りまとめ、内容を確認する。確認の結果、入力ミスや判断根拠の不足、判読者間での不整合等が認められた場合は、該当する判読者に問い合わせて、修正または再確認を依頼する。必要な修正が反映され、結果の整合性が確認できた段階で、判読結果を最終的に確定する。

判読管理者の役割は、判読結果の品質（精度・再現性）を担保するための中核である。目視判読は、同一地点であっても判読者の経験や解釈の違いにより判断が分かれ得るため、管理者が基準の運用状況を点検し、判断の揺れや不整合を早期に検出・是正することが、推定結果の信頼性に直結する。特に、入力ミスや根拠情報の不足、判読者間の判定差が放置されると、伐採面積の推定に系統的な偏りが生じる可能性がある。このため管理者は、差戻し・再確認を通じて記録の完全性と判断根拠の明確化を徹底し、必要に応じて迷いやすい事例の判断方針を共有することで、判読基準の統一と作業品質の平準化が期待できる。これらの確認を経て整合性が確保された段階で判読結果を確定することにより、受託者や担当者が変わった場合でも、一定の品質で継続的に判読業務を実施できる。

## 6 最後に

衛星画像の判読では、撮影時の状況が都度異なり、また現地の施業状況も作業道開設から造林といった様々な段階にあること、また判読地点も影や土地被覆の境界に位置することもあり、すべての地点を完全に判読することは難しい。したがって、本作業では「誤りをゼロにする」ことを目的とするのではなく、判断の根拠を明確にし、迷いが生じた場合の対処を定めることで、判読結果の一貫性と再現性を高めることが重要となる。

この観点から、判読は可能な限り複数人数で実施し、個々の判断差を前提として相互に補完する体制とすることが望ましい。複数の判読者が関与することで、見落としや入力ミスが発見、判断の偏りの抑制、迷いや事例の共有が進み、結果として伐採面積推定の信頼性向上につながる。

さらに、これらの体制を機能させるためには、判読管理者の配置が不可欠である。判読管理者は、判読結果を取りまとめるだけでなく、判断根拠の不足、入力ミス、判読者間の不整合を点検・是正し、基準の運用を統一する役割を担う。管理者による確認とフィードバックがあることで、判読の品質が平準化され、担当者や受託者が変わった場合でも一定の品質で作業を継続できる。

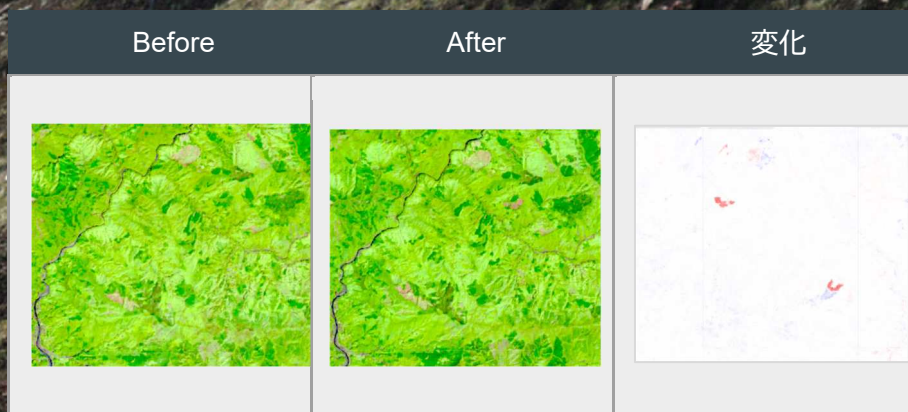
本マニュアルは、判読に伴う不確実性を前提としつつ、判断の手掛かりや迷ったときの考え方、記録の仕方を整理したものである。実際の運用の中で生じた迷いや新たな事例は継続的に追記・更新し、より再現性の高い判読手順として改善していくことが望まれる。

### 6.3. FAMOST 活用マニュアル

FAMOST を活用した

# 伐採マップ作成マニュアル

Google Earth Engine を使って変化抽出



林野庁

令和8年3月

## 目次

1	はじめに .....	138
1.1	背景・目的.....	138
1.2	FAMOST の概略.....	138
1.3	処理の流れ.....	139
1.4	出力仕様 .....	140
1.5	用語 .....	140
2	Google Earth Engine のアカウント作成と初期設定 .....	141
3	FAMOST スクリプトの準備 .....	142
3.1	AOI の準備と設定.....	142
3.2	スクリプトの新規作成と貼り付け .....	144
3.3	主要パラメータ（ユーザー設定） .....	145
4	実行手順 .....	147
4.1	実行（Run）と画面の見方.....	147
4.2	表示レイヤ（本スクリプト） .....	149
4.3	差分指標を調整したいとき .....	149
4.4	Export の設定（任意） .....	150
5	Export（Tasks）とファイルのダウンロード方法.....	151
6	トラブルシューティング（FAQ） .....	152
7	付録：スクリプト全文.....	153

## 1 はじめに

本書は、FAMOST (伐採・擾乱候補抽出) を Google Earth Engine (以下 GEE) Code Editor 上で実行し、結果を GeoTIFF として出力し、GIS で利用するまでの手順をまとめたものです。市町村が無償で使用することを念頭に公開してきた、旧来の Web UI (フォーム入力→ボタン実行) による FAMOST 運用システムが、Google earth engine 利用規約の改定により無償での利用ができなくなったことを受け、スクリプト運用が可能な技術者向けの手引きとして作成しました。

本マニュアルでは「ある程度 GIS を扱え、スクリプトに記載の変数や Asset ID 等の一部を書き換えられる利用者」を想定しています。GEE の利用形態 (無料/有料)、利用規約、処理上限、入力データの更新状況などにより、実行可否や結果が変わる可能性があります。

### 1.1 背景・目的

本章では、マニュアルの背景・目的と、運用の前提 (どこを利用者が設定し、どこが固定値か) を整理します。FAMOST のスクリプトは、解析範囲 (AOI)、比較する期間 (before/after)、雲・影の条件、最小パッチ (mmu) 等をユーザーが設定できます。それ以外の処理はスクリプト内の既定値で動作します。

旧 UI で行っていた「県の選択・最小面積の入力・実行」相当の操作は、GEE Code Editor では (1) AOI の指定、(2) ユーザー設定変数の編集、(3) Run および Tasks 実行、に置き換わります。

### 1.2 FAMOST の概略

FAMOST は、林野庁事業「令和 3 年度 森林情報活用促進事業のうち「無断伐採の把握体制の整備」と「令和 4 年度 伐採造林届出制度の効果的な運用に向けたリモートセンシング技術活用促進に関する調査事業」で開発された伐採地把握システムです。本マニュアルでは、**Sentinel-2 衛星画像**を対象期間の前後で比較し、植生・水分・焼失等に関する複数の指標の差分から「森林域の変化 (伐採・擾乱の可能性が高い場所)」を抽出する処理を示しています。抽出結果は確定した伐採地ではなく“候補”であり、必ず目視確認や現地情報等と併用して利用してください。

実行スクリプトでは、クラウドマスク処理された Sentinel-2 画像 (Sentinel-2 SR の SCL と

s2cloudless) を用いて雲・影等を除外した上で、複数指標の閾値判定を AND 条件で重ね合わせ、最後に mmu で小領域ノイズを除去します。

### 1.3 処理の流れ

ここでは、運用時に利用者が準備するものと、巻末の 7.付録に記載したスクリプト内部の処理ステップ (節 0~7) の関係を整理します。AOI (解析対象範囲) の GEE への登録と、スクリプトが参照する Asset の権限確認に初回は少し時間を要する場合があります。

運用の基本は「入力データを整える → スクリプト実行で結果を確認 → 必要に応じて条件を調整 (繰り返し) → Export して GIS で利用」です (図 1)。

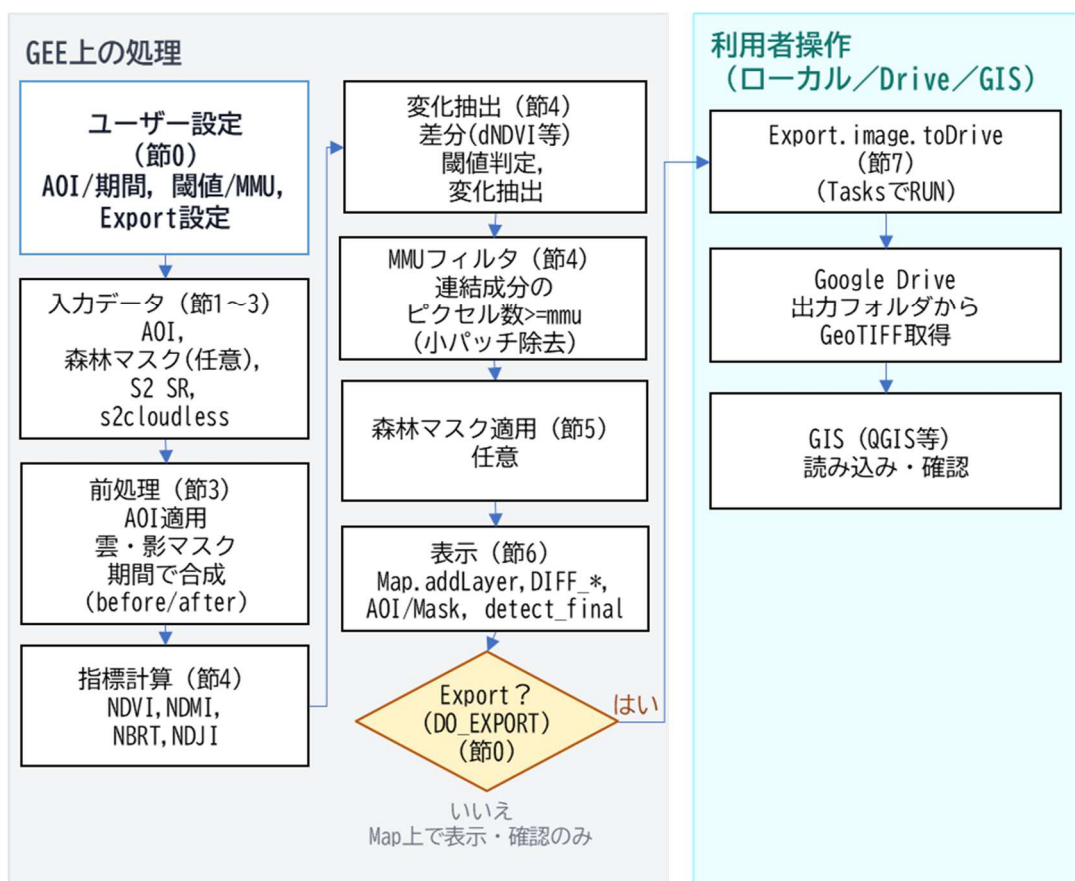


図 1 処理フロー図

## ■ 自分で準備するもの

- 解析対象範囲の GIS ポリゴン (AOI) をまず準備し、これを GEE の Assets に登録し、FeatureCollection (Asset ID) を取得します。
- (任意) 森林マスク画像 (Forest Mask) を準備し、GEE の Assets に登録。森林域のみ抽出したい場合に使用します。
- 出力先となる Google Drive (フォルダ名はスクリプトの EXPORT\_FOLDER で指定)
- 動作確認用に小さめの AOI (10km 四方程度) を用意しておく、エラーの切り分けがしやすくなります。

## ■ スクリプトの流れ

スクリプト本体は付録に記載されています。

- 節 0: ユーザー設定 (AOI/Export/雲条件/ mmu /期間など、運用で主に変更する部分)
- 節 1: AOI の作成 (FeatureCollection から解析範囲 Geometry を作成し、AOI 外をマスク)
- 節 2: 森林マスク (任意で設定。USE\_FOREST\_MASK=true の場合に適用)
- 節 3: Sentinel-2 SR と s2cloudless による雲・影マスク、期間内の画像を合成
- 節 4: 指標差分の計算と閾値判定 (複数指標を AND で統合)、mmu で小領域を除去
- 節 5~7: 表示用レイヤ追加、Export (任意)

## 1.4 出力仕様

出力される GeoTIFF は 0/1 の数値で構成される画像で、値 1 が「伐採・擾乱候補」を表します。候補域には誤検出 (過検出) や見逃し (検出漏れ) が含まれるため、差分画像 (DIFF\_NDVI, DIFF\_NBRT) や before/after の擬似カラー表示と合わせて確認してください。

Export の既定設定では、座標系に EPSG:3857、解像度に 10m (EXPORT\_SCALE=10) を指定しています。AOI が UTM 帯をまたぐ場合などは、出力座標系を明示することで後工程 (GIS) での取扱いが安定します。

## 1.5 用語

- AOI: 解析対象範囲 (Area of Interest)
- Task: GEE の Export 等の非同期処理
- Asset: GEE の Assets に登録されたデータ (画像・ベクタ)
- mmu: Minimum Mapping Unit。本スクリプトでは「連結したピクセル数」が mmu 以上

の領域だけを残し、小さなノイズを除去

- **before/after** : 比較する 2 期間の期首の年と期末の年。2 時期とも展葉期の同じ期間 (例 : 5/1-10/31) で設定し、フェノロジー差の影響を抑える
- **Export** : GEE の結果を Drive 等へ書き出す処理。Code Editor の Tasks で手動実行

## 2 Google Earth Engine のアカウント作成と初期設定

GEE の利用には Google アカウントと Earth Engine の利用登録が必要です。すでに利用可能なアカウントがある場合は、Code Editor にログインできること (画面が表示されること) をまず確認してください。

推奨されるブラウザは、Chrome/Edge (最新版推奨) です。

登録の入口 :

- Earth Engine トップ : [earthengine.google.com](https://earthengine.google.com)

✓ 新規登録は以下のサイトを参考 :

<https://zenn.dev/labcode/books/2xvfkoic4p7biv/viewer/3dwu9c-3>

- ログインの入口 : Code Editor : [code.earthengine.google.com](https://code.earthengine.google.com)

※ 組織の運用方針により、Google Cloud プロジェクトの作成や請求設定 (Billing) が必要になる場合があります。利用できない場合は、組織内の管理者・担当者に確認してください。

ログインすると、図2に示したような画面が表示されます。左上に、Script/Docs/Assets タブが配置、中央上にスクリプトのエディタ画面が配置、右上に Inspector/Console/Tasks タブ、下に Map 画面が配置されています。

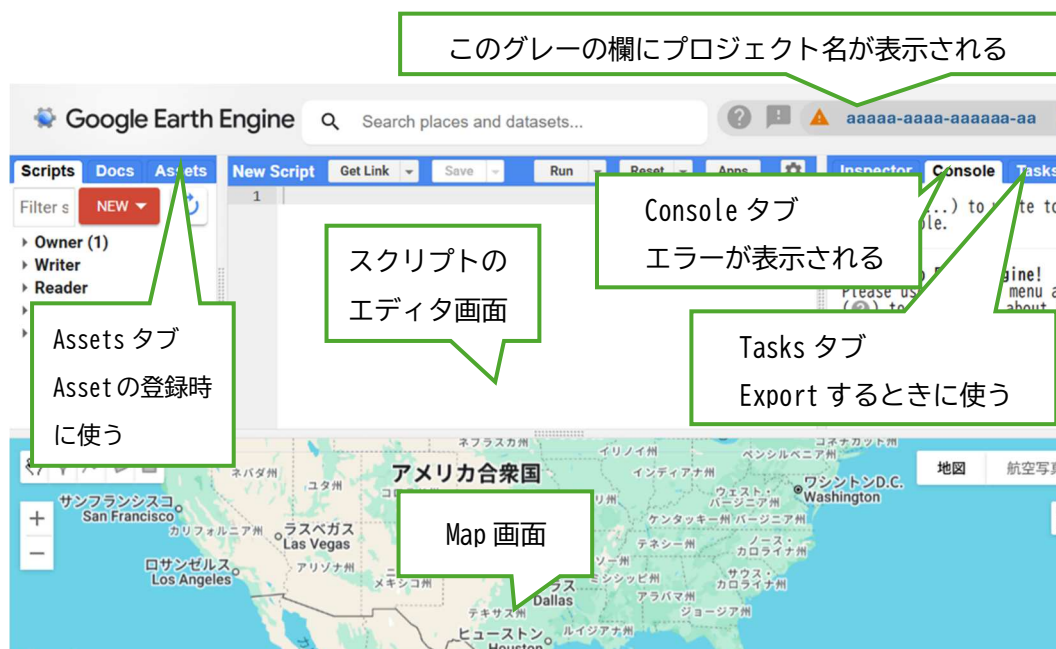


図2 GEE Code Editor トップ画面

### 3 FAMOST スクリプトの準備

本章では、付録に掲載したスクリプト全文を GEE Code Editor に貼り付け、実行できる状態に整えます。運用上、利用者が変更するのは主に「節 0：ユーザー設定」です（AOI、期間、雲条件、mmu、Export 設定など）。

スクリプトが参照する Asset（AOI の FeatureCollection、森林マスク等）が存在し、かつ閲覧権限があることが前提です。権限が不足していると、実行時に Asset not found / Permission denied などのエラーになります。

#### 3.1 AOI の準備と設定

AOI は解析対象範囲を示すポリゴンで、GEE の Assets に FeatureCollection として登録しておく必要があります。旧 UI の「県選択」に相当する範囲指定は、AOI（ポリゴン）で実現します。

##### ■ AOI を用意する方法（例）

- (1) QGIS 等 GIS ソフトでポリゴンを作成（既存のポリゴンでも利用可能）

- (2) SHP ファイル一式を出力
- (3) GEE Code Editor の Assets タブからアップロード（QGIS で出力時の qmd ファイルは Asset に登録しない）（図 3）
- (4) 表示されるアセット名（Asset ID）をスクリプトの AOI\_FC\_ASSET\_ID の該当箇所に設定（「3.3 主要パラメータ（ユーザー設定）」で設定）

複数ポリゴンを有する AOI を 1 つの FeatureCollection として運用する場合は、GIS ソフトであらかじめ属性フィールド（例：pref\_code、name 等）を持たせ、スクリプトの AOI\_FILTER\_FIELD / AOI\_FILTER\_VALUE で抽出対象を切り替えます。

※ AOI のポリゴンが自己交差等で不正な場合、エラーや結果の欠落の原因になります。アップロード前に GIS 側でジオメトリチェックを推奨します。



図 3 GEE Code Editor の Assets タブからの SHP ファイル登録画面

## 3.2 スクリプトの新規作成と貼り付け

GEE Code Editor では、「Scripts」でスクリプトを新規作成し（図4）、本文末尾（付録）のスクリプトをそのまま貼り付けて保存します。貼り付け後は、まず保存しましょう。

### ■ 流れ

- GEE Code Editor の「Scripts」→「NEW」→「FILE」を選択し、Create file 画面で File Name を指定
- スクリプト全体を貼り付け、保存（Save）（図5）

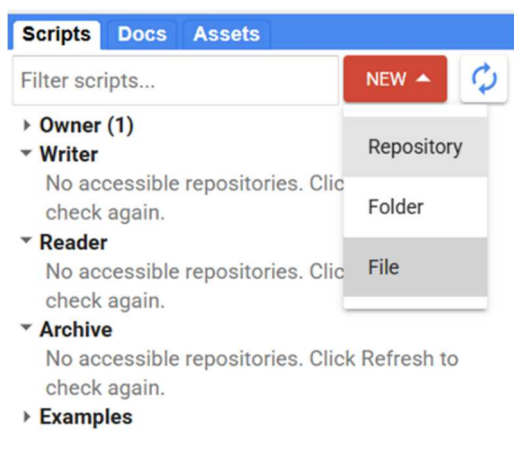


図4 Scripts パネルでスクリプトを新規作成

```
59 // 0. ユーザー設定（ここだけ変えれば運用できる）
60 // =====
61 // -----
62 // AOI (FeatureCollection)
63 // -----
64 // -----
65 var AOI_FC_ASSET_ID = 'projects/プロジェクト名/assets/AssetsにアップしたAOIのAsset名';
66
67 // AOIを「複数から選択」する場合：属性列名と値を設定（単一AOIの場合は null）
68 var AOI_FILTER_FIELD = null; // 例：'CODE' / 'id' / 'NAME' 等。単一AOIなら null
69 var AOI_FILTER_VALUE = null; // 例：45 / 'Tokyo' / ['A','B'] 等。単一AOIなら null
70
71 // 表示/出力用のAOI名称（任意）
72 // (AOIが複数候補からの選択でも、出力名に混ぜて識別しやすくするため)
73 var AOI_NAME = 'AOI';
74
75 // -----
76 // Forest mask（任意）
77 // -----
78 var USE_FOREST_MASK = true; // true: Forestマスクを使う / false: 使わない
79
80 var FOREST_ASSET_ID = 'projects/プロジェクト名/assets/Assetsにアップした森林マスクのAsset名';
81
82 // -----
83 // 出力（Export）
84 // -----
85 var DO_EXPORT = true; // true: Export 実行 / false: Export しない
86 var EXPORT_FOLDER = 'GEE export FOREST';
```

図5 貼り付け後のエディタ画面

### 3.3 主要パラメータ（ユーザー設定）

本スクリプトは、冒頭の「節 0：ユーザー設定」を編集します。まずは小さな AOI を使い既定値のまま動作確認し、その後に期間・雲条件・mmu・閾値を調整してください。

#### ■最初に調整することが多いパラメータ

- 閾値（dNDMI/dNDVI/dNBRT/dNDJI）はスクリプト内に記載された固定値を使うが、必要に応じてスクリプトの節 4 に記載の閾値を調整可能
- 値を変更したら保存し、再実行（Run）

#### ■主な設定項目（節 0：ユーザー設定）

設定箇所	必須/任意で書き直し	意味
AOI_FC_ASSET_ID	必須	解析対象ポリゴン（FeatureCollection）の Asset ID（projects/プロジェクト名/assets/Asset 名）を必ず入力
AOI_FILTER_FIELD, AOI_FILTER_VALUE	複数ポリゴンを含む AOI を使う場合は必須	複数のポリゴンを含む AOI ファイル（例えば林班や市町村ポリゴン）が 1 つの FeatureCollection に入っている場合に、属性で抽出対象を絞り込むための設定。一つのポリゴンのみの AOI の場合は両方 null を入力
USE_FOREST_MASK, FOREST_ASSET_ID	任意	（任意）森林域に限定して抽出したい場合に使用。Asset ID を入力。 Forest Mask で設定された値により、スクリプト内の gt(0) を eq(1) 等に調整（コメント「2 節に記載の★マスク仕様に応じて変更」参照）
DO_EXPORT	任意	伐採マップを GIS ソフト等で表示したい場合は true のまま、出力不要の場合は false に書き換え
EXPORT_FOLDER	出力する場合は Export 必須	利用者の Google Drive にフォルダをあらかじめ作成し、その名前書き換える
CLOUD_FILTER	任意	画像を解析に使うか選ぶためのフィルタ Sentinel-2 メタデータの雲量（CLOUDY_PIXEL_PERCENTAGE）の上限を設定。値を小さくすると雲が少ない画像に絞られるが、画像枚数が不足しやすくなる
CLOUD_PROB_TH	任意	画像を選んだあと、雲を“ピクセル単位”で消すためのしきい値 雲 確 率 し き い 値（probability > CLOUD_PROB_TH を雲とみなす）を設定
startYear endYear startDay endDay	年は必須、日には任意	before/after の期間設定 原則として同じ期間で比較することを推奨
mmu	任意	最小パッチ（ピクセル数） 抽出結果の連結領域のうち、連結ピクセル数が mmu 以上の領域だけを残す

mmu (最小パッチ) と connectedPixelCount の意味

スクリプトでは、まず閾値条件を満たすピクセルを changes として作成し、connectedPixelCount により各ピクセルが属する連結領域の「連結ピクセル数」を計算します (今回は 20 ピクセルで設定)。その後 .gte(mmu) により mmu 以上の領域のみを残します (= mmu 未満の小領域を除去)。connectedPixelCount の引数 20 は“連結ピクセル数の集計上限”で、連結領域が 20 ピクセルを超える場合でも 20 で打ち切ってカウントします。したがって、mmu=10 のように  $mmu \leq 20$  であれば運用上問題ありませんが、mmu を 20 より大きく設定する場合は、connectedPixelCount の上限値も同等以上に見直してください。

ユーザー設定のスクリプト箇所を下に抜粋しています。青色でハイライトした箇所は必ず入力し直しが必要で、黄色でハイライトした箇所は必要に応じて入力し直してください。

```
// 0. ユーザー設定 (ここだけ変えれば運用できる)
var AOI_FC_ASSET_ID = 'projects/プロジェクト名/assets/Assets にアップした AOI の Asset 名'; //利用者のプロジェクト名と Asset 名を入力
var AOI_FILTER_FIELD = null; //複数 AOI のときは例: 'CODE' / 'id' / 'NAME' 等,
単一 AOI なら null
var AOI_FILTER_VALUE = null; //複数 AOI のとき例: 45 / 'Tokyo' / ['A', 'B'] 等,
単一 AOI なら null
var AOI_NAME = 'AOI';

var USE_FOREST_MASK = true; // 森林マスクを使うかは任意 true: Forest Mask を使う / false: 使わない
var FOREST_ASSET_ID = 'projects/プロジェクト名/assets/Assets にアップした森林マスクの Asset 名'; //利用者のプロジェクト名と Asset 名を入力

var DO_EXPORT = true; // true: Export 実行 / false: Export しない
var EXPORT_FOLDER = 'GEE_export_FAMOST'; //任意のフォルダを利用者の Google Drive に作成
var EXPORT_CRS = 'EPSG:3857';
var EXPORT_SCALE = 10; //ピクセルサイズ(m)

var CLOUD_FILTER = 50;
var CLOUD_PROB_TH = 50;
var mmu = 10;
```

```
var startYear = 2022;  
var endYear   = 2023;  
var startDay  = '-05-01';  
var endDay    = '-10-31';
```

## 4 実行手順

実行前に、節 0 (ユーザー設定) の AOI・期間・雲条件・mmu (必要なら森林マスク、Export 設定) を再確認しておきます。

Run によりスクリプトを実行すると、マップ画面の地図上のレイヤ (Layers) に結果と確認用の補助レイヤが追加されます。

マップ画面での確認手順は、

- (1) AOI が正しい位置・範囲か、
- (2) before/after の擬似カラー (S2 before/after) で季節や雲の影響が大きすぎないか、
- (3) 差分画像 (DIFF\_NDVI や DIFF\_NBRT) の青～赤色の分布、
- (4) 最終結果 detect\_final で示される伐採候補箇所と (3) の画像を見比べ、  
の順に確認し、必要に応じてパラメータを調整する流れです。

### 4.1 実行 (Run) と画面の見方

Run を押すと (図 6)、画面上部のスクリプトが GEE サーバ側で実行され、Map/Layers/Console に結果が反映されます。実行後の Map 画面とレイヤ画面を図 7 に示します。図 8 に Deforestation の箇所が示されたマップ画面 (上図)、NBRT の差分画像が表示されたマップ画面とレイヤ画面 (下図) を示します。初回や AOI が広い場合は計算量が大きく、実行に時間がかかることがあります。

エラーが出た場合は、Console の赤字メッセージに表示される行番号・内容を手掛かりに、Asset ID の誤り/権限不足、期間や AOI が大きすぎる、パラメータの型 (null/配列/文字列) の不一致、などを切り分けます。

※ Export (Drive 出力) は Run だけでは開始しません。DO\_EXPORT=true の場合に Tasks にタスクが作成され、Tasks 側で RUN すると Export が開始します。

```

FAMOST
Get Link Save Run Reset Apps
125 if (Array.isArray(AOI_FILTER_VALUE)) {
126   AOI_FC = AOI_FC_ALL.filter(ee.Filter.inList(AOI_FILTER_VALUE));
127 } else {
128   AOI_FC = AOI_FC_ALL.filter(ee.Filter.eq(AOI_FILTER_VALUE));
129 }
130 }
131
132 var AOI = AOI_FC.geometry();
133
134 // AOI内マスク (AOI外は解析しない)
135 var aoi_mask = ee.Image().byte().paint(AOI_FC, 1).rename('AOI_mask').unmask(0);
136
137 // 出力名に付ける識別子 (AOI_FILTER_VALUE があればそれも入れる)
138 var aoi_id_str = (AOI_FILTER_VALUE === null) ? 'ALL'
139   : (Array.isArray(AOI_FILTER_VALUE) ? 'MULTI' : String(AOI_FILTER_VALUE));
140
141 var name_string = AOI_NAME + '_' + aoi_id_str + '_' + startYear + 'to' + endYear;
142
143

```

Run ボタン

図6 Run ボタン

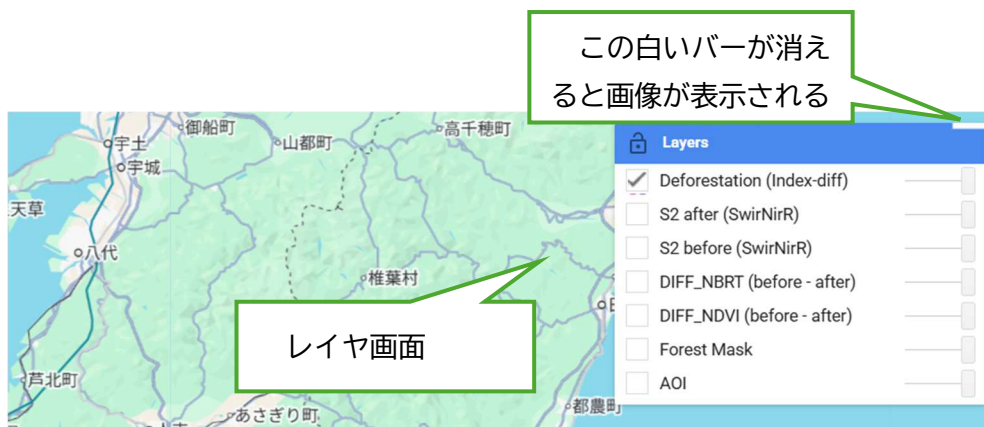
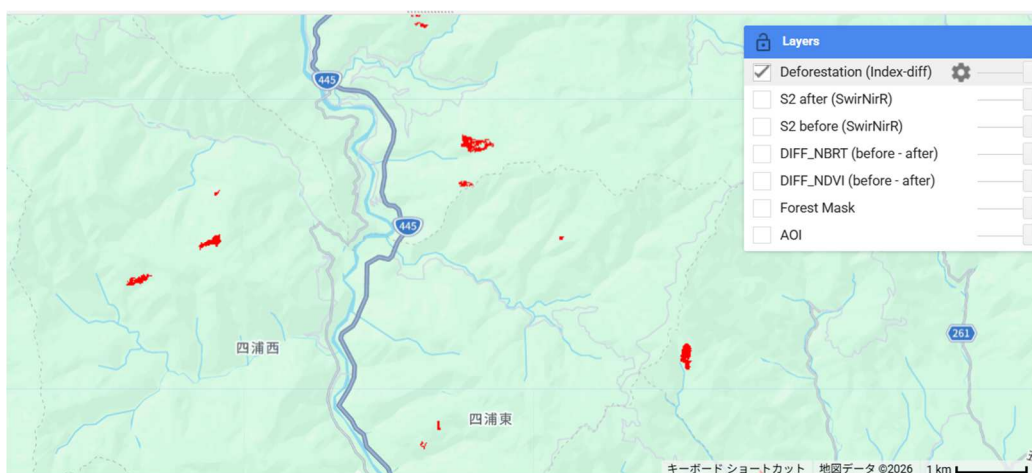



図7 実行後の Map 画面



Deforestation が表示されたところで、(伐採候補地) が赤く表示されている状態



Layers 画面の NBRT の差分画像 (DIFF\_NBRT (before-after)) にチェックを入れ、画像を表示しているところ。赤い箇所で差分値がプラス、青がマイナスを示す

図 8 Layers パネルと画像の表示

## 4.2 表示レイヤ (本スクリプト)

本スクリプトは、結果確認のために複数のレイヤを Map に追加します。初期表示 ON/OFF はレイヤごとに設定しているため、必要に応じて Layers で表示を切り替えてください (図 8)。

差分レイヤ (DIFF\_NDVI や DIFF\_NBRT) や before/after の擬似カラーは、過検出・検出漏れの原因 (雲影、季節差、裸地・造成等) を判断するのに有効です。検出結果だけで判断せず、必ずこれらの補助レイヤと合わせて確認します。

### ■ 各レイヤで表示される画像と初期表示設定

- Deforestation (Index-diff) : 抽出結果 (初期 ON)
- S2 before (SwirNirR) / S2 after (SwirNirR) : 確認用の擬似カラー (初期 OFF)
- DIFF\_NBRT : 差分画像 (before-after) (初期 OFF)
- DIFF\_NDVI : 差分画像 (before-after) (初期 OFF)
- Forest Mask : 森林マスク表示 (USE\_FOREST\_MASK=true の場合、初期 OFF)
- AOI : 解析範囲の表示 (初期 OFF)

## 4.3 差分指標を調整したいとき

伐採を抽出する際に使用される指標は下表に示した 4 つです。なお、NBRT について、本来は熱赤外バンドを有する Landsat といった衛星に適用されるものですが、FAMOST 事業に

において熱赤外を短波長赤外(SWIR2)に割当てて Sentinel-2 に適用した変則版となります。

INDEX	Equation	Reference
Normalized Difference Moisture Index 正規化水分指数	$NDMI = \frac{NIR - SWIR}{NIR + SWIR}$	Gao, 1996 <a href="https://doi.org/10.1016/S0034-4257(96)00067-3">https://doi.org/10.1016/S0034-4257(96)00067-3</a>
Normalized Difference Vegetation Index 正規化植生指数の差分	$NDVI = \frac{NIR - RED}{NIR + RED}$	Tucker & Sellers, 1986 <a href="https://doi.org/10.1080/01431168608948944">https://doi.org/10.1080/01431168608948944</a>
Normalized Burn Ratio-Thermal 正規化燃焼指数(熱)	$NBRT = \frac{NIR - 0.0001 \times SWIR \times T}{NIR + 0.0001 \times SWIR \times T}$	Holden et. al, 2005 <a href="https://doi.org/10.1080/01431160500239008">https://doi.org/10.1080/01431160500239008</a>
Normalized Difference JAFTA Index 正規化日林協指数	$NDJI = \frac{BLUE + GREEN - RED}{BLUE + GREEN + RED}$	FAMOST 用に日林協が開発した指数

これらの4つの指標の before/after の差分値を使って伐採地を抽出しており、下に示したスクリプトの該当箇所の数値を変更することで伐採候補地抽出の調整が可能です。数値を小さくするほど、見逃しが減りますが誤検出が増え、数値を大きくするほど、見逃しは増えますが誤検出が減ります。

```

288
289 // 閾値判定
290 var ndmiMask = DIFF_NDMI.gt(0.40);
291 var ndviMask = DIFF_NDVI.gt(0.25);
292 var nbrtMask = DIFF_NBRT.gt(0.38);
293 var ndjiMask = DIFF_NDJI.gt(0.30);
294

```

#### 4.4 Export の設定 (任意)

Export を行う場合は、節 0 で DO\_EXPORT=true とし、出力先フォルダ名

(EXPORT\_FOLDER)、座標系 (EXPORT\_CRS)、解像度 (EXPORT\_SCALE) などを必要に応じて設定します(図 9)。

Export の region は AOI (Geometry) で指定されています。AOI が非常に広い場合や期間が長い場合は、計算時間の増加や maxPixels 制限により失敗することがあります。その場合は AOI を分割する、期間を短くする、scale を粗くする等に対応します。

```
04
85 // -----
86 // 出力 (Export)
87 // -----
88 var DO_EXPORT      = true;           // true: Export 実行 / false: Export しない
89 var EXPORT_FOLDER  = 'GEE_export_FAMOST';
90 var EXPORT_CRS     = 'EPSG:3857';   // 推奨: EPSG:3857 (メートル単位)
91 var EXPORT_SCALE   = 10;           // 10m
92
```

図 9 Export 設定 (節 0 ユーザー設定)


## 5 Export (Tasks) とファイルのダウンロード方法

Run 実行後、DO\_EXPORT=true の場合は Tasks タブに Export タスクが追加されます。Tasks の RUN を押すことで Drive への出力が開始され、完了すると指定フォルダに GeoTIFF が作成されます(図 10)。

出力ファイル名 (description) はスクリプト内で自動生成しており、AOI 名・選択値・期間などが付与されます。運用でファイル管理しやすい命名になっているか、必要に応じて name\_string の組み立てを調整してください。

### ■ 流れ

- スクリプト実行後、Tasks タブに Export タスクが追加される
- Tasks で該当タスクを選択し「RUN」を押す (出力先 Drive フォルダを確認)
- Status が COMPLETED になったら Drive でファイルを確認する
- Drive 上の出力フォルダから GeoTIFF をダウンロードする (右クリック→ダウンロード (zip の場合は要解凍))



処理が成功すると、Tasks に出力ファイル名と青い RUN ボタン表示される



出力が完了すると、Google Drive の出力フォルダにファイルが格納される

図 10 Export 時の手動操作

## 6 トラブルシューティング (FAQ)

ここでは、実行時によくあるエラー・症状と、切り分けの観点をまとめます。多くの場合、(1) Asset ID/権限、(2) AOI・期間が大きすぎる、(3) 雲条件・閾値が厳しすぎる／緩すぎる、のいずれかです。

原因が特定しにくい場合は、まず AOI を小さくし、期間を短くし、Forest Mask を一旦 OFF にするなど、段階的に条件を緩めていくと切り分けが容易です。

### ■ よくあるエラーと確認事項

- Asset not found : Asset ID の誤り、権限不足、プロジェクト切替を確認する。
- Permission denied : Asset 共有設定、GEE アカウント (メール) を確認し、権限付与を依頼する。
- Export 失敗 : AOI が広すぎる / 期間が長い / maxPixels 不足 / scale 不適切などを見直す。

- 結果が空：AOI、期間、森林マスク、閾値 (SI\_THRESHOLD 等) を段階的に緩めて原因を切り分ける。
- 過検出/検出漏れ：SI\_THRESHOLD、雲条件、mmu、解析期間を調整し、目視で妥当性を確認する。
- タスクが出ない：DO\_EXPORT が false になっていないか、Run 後に Tasks を更新したかを確認する。
- 処理が非常に遅い：AOI/期間を縮小し、CLOUD\_FILTER を緩めて画像数を確保する。必要なら EXPORT\_SCALE を粗くする。

## 7 付録：スクリプト全文

```
// =====
// FAMOST マニュアル用：Sentinel-2 伐採抽出 (GEE Code Editor)
// =====
// 実行環境：Google Earth Engine Code Editor
//
// -----
// 【使用している座標系】
// -----
// 1) AOI (FeatureCollection / Geometry)
//   - Earth Engine 内部の Geometry は基本的に WGS84 (EPSG:4326) の緯度経度として扱われます。
//   - もとの SHP が別の座標系でも、Assets 化された時点で EE 内では EPSG:4326 相当で扱われます。
//     (※ただし、SHP の座標系情報が欠落していると位置ずれの原因になります)
//
// 2) 表示 (Map)
//   - GEE Code Editor の地図表示は Web Mercator (EPSG:3857) 相当で描画されます。
//     (表示の座標系であり、解析・演算の座標系を固定するものではありません)
//
// 3) Sentinel-2 画像 (COPERNICUS/S2_SR_HARMONIZED)
//   - Sentinel-2 はタイルごとに UTM 座標系 (EPSG:326xx/327xx) で提供されます。
//   - 本スクリプトの合成 (median) 後の画像は、内部的には入力画像の投影を引き継いで扱われます。
//     AOI が複数 UTM 帯に跨る場合、出力時に座標系を明示しておくことで運用が安定します。
//
// 4) 出力 (Export)
//   - 本スクリプトでは Export 時の出力座標系を EXPORT_CRS で指定できます。
//   - 推奨 (汎用)：EPSG:3857 (メートル単位で扱える)
//     例) EXPORT_CRS='EPSG:3857', EXPORT_SCALE=10
//   - 注意：EPSG:4326 (緯度経度) を指定すると scale は「度」単位になり、10m 指定が崩れます。
//     よって本マニュアル用途では EPSG:3857 を推奨します。
//
// -----
// 【事前に準備するデータ】
// -----
// A) AOI (対象範囲)
//   - GEE Assets にアップロードした FeatureCollection (ポリゴン) を使用します。
//   - 例：都道府県境界 SHP → Assets 化 → AOI_FC_ASSET_ID に Asset ID を設定
//   - AOI が「単一ポリゴンだけ」の場合：AOI_FILTER_FIELD / VALUE を null にして全体を使います。
```

```

// - AOI が「複数ポリゴンから選択」する場合：識別用属性列（例：CODE, ID, NAME 等）を用意し
//   AOI_FILTER_FIELD / AOI_FILTER_VALUE で 1 つ選択します。
// - AOI_FILTER_VALUE は 1 つ（数値/文字列）でも、配列（複数候補）でも OK
//   - 1 つ：eq フィルタ
//   - 配列：inList フィルタ
//
// B) Forest Mask（森林マスク：任意）
// - 森林マスクを使う場合：GEE Assets の森林ラスタ（ee.Image）の Asset ID を FOREST_ASSET_ID
に設定。
// - USE_FOREST_MASK=true/false で「使う/使わない」を切り替え可能。
// - マスク値仕様に応じて、Forest.gt(0) を Forest.eq(1) 等に変更が必要な場合があります。
//
// C) Sentinel-2 データ
// - GEE 公式カタログを使用（追加準備不要）
//
// -----
// 【このスクリプトの仕様（要点）】
// -----
// 1) AOI は汎用可能（ユーザーが興味があるエリアを設定）
// 2) 伐採候補箇所を NDVI, NDMI, NBRT, NDJI の差分の閾値で判定
// 3) 差分画像も表示して、伐採抽出候補と比較できる（NDVI と NBRT）
//
// =====
// 0. ユーザー設定
// =====

// -----
// AOI (FeatureCollection)
// -----
//var AOI_FC_ASSET_ID = 'projects/*****/assets/*****';
var AOI_FC_ASSET_ID = 'projects/*****/assets/*****';//TIF 画像

// AOI を「複数から選択」する場合：属性列名と値を設定（単一 AOI の場合は null）
var AOI_FILTER_FIELD = null; // 例：'CODE' / 'id' / 'NAME' 等。単一 AOI なら null
var AOI_FILTER_VALUE = null; // 例：45 / 'Tokyo' / ['A','B'] 等。単一 AOI なら null

// 表示/出力用の AOI 名称
var AOI_NAME = 'AOI';

// -----
// Forest Mask (任意)
// -----
var USE_FOREST_MASK = true; // true: Forest Mask を使う / false: 使わない

var FOREST_ASSET_ID = 'projects//*****/assets//*****';

// -----
// 出力 (Export)
// -----
var DO_EXPORT      = true;          // true: Export 実行 / false: Export しない
var EXPORT_FOLDER  = 'GEE_export_FAMOST';
var EXPORT_CRS     = 'EPSG:3857';   // 推奨：EPSG:3857（メートル単位）
var EXPORT_SCALE   = 10;           // 10m

```

```

// -----
// 解析期間・雲条件など
// -----
var CLOUD_FILTER = 50; // Sentinel-2 メタデータの雲量 (CLOUDY_PIXEL_PERCENTAGE)
var CLOUD_PROB_TH = 50; // s2cloudless の雲確率しきい値 (probability > 50 を雲)

// 最小パッチ (mmu)
var mmu = 10; //ピクセル数

// before / after 期間設定 (例: 2022→2023 の同時期比較)
var startYear = 2022;
var endYear   = 2023;
var startDay  = '-05-01';
var endDay    = '-10-31';

var DATE_START_1 = startYear + startDay;
var DATE_END_1   = startYear + endDay;
var DATE_START_2 = endYear   + startDay;
var DATE_END_2   = endYear   + endDay;

// =====
// 1. AOI の作成 (単一でも選択式でも対応)
// =====

var AOI_FC_ALL = ee.FeatureCollection(AOI_FC_ASSET_ID);

var AOI_FC;
if (AOI_FILTER_FIELD === null || AOI_FILTER_VALUE === null) {
  // 単一 AOI (または全体を AOI として使用)
  AOI_FC = AOI_FC_ALL;
} else {
  // 選択式 (1つ or 配列)
  if (Array.isArray(AOI_FILTER_VALUE)) {
    AOI_FC = AOI_FC_ALL.filter(ee.Filter.inList(AOI_FILTER_FIELD, AOI_FILTER_VALUE));
  } else {
    AOI_FC = AOI_FC_ALL.filter(ee.Filter.eq(AOI_FILTER_FIELD, AOI_FILTER_VALUE));
  }
}

var AOI = AOI_FC.geometry();

// AOI 内マスク (AOI 外は解析しない)
var aoi_mask = ee.Image().byte().paint(AOI_FC, 1).rename('AOI_mask').unmask(0);

// 出力名に付ける識別子 (AOI_FILTER_VALUE があればそれも入れる)
var aoi_id_str = (AOI_FILTER_VALUE === null) ? 'ALL'
              : (Array.isArray(AOI_FILTER_VALUE) ? 'MULTI' : String(AOI_FILTER_VALUE));

var name_string = AOI_NAME + '_' + aoi_id_str + '_' + startYear + 'to' + endYear;

Map.centerObject(AOI, 9);
Map.addLayer(AOI, {color: 'red'}, 'AOI', false);

// =====

```

```

// 2. Forest Mask (任意: ON/OFF)
// =====

var Forest = ee.Image(FOREST_ASSET_ID);

// マスク仕様に応じて変更: gt(0) → eq(1) など
var ForestMask = Forest.gt(0).rename('ForestMask');

// Forest Mask を使わない場合は「全て 1 のマスク」を使う (AOI 内に限定)
var ForestMaskOrAll = ee.Image(1).rename('ForestMaskOrAll').updateMask(aoi_mask);
if (USE_FOREST_MASK) {
  ForestMaskOrAll = ForestMask.updateMask(aoi_mask); // AOI 内に限定
  Map.addLayer(
    ForestMaskOrAll.updateMask(ForestMaskOrAll),
    {palette: ['#ffc71a']},
    'Forest Mask',
    false
  );
}

// =====
// 3. Sentinel-2 SR + s2cloudless マスク (AOI 内)
// =====

function getS2Collection(startDate, endDate) {

  // Sentinel-2 SR (L2A)
  var s2_sr = ee.ImageCollection('COPERNICUS/S2_SR_HARMONIZED')
    .filterBounds(AOI)
    .filterDate(startDate, endDate)
    .filter(ee.Filter.lte('CLOUDY_PIXEL_PERCENTAGE', CLOUD_FILTER));

  // s2cloudless
  var s2_cloudprob = ee.ImageCollection('COPERNICUS/S2_CLOUD_PROBABILITY')
    .filterBounds(AOI)
    .filterDate(startDate, endDate);

  // system:index で join
  var joined = ee.ImageCollection(ee.Join.saveFirst('s2cloudless').apply({
    primary: s2_sr,
    secondary: s2_cloudprob,
    condition: ee.Filter.equals({
      leftField: 'system:index',
      rightField: 'system:index'
    })
  }));

  // cloud_prob / clouds バンド追加
  function addCloudBands(img) {
    var cldPrb = ee.Image(img.get('s2cloudless')).select('probability');
    var isCloud = cldPrb.gt(CLOUD_PROB_TH).rename('clouds');
    return img.addBands(cldPrb.rename('cloud_prob'))
      .addBands(isCloud);
  }
}

```

```

// SCL + clouds でマスク (AOI 内のみ)
function applyMasks(img) {
  var scl = img.select('SCL');

  // SCL 除外クラス (2,3,7~11)
  var invalid = scl.eq(2) // Topographic shadows
    .or(scl.eq(3)) // Cloud shadows
    .or(scl.eq(7)) // Cloud low prob.
    .or(scl.eq(8)) // Cloud med prob.
    .or(scl.eq(9)) // Cloud high prob.
    .or(scl.eq(10)) // Thin cirrus
    .or(scl.eq(11)); // Snow / ice

  var validSCL = invalid.not();
  var validCloud = img.select('clouds').not();
  var mask = validSCL.and(validCloud);

  return img.updateMask(mask)
    .updateMask(aoi_mask); // AOI 内のみ
}

return joined.map(addCloudBands)
  .map(applyMasks);
}

var col_before = getS2Collection(DATE_START_1, DATE_END_1);
var col_after = getS2Collection(DATE_START_2, DATE_END_2);

// median 合成
var s2_before = col_before.median().select('B.*').clip(AOI);
var s2_after = col_after.median().select('B.*').clip(AOI);

// =====
// 4. 指標 (NDVI/NDMI/NBRT/NDJI) 差分と閾値判定 (before - after)
// =====
// ※ Shadow Index (SI) と影マスクは【省略】
//
// 閾値 (before - after が以下を超える)
// - NDMI: > 0.40
// - NDVI: > 0.25
// - NBRT: > 0.38
// - NDJI: > 0.30

// NDMI
var ndmi_bf = s2_before.normalizedDifference(['B8', 'B11']).rename('NDMI');
var ndmi_at = s2_after.normalizedDifference(['B8', 'B11']).rename('NDMI');

// NDVI
var ndvi_bf = s2_before.normalizedDifference(['B8', 'B4']).rename('NDVI');
var ndvi_at = s2_after.normalizedDifference(['B8', 'B4']).rename('NDVI');

// NBRT
var nbrt_bf = s2_before.expression(

```

```

'(NIR - 0.0001 * SWIR * Temp) / (NIR + 0.0001 * SWIR * Temp)', {
  'NIR': s2_before.select('B8'),
  'SWIR': s2_before.select('B11'),
  'Temp': s2_before.select('B12')
}).rename('NBRT');

var nbrt_at = s2_after.expression(
'(NIR - 0.0001 * SWIR * Temp) / (NIR + 0.0001 * SWIR * Temp)', {
  'NIR': s2_after.select('B8'),
  'SWIR': s2_after.select('B11'),
  'Temp': s2_after.select('B12')
}).rename('NBRT');

// NDJI
var ndji_bf = s2_before.expression(
'(BLUE + GREEN - RED) / (BLUE + GREEN + RED)', {
  'BLUE': s2_before.select('B2'),
  'GREEN': s2_before.select('B3'),
  'RED': s2_before.select('B4')
}).rename('NDJI');

var ndji_at = s2_after.expression(
'(BLUE + GREEN - RED) / (BLUE + GREEN + RED)', {
  'BLUE': s2_after.select('B2'),
  'GREEN': s2_after.select('B3'),
  'RED': s2_after.select('B4')
}).rename('NDJI');

// 差分 (before - after)
var DIFF_NDMI = ndmi_bf.subtract(ndmi_at).rename('dNDMI');
var DIFF_NDVI = ndvi_bf.subtract(ndvi_at).rename('dNDVI');
var DIFF_NBRT = nbrt_bf.subtract(nbrt_at).rename('dNBRT');
var DIFF_NDJI = ndji_bf.subtract(ndji_at).rename('dNDJI');

// 閾値判定
var ndmiMask = DIFF_NDMI.gt(0.40);
var ndviMask = DIFF_NDVI.gt(0.25);
var nbrtMask = DIFF_NBRT.gt(0.38);
var ndjiMask = DIFF_NDJI.gt(0.30);

// 4 指標すべて満たす (AND)
var changes = ndmiMask.add(ndviMask).add(nbrtMask).add(ndjiMask)
  .eq(4)
  .selfMask();

// mmu (最小パッチ)
// connectedPixelCount(20) は連結ピクセルの集計上限 (20)
var detect_raw = changes
  .connectedPixelCount(20)
  .gte(mmu)
  .selfMask();

// =====
// 5. Forest Mask 適用 (任意: ON/OFF)

```

```

// =====
var detect_final = detect_raw;
if (USE_FOREST_MASK) {
  detect_final = detect_raw.updateMask(ForestMaskOrAll);
}

// =====
// 6. 表示 (確認用)
// =====

// (a) 差分画像: 指定どおり NDVI / NBRT のみ表示
Map.addLayer(
  DIFF_NDVI,
  {min: -0.6, max: 0.6, palette: ['0000ff', 'ffffff', 'ff0000']},
  'DIFF_NDVI (before - after)',
  false
);

Map.addLayer(
  DIFF_NBRT,
  {min: -1.0, max: 1.0, palette: ['0000ff', 'ffffff', 'ff0000']},
  'DIFF_NBRT (before - after)',
  false
);

// (b) S2 BEFORE / AFTER (確認用: SwirNirR)
Map.addLayer(
  s2_before.select(['B11', 'B8', 'B5']).divide(10000),
  {min: 0, max: 0.3},
  'S2 before (SwirNirR)',
  false
);

Map.addLayer(
  s2_after.select(['B11', 'B8', 'B5']).divide(10000),
  {min: 0, max: 0.3},
  'S2 after (SwirNirR)',
  false
);

// (c) 伐採抽出結果
Map.addLayer(
  detect_final,
  {min: 0, max: 1, palette: ['000000', 'ff0000']},
  'Deforestation (Index-diff)',
  true
);

// =====
// 7. Export (任意)
// =====

if (DO_EXPORT) {

```

```
Export.image.toDrive({
  image: detect_final,
  description: 'S2_FAMOST_detect_' + name_string,
  folder: EXPORT_FOLDER,
  region: AOI,
  crs: EXPORT_CRS,
  scale: EXPORT_SCALE,
  maxPixels: 1e13
});
}
```

#### 6.4. 検討委員 議事録の要約

#### 6.5. 第 1 回

検討項目	内容
会議情報	日時：令和 7 年 11 月 28 日（金）14:00～16:30 場所：日林協会館 5F（中会議室）／Web 形式：対面／Web（ハイブリッド）
(1) ① 過去の伐採面積の推定（全国）	<p><b>【伐採面積の推移】</b></p> <ul style="list-style-type: none"> <li>・（林野庁／藤代）年別の落ち込み（H29/2017、R3/2021 等）については、判読用画像の不足や年割り当ての仕組みに起因する可能性があるため、理由を挙げて説明できるようにはしたい。</li> <li>・（日林協／古田）H29/2017 の落ち込みは、目視判読時に使用する H28/2016 年の Sentinel-2 の公開画像が少なく、目視判読の精度が下がり、推定結果に影響した可能性がある。</li> <li>・（森林総研／志水）補足：Landsat の伐採マップはサンプル抽出に使われ、伐採マップの精度が低くても基本的には計算される推定面積の偏りには影響がない。ただ、95%信頼区間が少し大きくなる可能性はあり。</li> <li>・（林野庁／藤代）R3/2021 の落ち込みは、コロナ禍の需給変動（滞留→供給不足→価格上昇）など“特殊要因”の影響もあり、単純に伐採抑制で説明しにくい。需給関係の資料を見る限り R3/2021 に伐採が抑制されたとは考えがたいと思っている。</li> <li>・（森林総研／齋藤）Sentinel-2 合成期間（主に 5-10 月）と伐採の季節性（冬季中心）のズレにより、年度内伐採が翌年の合成画像に現れる等、年次対応がずれる可能性がある（R3 年度伐採が R4 年度に反映され得る）。</li> <li>・（日林協／笹川）GFW の抽出結果の単純積み上げも、同じような動きをしているように見える。</li> <li>・（林野庁／藤代）どちらも同じ Landsat 画像から判読していることに起因するのでは？</li> <li>・（森林総研／志水）GFW は Landsat 画像から抽出しているが、本事業での推定では、Landsat 時系列マップで層化抽出しているが、伐採判読は Sentinel-2 画像で目視判読しているので、ソースは異なる。</li> <li>・（林野庁／藤代）行政情報は年度集計が多い一方、出荷等は年次集計もあり、区切りの違いに伴うズレは一定程度発生し得るので、最後は割り切りになるほかない。</li> </ul>

検討項目	内容
	<ul style="list-style-type: none"> <li>・(日林協／古田) 必要に応じ、昨年度の月別判読結果等を活用し、伐採発生月の分布(傾向)を示せば年次解釈の補助資料にはなるのかと思う。</li> <li>・(林野庁／藤代) 北海道と九州では季節変化が異なるので、ブロック別(例:7ブロック)程度に大きな範囲で季節性や年次ズレの影響が大まかに見られればなとは思いますが、負担のない程度で。</li> </ul>
<p>(1)②FAMOSTを活用した伐採面積の推定(全国)</p>	<ul style="list-style-type: none"> <li>・(林野庁／藤代) 昨年度事業では「速報値」を得るために実施したが、今年は、Landsat 時系列伐採マップに依存しない継続体制の構築を目的に、Recall(取りこぼしを減らす)を重視した閾値設定も検討。</li> </ul> <p><b>【誤検出への対応】</b></p> <ul style="list-style-type: none"> <li>・(日林協／古田) 2023年の北海道で誤検出が顕著(影・草地・非森林等)。補足:最小面積(MMU)は0.1ha(10ピクセル)で試行。</li> <li>・(森林総研／小谷) 北海道での誤検出要因として、緯度差による太陽高度の違い(影の強調)も含め、要因切り分けが必要。合成期間(秋季の影響)も効いていそう。</li> <li>・(森林付箋／渡邊) 原因究明のため、計算に用いた Sentinel-2 合成画像を出力して目視確認し、特定年(例:2023年)の異常(早期紅葉、明るさ変動、雲残り等)を点検する。画素値ヒストグラムの年次比較による確認を推奨</li> <li>・(森林総研／志水) 地形補正は有効な可能性があるが、GEE 上で大面積を処理するにはメモリ等の制約で実行が難しい見込み。</li> <li>・(森林総研／齋藤) 短期対応として閾値調整(例:0.95)で改善を試み、難しければ今年度は Shadow Index で暫定対応し、来年度以降に追加検討もあり。</li> </ul>
<p>(1)③FAMOST(スギ人工林伐採重点区域)</p>	<p><b>【都道府県によって異なるスギ重点地区 GIS ポリゴンへの対応】</b></p> <ul style="list-style-type: none"> <li>・(林野庁／小林) 重点区域 GIS ポリゴンは県ごとにファイル形式や座標系が異なる。令和6年度提供(23県)に加え、追加分を含む最新版を提供予定。一部ポリゴンに非森林域が含まれ面積が過大となっていた事例があるため、民有林マスク等で一次補正し、人工林重ね合わせ後の面積などで不自然な箇所を共有してほしい。</li> <li>・(日林協／古田、林野庁／小林) 不自然箇所の確認については、</li> </ul>

検討項目	内容
	<p>民有林内か否かのチェックに留める。来年度以降は座標参照系(例: JGD2011 等)などの情報も含むデータ提供をご依頼願う。</p>
<p>(1) ④ 都道府県別の伐採面積推定に向けた検討</p>	<p>(林野庁／藤代)</p> <ul style="list-style-type: none"> <li>・昨年度事業で都道府県別の伐採面積推定に必要なサンプル数の案を幾つか検証しているが、伐採面積等に応じたサンプル数となる方法について、もう一步詰めて欲しい。</li> <li>・施策の単位である都道府県別の伐採面積把握が求められることを想定はしているが、実際に数百万点を判読し都道府県別に推定することまでは想定してない。 <ul style="list-style-type: none"> <li>・「この森林面積と伐採面積に対して考えれば、」など、「前提を置けば、各県このぐらいの点数を見れば、一旦こういう形になる」ということをまとめてもらえれば今回は大丈夫。</li> </ul> </li> </ul>
<p>(1) ⑤ AI 技術等活用による推定の省力化に向けた検討</p>	<ul style="list-style-type: none"> <li>・(林野庁／藤代) このパートの方針は(A) Landsat 時系列マップ等の伐採マップを AI の活用により精度高める方法の検討、(B) 目視判読の前段で森林/非森林等を自動分類して人が見る点を減らす方法の検討、の 2 本立て。ただ、実際に検討する内容は(A)(B)ともほぼ同じになると考えている。</li> <li>・(林野庁／藤代) 現時点では困難であるものの、AI で見た結果を全て足せば伐採の面積が分かるというピクセルカウントにいかにして近づいていくかという世界だと思うが、真値が分からないため評価が難しく、今年度は試行位置づけで進める。 <ul style="list-style-type: none"> <li>・(森林付箋／渡邊) 伐採件数が極端に少ない地域(例: 沖縄等)では、層化抽出と AI 検出(候補地点に限定)を組み合わせるなど、手法の使い分けが考えられる。</li> <li>・(森林総研／志水、森林付箋／渡邊) ピクセルカウント法と層化抽出法を併用する方法もある。実務上は「明らかに森林」等の判断を AI で肩代わりし、迷う点だけを人が確認することで作業量削減を狙う。</li> <li>・(森林総研／齋藤) 例えば 10,000 点あり、森林 8,000 点のうち判読容易な 7,000 点は AI で判読を目指し、3,000 点は人間の判読、くらいを目指しては?</li> </ul> </li> <li>・地域によっては高分解能の光学衛星画像の利用(購入+判読)も合理的な選択肢になり得る。</li> </ul>
<p>(2) 行政情報との比較検証</p>	<ul style="list-style-type: none"> <li>・(事務局説明) 行政情報による推計等との比較枠組みを共有</li> </ul>

検討項目	内容
(3) マニュアル等の整備	<ul style="list-style-type: none"> <li>・目視判読マニュアル：担当者・年度が変わっても判断がぶれないよう、判読の観点・手順を整理。</li> <li>・FAMOST 活用マニュアル：閾値変更前に公表していた FAMOST の再現・利用方法を、技術者向けに整理（GEE 等を想定）。</li> </ul>
(4) 更新状況の把握に向けた検討	<ul style="list-style-type: none"> <li>・(林野庁／藤代) 発注意図は『天然更新版 FAMOST』のイメージ。伐採後 5 年経っても草地・裸地のまま等の大面積の放棄地箇所を抽出し、現地確認につなげたい。</li> <li>・(森林付箋／渡邊) Sentinel-2 と AI で 5ha 以上伐採地の更新状況を判別する案、冬季データを用いた指標の可能性を提示。LiDAR も参照して慎重に評価。ただし、LiDAR は有効だが、データ品質/解釈に不確実性もあるため、GEE のタイムラプス等と併用して慎重に評価する（植栽しても伸びない事例の扱いも課題）。</li> <li>・訓練データでは、放置草地が再度刈られる等の紛らわしいケースを除外する必要がある、データ整備が難所。今回は伐採から約 5 年経過した箇所に限定し、「明らかに成長／明らかに未成長」の二値ラベルで訓練・評価データを作る方針。</li> <li>・(森林総研／志水) 『回復』の定義づけが難しく、光学衛星のみでは高さ推定に限界。</li> <li>・(森林総研／齋藤) 今回は広葉樹も常緑広葉樹の場所、佐伯とか九州とか四国というふうに限定しては？ 高木性樹種というよりも、木本性植物で 5m 以上の高さになると考えられる植物というふうに絞ったほうがいいのかもしい</li> <li>・(森林総研／小谷) 広葉樹は常緑/落葉、標高、季節、撮影時期の違いで反応が大きく異なる。</li> </ul>
スケジュール（次回）	<ul style="list-style-type: none"> <li>・次回委員会は 1 月中～下旬を目安に調整。</li> <li>・全国版の推定作業は次回までに終了予定。</li> <li>・進捗・報告内容に応じて開催有無、Web 開催も含め柔軟に対応。</li> </ul>

## 6.6. 第2回

検討項目	内容
会議情報	<p>日時：令和8年3月3日（火）14:00～17:00            場所：日林協会館 3F（大会議室）／Web            形式：対面／Web（ハイブリッド）</p>
<p>(1)            ① 過去の伐採面積の推定（全国）            ② FAMOST を活用した伐採面積の推定（全国）</p>	<ul style="list-style-type: none"> <li>・（林野庁／藤代）3名による再判読等により、95%信頼区間に対する比率が約10%まで改善し、発注者として十分な成果と評価した。</li> <li>・（林野庁／藤代）前年の1名判読との差が大きく、1点の判読誤りが大きな面積差につながることから、複数人判読の重要性を再認識した。</li> <li>・（事務局／古田、事務局／笹川）入力行ずれ等の単純ミスも発生し得るため、入力フォーマットの工夫と管理者確認は重要である。</li> <li>・（林野庁／藤代）今回検討した閾値は、2023、2024年以外にも適用できるのか。</li> <li>・（事務局／古田）既存の2021年、2022年、2024年の判読結果を基に閾値を決定している。閾値は原則固定で他年にも適用可能と想定している。ただし、2023年の北海道では夏季画像が不足し、一部地域で合成画像が伐採地のように見える等の誤検出が発生しており、確実ではない。</li> <li>・（森林総研／志水）FAMOSTは2時期差分を用いる基本手法であり、画像条件の影響を受けやすいため限界はあると思われる。</li> <li>・（森林総研／志水、事務局／古田）「見逃し率」等の表現や計算過程が分かりにくい箇所は、報告書で用語整理・説明補足を行う。</li> </ul>
<p>(1) ③            FAMOST（スギ人工林伐採重点区域）</p>	<p><b>【推定結果の評価】</b></p> <ul style="list-style-type: none"> <li>・（林野庁／藤代、林野庁／小林）重点区域に限定しても約31,000点の判読により昨年度より高精度な結果が得られ、全国値よりやや高い伐採率傾向も確認された。</li> </ul> <p><b>【GISデータの課題】</b></p> <ul style="list-style-type: none"> <li>・（林野庁／小林）重点区域は都道府県がスギ人工林と認識して設定した区域であり、公開となる森林簿ベースの樹種マップ重ね合わせにより精度が向上できると考えられる。</li> <li>・（事務局／古田）スギ重点地区GISポリゴンについて、受領時点でのGISソフトでの一次点検が望ましい。</li> </ul>

<p>(1)④ 都道府県別の伐採面積推定に向けた検討</p>	<ul style="list-style-type: none"> <li>・(林野庁／藤代) 全国一律に都道府県別推定を実施する想定はないが、報告書公開後に都道府県から活用ニーズが出る可能性があるため、参考情報として整理する意義は大きい。</li> <li>・(事務局／金森、事務局／古田) 都道府県単位で 30,000 点を 3 人で読むには相応のスキルと体制が必要であり、受託実施は時期・体制次第。トレーニング支援は対応可能。</li> <li>・(林野庁／藤代) 報告書の図表は横軸をそろえるなど、比較しやすい見せ方に修正する。</li> <li>・(森林総研／志水) ±10%精度を前提とした 30,000 点判読は研究的にも大規模であり、各県で再現するには十分なトレーニングと継続的なマニュアル整備が必要である。</li> </ul>
<p>(1)⑤ AI 技術等活用による推定の省力化に向けた検討</p>	<p><b>【A I による森林・非森林判定】</b></p> <ul style="list-style-type: none"> <li>・(小谷委員) 確度の高い森林だけでなく、非森林も AI に任せ、そのほかのサンプル地点のみ人が確認する方法について検討してはどうか。</li> <li>・(事務局／渡邊) 「100%正解」とみなせる自動判定は 14,000 点中約 1,700 点にとどまり、大幅な省力化には至らない。AI は 0～1 の確率値を出力しており、100%ではなく 99%や 97%など複数閾値のシナリオで比較した場合、労力はかなり減る可能性あり。</li> <li>・(森林総研／志水) 100%ではなく閾値を下げる検討をした方が良いと思われる。また、シナリオによってどのように伐採面積が変わっていくかを検討したら、傾向がつかめるのではないか。</li> <li>・(森林総研／志水) AI の評価は単純な分類精度だけでなく、層化抽出時のサンプル重みを考慮して伐採面積推定への影響を見るべきである。</li> <li>・(林野庁／藤代) 当面は AI 全面置換ではなく、伐採マップ作成や目視判読の重点化など、人手を減らす補助的な使い方から検討を進める。</li> <li>・(森林総研／志水) 都道府県レベルの推定といった小面積となると、判読労力を減らすためにピクセルカウント法との組み合わせも将来的に求められる可能性がある。</li> </ul>
<p>(2) 衛星判読による推定と行政情報の比較検証</p>	<ul style="list-style-type: none"> <li>・(林野庁／藤代) GLAD は単純なピクセルカウント結果で中央値評価には使えないが、衛星推定と同様の増減トレンドを示しており、衛星の動きが実態を一定程度反映している可能性がある。</li> <li>・(林野庁／藤代) 行政情報と衛星推定の R2～R3 のずれは、1～3 月に伐採が集中することに加え、ウッドショックによる材価急変が 4 月以降に起きた特殊要因が重なった可能性がある。</li> </ul>

	<ul style="list-style-type: none"> <li>・(林野庁／藤代) 年ごとの振れ幅を「仕方ない」で終わらせず、衛星で増減傾向まで評価できる可能性を今後も見ていきたい。</li> </ul>
(3) マニュアル等の整備	<ul style="list-style-type: none"> <li>・(林野庁／藤代) 目視判読マニュアルは、新任者でも使いやすく、受託者が変わっても判断の一貫性を保てる内容を重視する。FAMOST 活用マニュアルは、公的資金で整備した技術を技術者が再利用できる足がかりとして公開する位置づけである。</li> <li>・(事務局／古田、森林総研／志水) Google Earth Engine は組織利用が有償となる前提で整理し、利用可否は各ユーザーの判断に委ねる。</li> </ul>
(4) 更新状況の把握に向けた検討	<ul style="list-style-type: none"> <li>・(林野庁／藤代) 天然更新版 FAMOST は自治体個別利用よりも、当面は林野庁が中央一括で全国を俯瞰する運用を想定している。</li> <li>・(事務局／渡邊) 冬季 NDVI は更新不良地抽出に活用できる可能性があり、有望な指標と評価された。</li> <li>・(事務局／渡邊) LiDAR は有効だが、真値設定や指標選択が難しく、現地確認にも大きな手間を要する。</li> <li>・(事務局／古田) まずはチャンピオンデータや少数でも精度の高い検証データを整備し、そのあと地域別の横展開可能性を検討してはどうか。</li> <li>・(林野庁／藤代) 最終的には地域別に分かれたとしても全国を対象とした運用を想定しつつ、まずは積雪の有無や、照葉樹/落葉樹など植生の違いなどの比較検討を考えている。</li> </ul>
総括	<ul style="list-style-type: none"> <li>・(林野庁／藤代) 短期間ながら、伐採面積推定・AI・更新状況把握とも次年度につながる成果が得られた。</li> <li>・報告書は専門外の行政担当にも理解できる表現で最終化する。</li> </ul>

令和7年度  
再造林の推進に向けた伐採状況の把握手法等に関する調査委託事業  
報告書

令和8年3月

業務受託：一般社団法人日本森林技術協会  
〒102-0085 東京都千代田区六番町7番地 TEL：03-3261-5281（代表）  
担当者 笹川裕史