

修士論文

題目

Sentinel-2を用いたRandom Forestによるスギとヒノキの分類
～観測時期・観測波長帯・地形の評価～

指導教員

松岡真如

2024年 2月

三重大学大学院 工学研究科 情報工学専攻
データサイエンス研究室

花井陽一 (422M523)

Sentinel-2を用いたRandom Forestによるスギとヒノキの分類 ～観測時期・観測波長帯・地形の評価～

花井 陽一

内容梗概

スギ、ヒノキは日本の人工林面積の7割を占め、木材生産において重要な樹種である。森林の管理において人工林の樹種の分布を広範囲かつ迅速に把握するために、衛星リモートセンシングの活用が期待されている。スギとヒノキはどちらも常緑針葉樹であり、樹冠の形状や色が似ているため、衛星で観測する反射率の違いが小さい。また、日本の森林は山岳地帯に多く分布しており、傾斜による陰影が観測反射率に大きな影響を与える。本研究では、衛星画像からスギとヒノキを機械学習によって分類した。観測時期ごとに分類精度を算出し比較することで、分類に有効な時期を評価した。地形補正の有無で分類精度を比較し、地形による反射率の変化が分類精度にどのように影響するかを評価した。また、分類における各波長帯（バンド）の重要度を算出し、分類に重要な波長帯を特定した。

対象地は三重県と和歌山県と奈良県とした。対象期間は2020年から2023年までとし、雲が少ない18日分のデータを使用した。衛星データはSentinel-2/MSIを使用した。Sentinel-2/MSIは空間分解能が10～60m、観測周期が5日であり、可視光、近赤外光、短波長赤外光など13バンドを観測できる。解析には60m解像度のバンド1、9、10を除いた10バンドを使用した。Sentinel-2/MSIには、大気圏上部の反射率を記録したLevel 1Cデータと、Level 1Cデータに大気補正と地形補正を行ったLevel 2Aデータがある。スギとヒノキの参照データとして、国土数値情報の国有林野データからスギとヒノキの純林を抽出した。

分類手法にはRandom Forestを使用した。参照データの位置に基づいて、衛星データから画素値を抽出するとともに、スギかヒノキかのラベリングを行いデータセットを作成した。18時期の分類精度を算出して観測時期の影響を評価した。観測波長帯ごとの重要度はPermutation Importanceを用いて評価した。また、Level 1Cと2Aの精度を比較することで地形の影響を評価した。

観測時期についてはLevel 1Cと2Aとも、4月上旬と6月中旬の分類精度が高く、3月から4月または6月から7月が分類に有効であった。3月31日が全ての時期の中で最も精度が高く、地形補正ありで87.0%、地形補正なしで84.6%となった。一方、5月と、9月から1月までのデータでは精度が低くなった。観測波長帯の重要度については、3月から4月はバンド6、11の重要度が高く、3月31日ではバンド6、11のPermutation Importanceがそれぞれ30%を超えた。また、9月から12月はバンド3の重要度が高く40%を超えるなど、季節により違いがみられた。また、バンド2の重要度は全ての時期で0.1%未満と小さかった。地形補正なしの分類精度は約82%～約87%、地形補正ありでは約80%～約85%と、ほとんどの時期で地形補正なし分類精度が2%程度高くなった。この原因として、スギは谷に、ヒノキは尾根に植林されることが多いため、樹種の分布が地形と関連することで分類精度が高くなったことが考えられる。

Contents

1	はじめに	1
2	使用データ	3
2.1	参照データ	3
2.2	Sentinel-2/MSI	4
3	解析手法	7
3.1	データセットの作成	7
3.2	分類手法	8
3.3	特徴量の重要度	9
4	結果と考察	10
4.1	分類結果	10
4.2	分類精度	15
4.3	波長帯の重要度	17
4.4	地形補正	17
5	おわりに	23
5.1	まとめ	23
5.2	今後の課題	24
	参考文献	24
	謝辞	27

List of Figures

2.1	研究対象地の Sentinel-2/MSI 画像	5
2.2	Level 1C と Level 2A データのカラー画像	6
4.3	2021 年 3 月 31 日のデータを用いて作成した分類画像	10
4.4	2021 年 3 月 31 日のデータを用いて作成した分類画像を拡大したもの	11
4.5	空中写真、撮影日時:2022 年 3 月 4 日、撮影地域: 和歌山県伊都郡かつらぎ町	12
4.6	空中写真と同じエリアの分類画像	13
4.7	拡大した空中写真	14
4.8	拡大した分類画像	15
4.9	年間の精度の推移のグラフ	16
4.10	2021 年 3 月 31 日の反射率の平均と標準偏差 青色: スギ 橙色: ヒノキ	18
4.11	各波長帯の重要度 精度の高い時期	19
4.12	各波長帯の重要度 精度の低い時期	20
4.13	地形補正なしのデータが地形補正ありのデータよりも正確に分類した例	21
4.14	地形補正ありのデータが地形補正なしのデータよりも正確に分類した例	22

List of Tables

2.1	三重県、和歌山県、奈良県の国土面積と人工林面積と人工林率	3
2.2	使用したバンドの中心波長と解像度	5
2.3	使用したデータの観測日時と観測衛星	7

1 はじめに

国内林業の復興や地球温暖化の防止などの観点から適切な森林管理が求められている。スギとヒノキは日本の人工林面積の7割を占め、木材生産において重要な樹種である [1]。スギ、ヒノキの花粉は冬から春にかけての花粉症の原因となっている。2023年10月11日に行われた花粉症に関する関係閣僚会議では、2023年度中に「スギ人工林伐採重点区域」を設定してスギ人工林の伐採と花粉の少ない苗木への植え替えを重点的に進めていくことが決定した [2]。人工林は林班図や林地台帳などで管理されているが、情報の更新や訂正が必要であり、効率的な調査が求められる。森林の樹種の分布を広範囲かつ迅速に把握するために、衛星リモートセンシングの活用が期待されている [3-8]。齋藤らは熊本県の60km四方の森林を対象に、SPOT HRG衛星画像を用いてスギとヒノキの分類を行い、画素単位での分類ではスギが92.1%でヒノキが99.4%となった [3]。

マルチスペクトルカメラによる分類において、使用した波長帯の分類に対する寄与率を評価し、重要な波長帯を把握することは、学習モデルの過学習の防止や、将来のデータ収集のコストの軽減を見込めるという点から有効である。Zhangらは、フロリダ州沿岸の都市部における土地被覆分類をLandsat衛星画像を用いて行った。観測波長帯や標高データや正規化植生指数など全22の特徴量から、より重要度の高い特徴量を10個を選択した結果、すべての特徴量を使うよりも精度が向上した [9]。また、Markusらの研究では、全8バンドの高解像度マルチスペクトル画像を用いたRandom Forestによる樹種の分類を行い、精度は80%以上となった。この時、使用した8バンドの中から最適

な4バンドの組合せを特定するために Permutation Importance による特徴抽出が最も効率的であると結論付けた [7]。

リモートセンシングによる土地被覆分類において、地形による陰影が分光反射率に影響を及ぼす。対策として、地形の傾斜や太陽天頂角に基づいて地形補正を行うというものがある。A.Tweleらはインドネシアのスラウェシ島の森林の土地被覆分類において、地形補正の有無による精度の差を評価した。熱帯雨林とプランテーションの二つの分類において、未補正の画像での分類精度が78.9%であり、Minnaert補正を行った分類精度が83.2%となり、地形補正の有効性を示した [10]。

本研究では、Sentinel-2/MSI画像のスギとヒノキの人工林に対して、画素単位でRandom Forestによる分類精度の検証を行った。三重県と和歌山県と奈良県のスギとヒノキの純林の国有林を対象地域とした。対象時期は2020年1月から2023年11月とした。各時期のデータに対して分類精度を算出し、季節による精度への影響を評価した。対象地域は大部分が山岳地帯であるため、斜面による影が発生する。同時期の地形補正のされていないデータとされているデータの分類精度を比較し、地形補正の精度への影響を評価した。Random Forestによる分類を行う際に使用した各波長帯の値が学習にどれだけ寄与するかを、Permutation Importanceにより算出し、分類の際に各時期においてどの波長帯が重要であるか評価した。

2 使用データ

本研究は、紀伊半島を中心に三重県、和歌山県、および奈良県を対象地域とする。これらの三県はいずれも山岳地帯が多く、林業が発達している。三重県と和歌山県と奈良県の国土面積と人工林面積と人工林率の表を表 2.1 に示す。どの県も人工林率が 60% を超えており、林業の盛んな地域である。[12]

表 2.1: 三重県、和歌山県、奈良県の国土面積と人工林面積と人工林率

県名	国土面積 (ha)	人工林面積 (ha)	人工林率
三重県	577,441	229,969	62%
和歌山県	472,471	220,320	61%
奈良県	369,094	172,203	61%

2.1 参照データ

国土数値情報から提供されている国有林野データを用いて衛星画像にラベリングを行った。国有林野データはポリゴンデータであり、各ポリゴンに樹種や面積や森林管理局コードなどの情報が含まれている。このうち、樹種がスギとヒノキのみとなっている森林のポリゴンを参照データとして用いた。ポリゴンの数はスギが 613 個、ヒノキが 717 個となった。

2.2 Sentinel-2/MSI

解析には Sentinel-2 の Multispectral Instrument(MSI) データを使用した。Sentinel-2 は Sentinel-2A と Sentinel-2B という同一の 2 つの衛星が同時に運用されており、二機を合わせて 5 日間に 1 度観測が行われる。Sentinel-2/MSI には、大気圏上部の反射率を測定している。研究対象地の全体の画像を図 2.1 に示す。

Sentinel-2/MSI には Level 1C データと、Level 1C データに大気補正と地形補正の処理を行った Level 2A データがある。Level 2A は Level 1C と Level 2A それぞれの山岳地帯の画像を図 2.2 に示す。使用した波長帯と空間解像度を表 2.2 に示す。バンド 1、9 および 10 は空間解像度が 60m と低いため使用しなかった。対象期間の期間は 2020 年 1 月から 2023 年 9 月とした。この期間に観測されたデータのうち、雲がほとんど無い、もしくは雲が少ないデータを使用した。また、参照データの範囲に雲がかかっている場合にはマスクをかけて雲の画素を使用しないようにした。使用した時期の数は 18 個となった。使用した Sentinel-2/MSI 画像の観測日時と観測衛星を表 2.3 に示す。

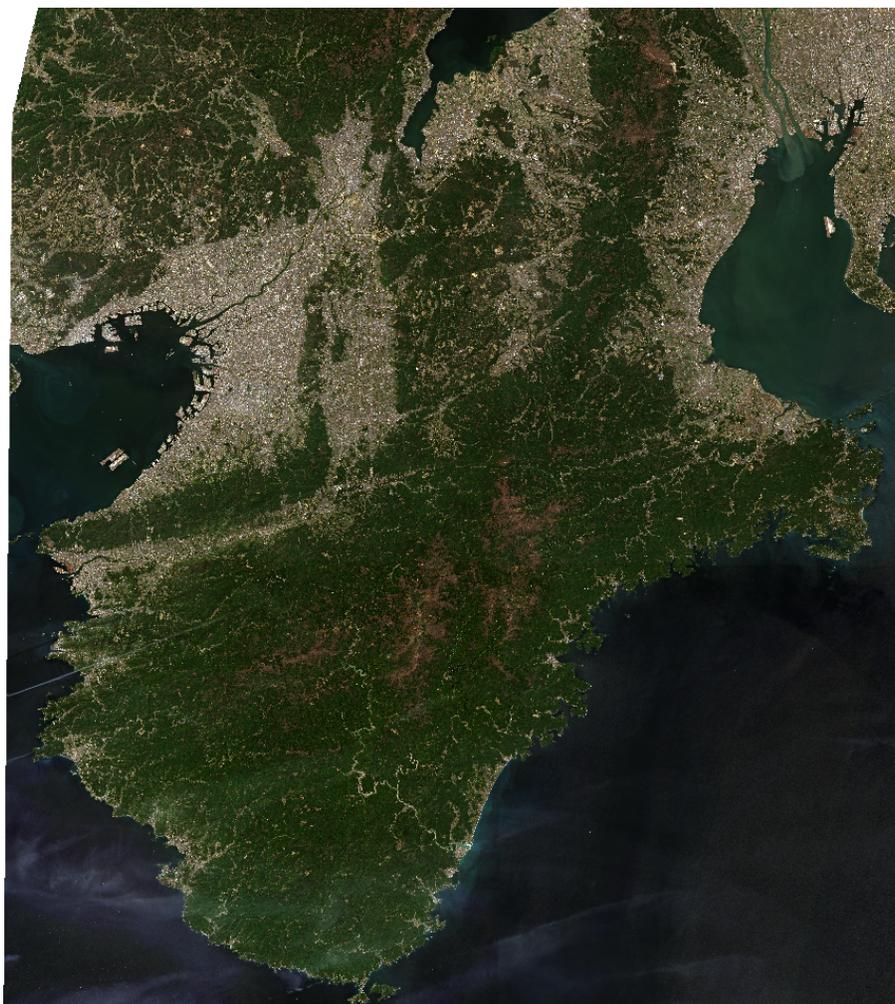
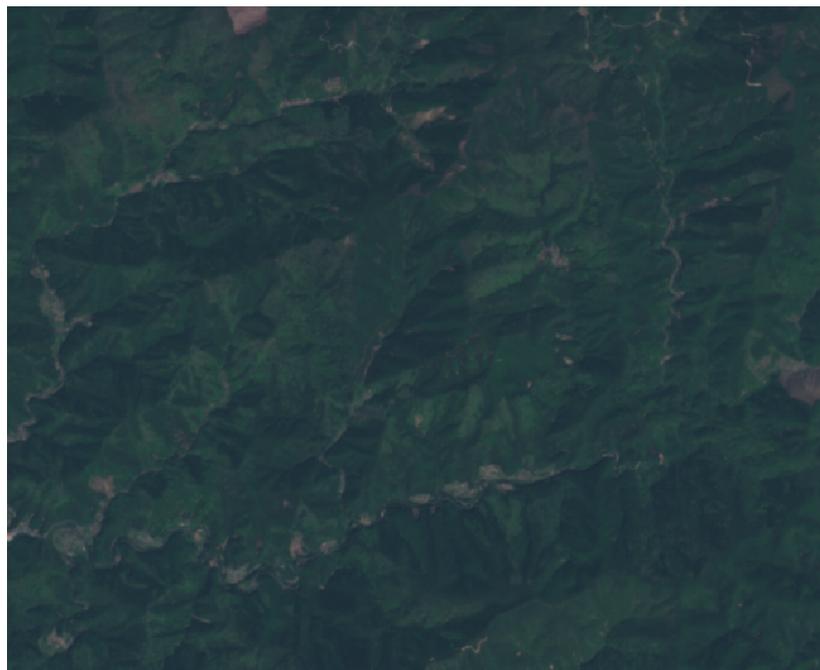


図 2.1: 研究対象地の Sentinel-2/MSI 画像

表 2.2: 使用したバンドの中心波長と解像度

バンド名	中心波長		空間解像度
	Sentinel-2A	Sentinel-2B	
B02	492.4nm	492.1nm	10m
B03	559.8nm	559.0nm	10m
B04	664.6nm	665.0nm	10m
B05	704.1nm	703.8nm	20m
B06	740.5nm	739.1nm	20m
B07	782.8nm	779.7nm	20m
B08	832.8nm	833.0nm	10m
B8A	864.7nm	864.0nm	20m
B11	1613.7nm	1610.4nm	20m
B12	2202.4nm	2185.7nm	20m



(a) Level 1C



(b) Level 2A

図 2.2: Level 1C と Level 2A データのカラー画像

表 2.3: 使用したデータの観測日時と観測衛星

観測日時	観測衛星
2020-01-06 10:40:41	Sentinel-2A
2020-04-30 10:36:49	Sentinel-2B
2020-10-27 10:37:49	Sentinel-2B
2021-01-15 10:40:19	Sentinel-2B
2021-03-31 10:36:51	Sentinel-2A
2021-04-20 10:36:51	Sentinel-2A
2021-05-30 10:36:51	Sentinel-2A
2021-10-02 10:36:49	Sentinel-2B
2021-12-11 10:40:39	Sentinel-2B
2022-01-10 10:40:29	Sentinel-2B
2022-02-09 10:38:19	Sentinel-2B
2022-04-10 10:36:49	Sentinel-2B
2022-06-29 10:36:59	Sentinel-2B
2022-11-06 10:38:39	Sentinel-2B
2023-03-11 10:36:51	Sentinel-2A
2023-06-19 10:37:01	Sentinel-2A
2023-07-04 10:36:59	Sentinel-2B
2023-09-27 10:36:51	Sentinel-2A

3 解析手法

3.1 データセットの作成

国有林野データから作成した参照データを用いて、Sentinel-2/MSI の森林の画素にラベリングを行い、機械学習用のデータセットを作成した。参照データと衛星画像を位置情報から対応させて、衛星画像からスギとヒノキの純林とされる範囲の画素のみを抽出した。同一のポリゴン内から学習用データとテストデータが作成されると精度が過剰に上がってしまうため、ポリゴン単位で学習データとテストデータを分けた。また、学習用のポリゴンの選択によって反射率が偏ると分類精度が不安定になるため、交差検証を行った。一つの衛星画像から作成したデータから5つのデータセットを作成し、各デー

データセットの精度の平均を算出した。ポリゴンは面積の大きさに差があるため、各データセットの面積の合計が近くなるように調整する必要がある。国有林野データから作成したスギとヒノキの純林のポリゴンを、それぞれのクラス毎に面積順に1から通し番号を割り振り、その番号の5の剰余でグループ分けをし、1つのグループをテストデータとし、他のグループを学習データとして5つのデータセットを作成した。各データセットのデータの個数は、学習データが約70,000個、テストデータが約17,000個となった。

3.2 分類手法

機械学習の手法には Random Forest を使用した。Random Forest はアンサンブル学習の一種で、学習データからブートストラップデータを複数作成し、そのデータによって学習された決定木による分類結果の多数決をとることによって最終的な予測を行うものである。学習の仕方を制御するハイパーパラメータは、作成する決定木の個数である 'n_estimators' を 140、決定木の最大深度である 'max_depth' を 24 とした。Random Forest の実装には、GPU アクセラレーションを活用したシステムである RAPIDS ライブラリ群の一環として提供される Cumulative Machine Learning(cuML) ライブラリを使用した。GPU には NVIDIA RTX A5000 を使用した。cuML のバージョンは 22.12.00 を使用した。

3.3 特徴量の重要度

特徴量の重要度を評価する手法として、Permutation Importance を使用した。Permutation Importance は、データセット内のある特徴量の値をランダムに並び替え、その際にモデルの性能がどれだけ低下するかによって評価する。ある特徴量が分類にとって重要なほど、並び替えた時の精度がより大きく低下する。そのため、元のデータセットによる精度とある特徴量の値を並び替えたデータセットによる精度の差が、その特徴量の重要度となる。交差検証を行っているため、1つのデータから学習モデルが5つ作られるが、Permutation Importance の計算はそのうちの1つのみで行った。

4 結果と考察

4.1 分類結果

分類した結果の画像を図 4.3 に示す。針葉樹林のエリアのみをスギとヒノキに分類した。針葉樹林の特定には JAXA より提供されている高解像度土地利用土地被覆図を用いた。スギを緑色、ヒノキを赤色として表示している。拡大した図を 4.4 に示す。地形補正のないデータでは分類結果に地形の影響がみられ、北側の斜面がスギに、南側の斜面がヒノキに分類される傾向がある。

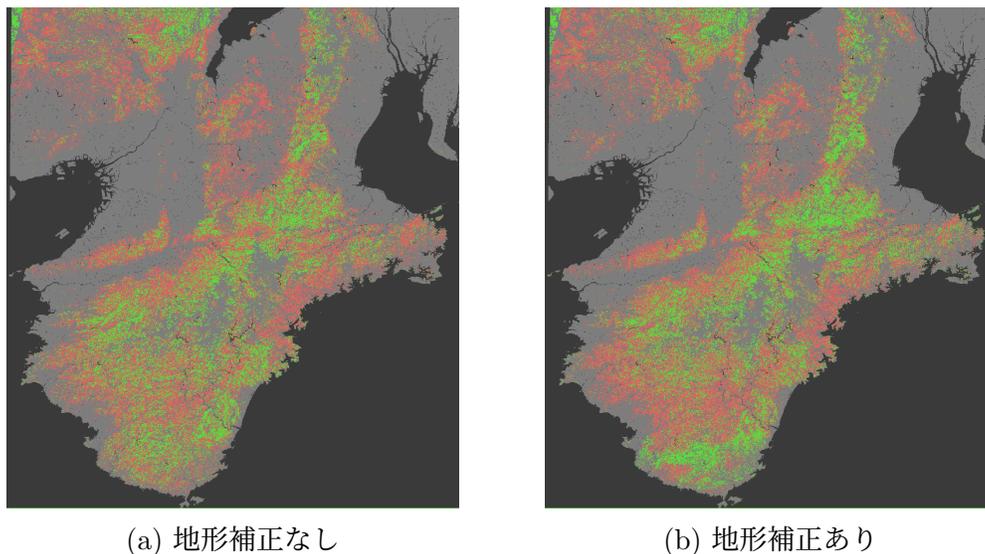


図 4.3: 2021 年 3 月 31 日のデータを用いて作成した分類画像

分類結果の画像と空中写真との比較を行う。比較対象の空中写真を図 4.5 に示す。空中写真は航空機によって撮影されており、撮影時期は 2022 年 3 月 4 日、撮影地域は和歌山県の伊都郡かつらぎ町（東経 135 度 31 分、北緯 34 度 09 分）周辺である。空中写真の上で茶色の部分がスギであり、緑色の部分がヒノキである。図 4.6 に空中写真と同じエリアの分類画像を示す。地形補正なしのデータでの分類画像の方がスギとヒノキの

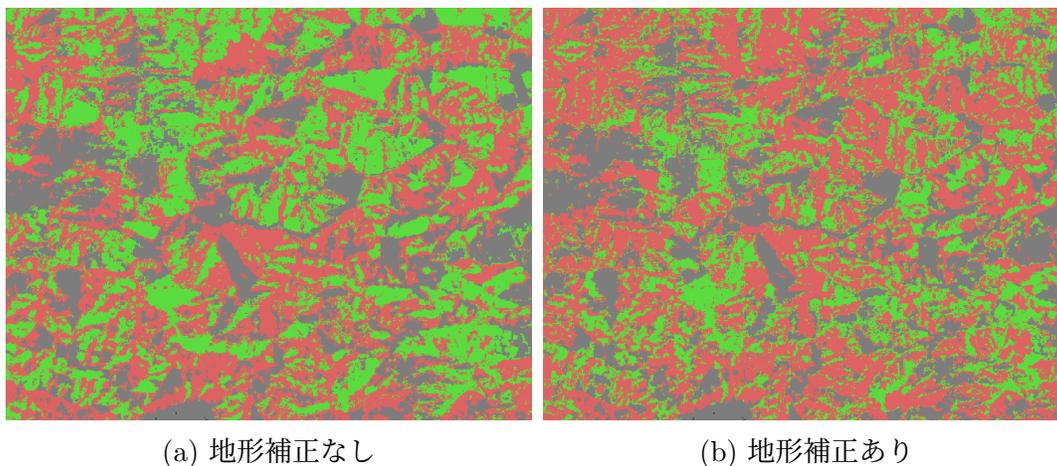
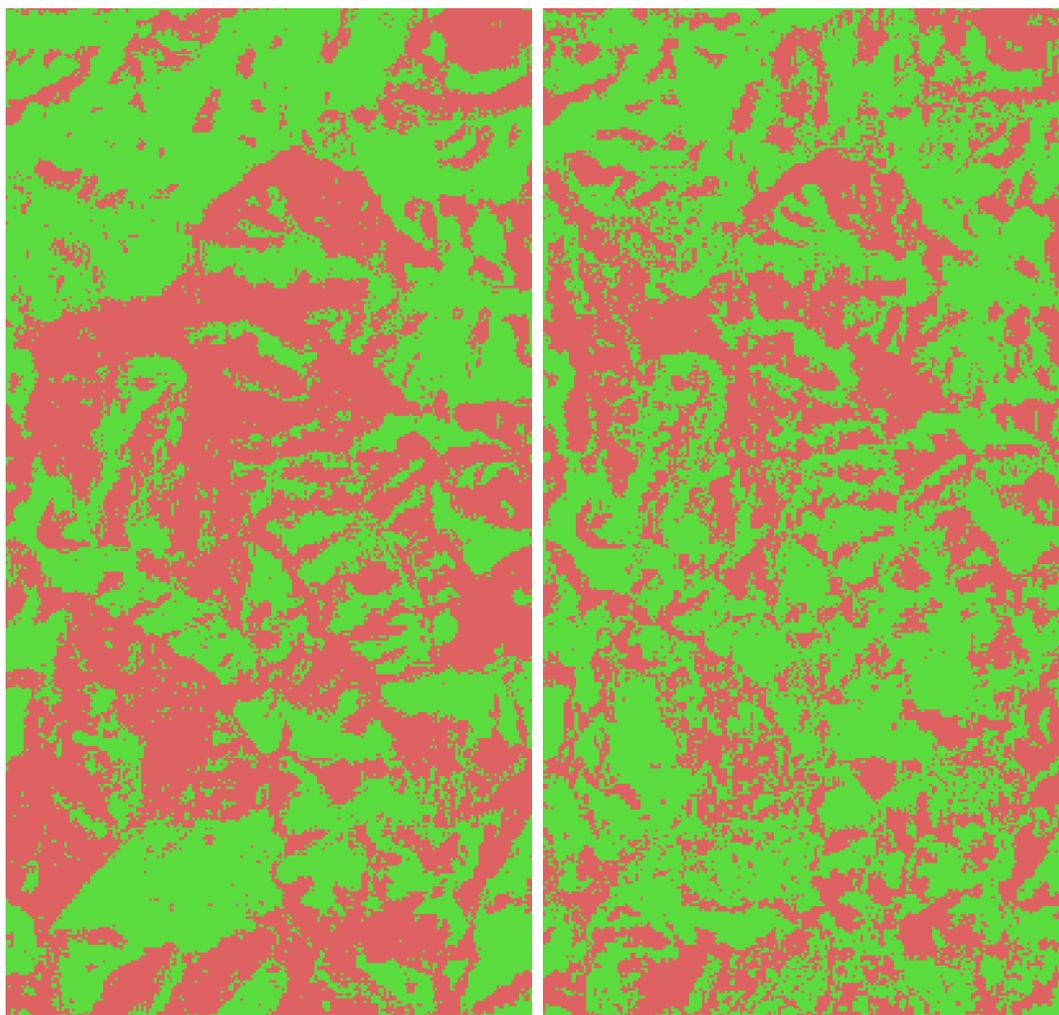


図 4.4: 2021 年 3 月 31 日のデータを用いて作成した分類画像を拡大したもの

分布の範囲が大きく分かれており、地形補正ありのデータではスギとヒノキの分布は細かく分かれている。次に空中写真の北東の部分拡大して比較する。拡大した空中写真を 4.7 に示す。茶色の谷の部分にスギが分布しており、緑色の尾根の部分にヒノキが分布していることがわかる。ヒノキの分布している尾根が中央上部と下部に V 字型になっていることが確認できる。同じ範囲について拡大した分類画像を図 4.8 に示す。どちらも V 字の形状のヒノキが正しく分類されていることがわかる。また、画像下半分にある尾根のヒノキについては、地形補正なしの分類結果は地形補正ありのものに比べて分類結果にばらつきがあり、スギと誤分類されている部分が存在する。



図 4.5: 空中写真、撮影日時:2022年3月4日、撮影地域:和歌山県伊都郡かつらぎ町



(a) 地形補正なし

(b) 地形補正あり

図 4.6: 空中写真と同じエリアの分類画像



図 4.7: 拡大した空中写真

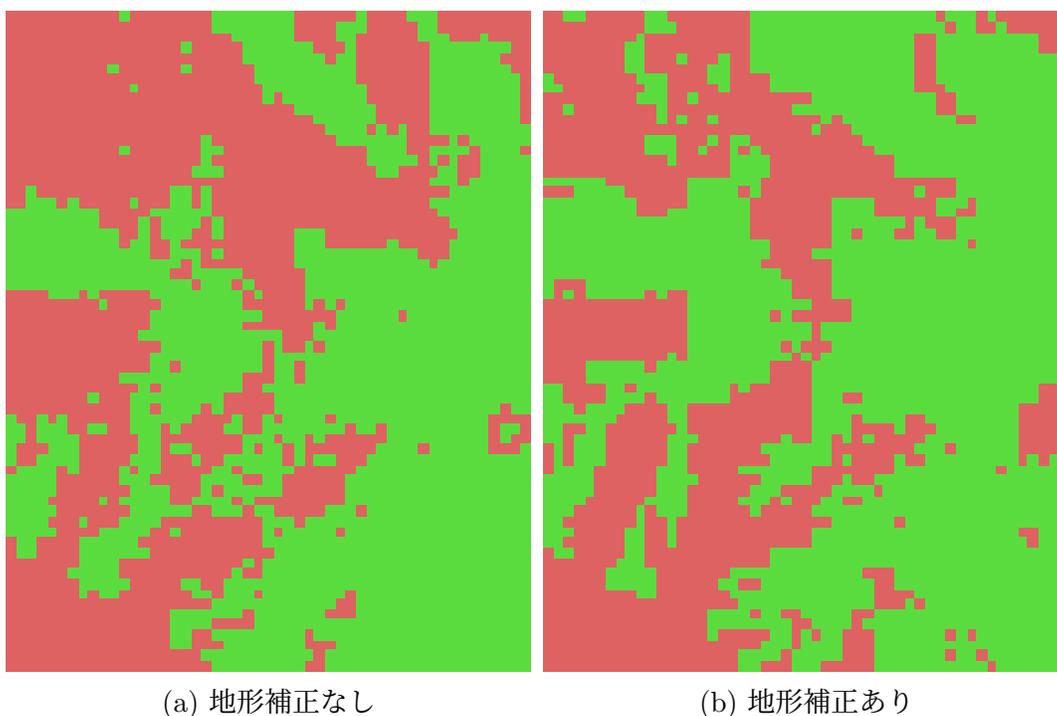


図 4.8: 拡大した分類画像

4.2 分類精度

精度を月日の順で並び替え、年間の精度の推移をグラフにしたものを図 4.9 に示す。橙色の線が地形補正なし、青色の線が地形補正ありのデータによる精度の線である。地形補正の有無や時期を問わず 80%以上となっている。3月4月と6月7月の精度が高く、2021年3月31日のデータは地形補正前のデータで 86.02%、地形補正後のデータで 84.74%と、どちらも精度が最高となっている。ほぼ全ての時期で地形補正なしのデータが地形補正ありのデータよりも精度が高くなっており、その差は平均で約 2%である。

地形補正のないデータの方が地形補正のあるデータよりも精度が高くなっているのはスギがヒノキに比べて反射率が低く、また地形の谷筋に植林されることが多いこと由来していると考えられる [11]。2021年3月31日について地形補正のあるデータと地

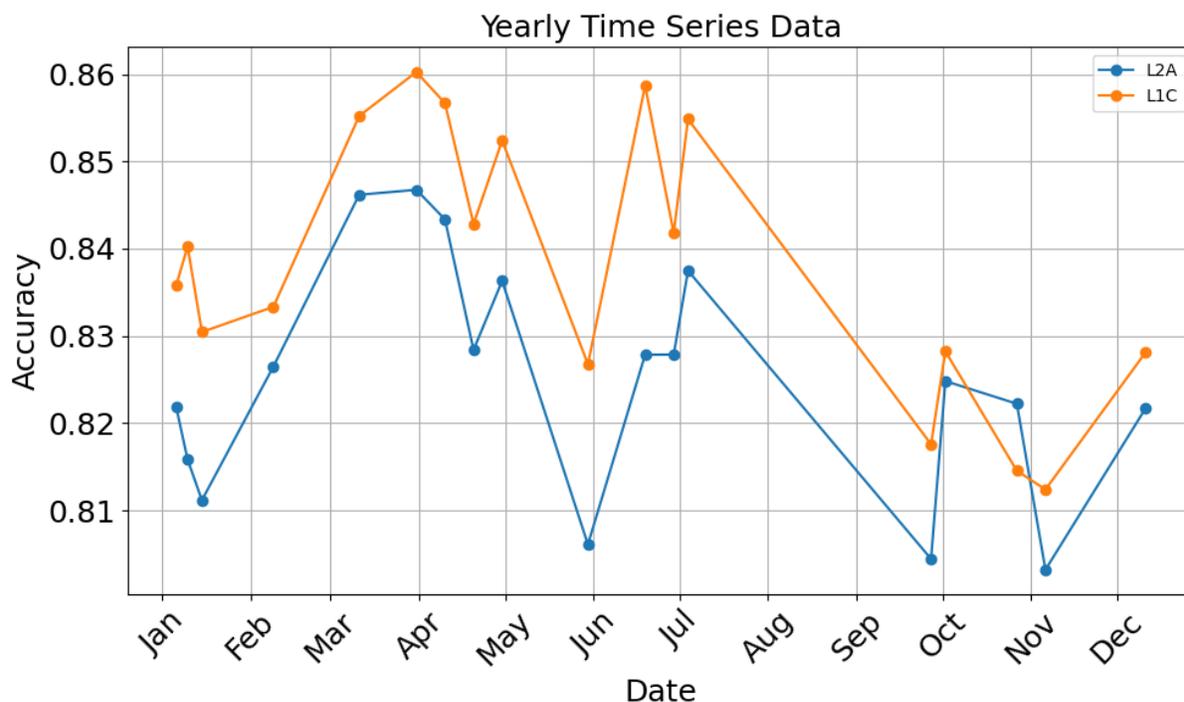


図 4.9: 年間の精度の推移のグラフ

形補正のないデータの各バンドの反射率の平均のグラフを図 4.10 に示す。青色の線と橙色の線がそれぞれスギとヒノキを示している。また、スギとヒノキのそれぞれで各バンドの反射率の標準偏差の値を縦棒で示している。スギは地形の谷筋に植林されることが多いため、地形の影になることが多い。そのため、どの波長帯でもスギの反射率はヒノキの反射率に比べて低い。地形補正のあるデータでは地形の日の当たっている部分と日陰になっている部分で反射率の差が小さい。そのため、分類におけるスギとヒノキのクラス間の反射率の値の差が小さくなり、分類精度が低くなったと考えられる。5月のデータの分類精度が前後の時期のデータに比べて低くなっている。原因として太陽高度が高くなることによって地形の影が薄くなり、精度が低くなったことが考えられる。Sentinel-2/MSI が対象地域を観測する時刻はおよそ午前 10 時 30 分であるが、対象地域

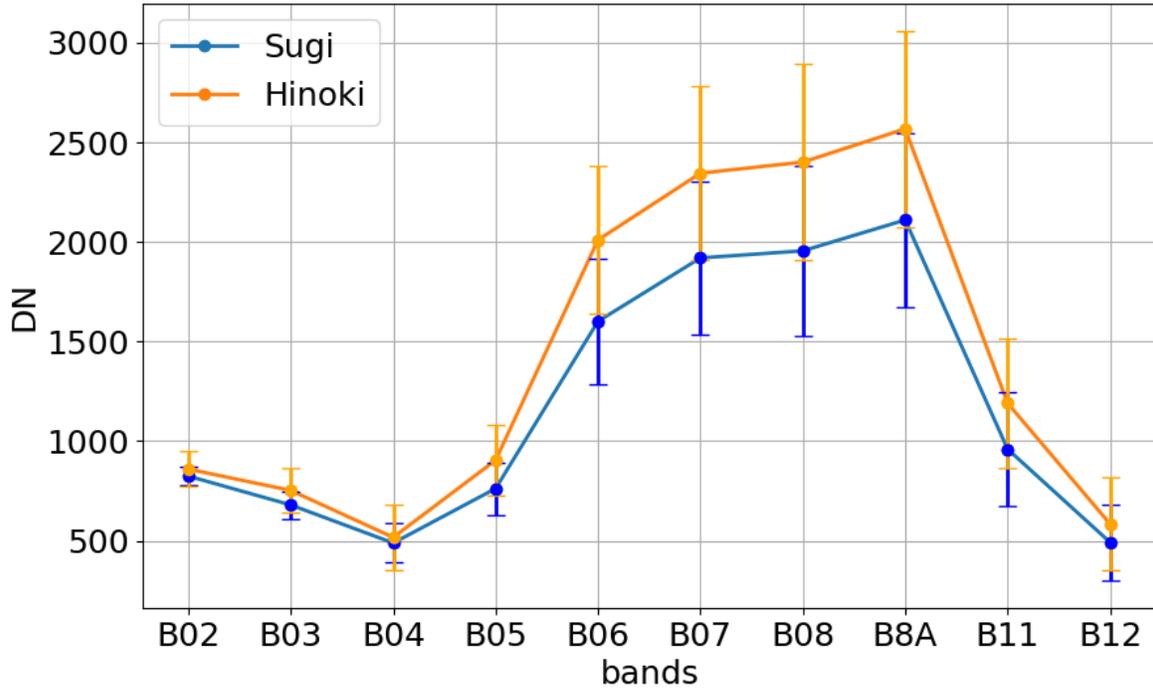
におけるその時刻の太陽高度は、4月31日と5月30日がそれぞれ63.13°、67.72°となっており、5月30日の方が高い。しかし、6月19日の太陽高度は68.01°と、5月30日よりも高くなっているが、分類精度は5月30日のデータよりも高くなっている。

4.3 波長帯の重要度

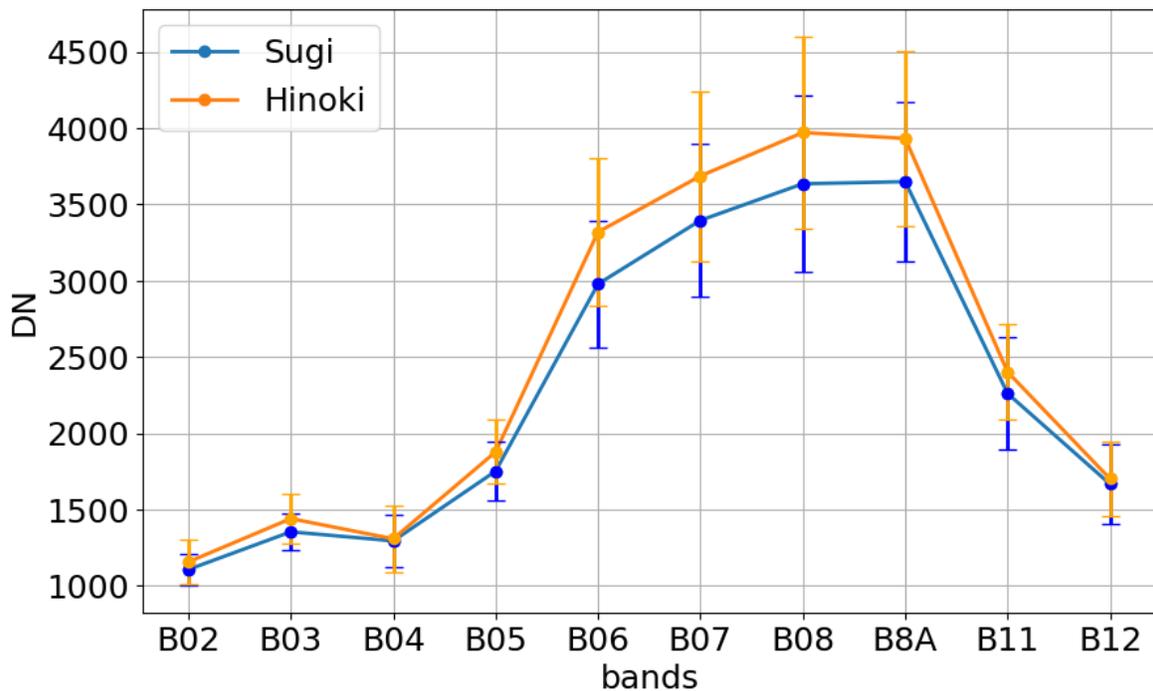
精度の高くなったデータと精度の低くなったデータについて3時期ずつ、地形補正があるデータとないデータの各波長帯の重要度のグラフを図4.11と図4.12に示す。それぞれの時期について地形補正の有無によって重要とされるバンドには相関がある場合がある。また、どの時期でもバンド3か6か11のいずれかの波長帯の重要度が高くなっている。精度の高いデータではバンド6とバンド11の重要度が高くなることが多くなった。また、9月や11月といった秋冬のデータでは、バンド3の重要度が高くなった。バンド2の重要度はどの時期でも、また地形補正の有無に関わらず極めて低く、0.01%未満となっている。精度の値と、重要となる波長帯や重要度の大きさとの関係は見られなかった。

4.4 地形補正

2020年10月27日を除くすべてのデータについて、分類精度は地形補正なしのデータが地形補正ありのデータよりも上回った。図4.13に地形補正なしのデータが正しく分類できたエリアの、地形補正なしのデータとありのデータで衛星画像と分類画像を示す。衛星画像上に描かれた線は国有林野データ上での樹種を示し、緑色がスギ、赤色がヒノキである。中央の森林は全域がスギであり、地形補正のないデータではスギが広い



(a) 地形補正なし



(b) 地形補正あり

図 4.10: 2021年3月31日の反射率の平均と標準偏差 青色: スギ 橙色: ヒノキ

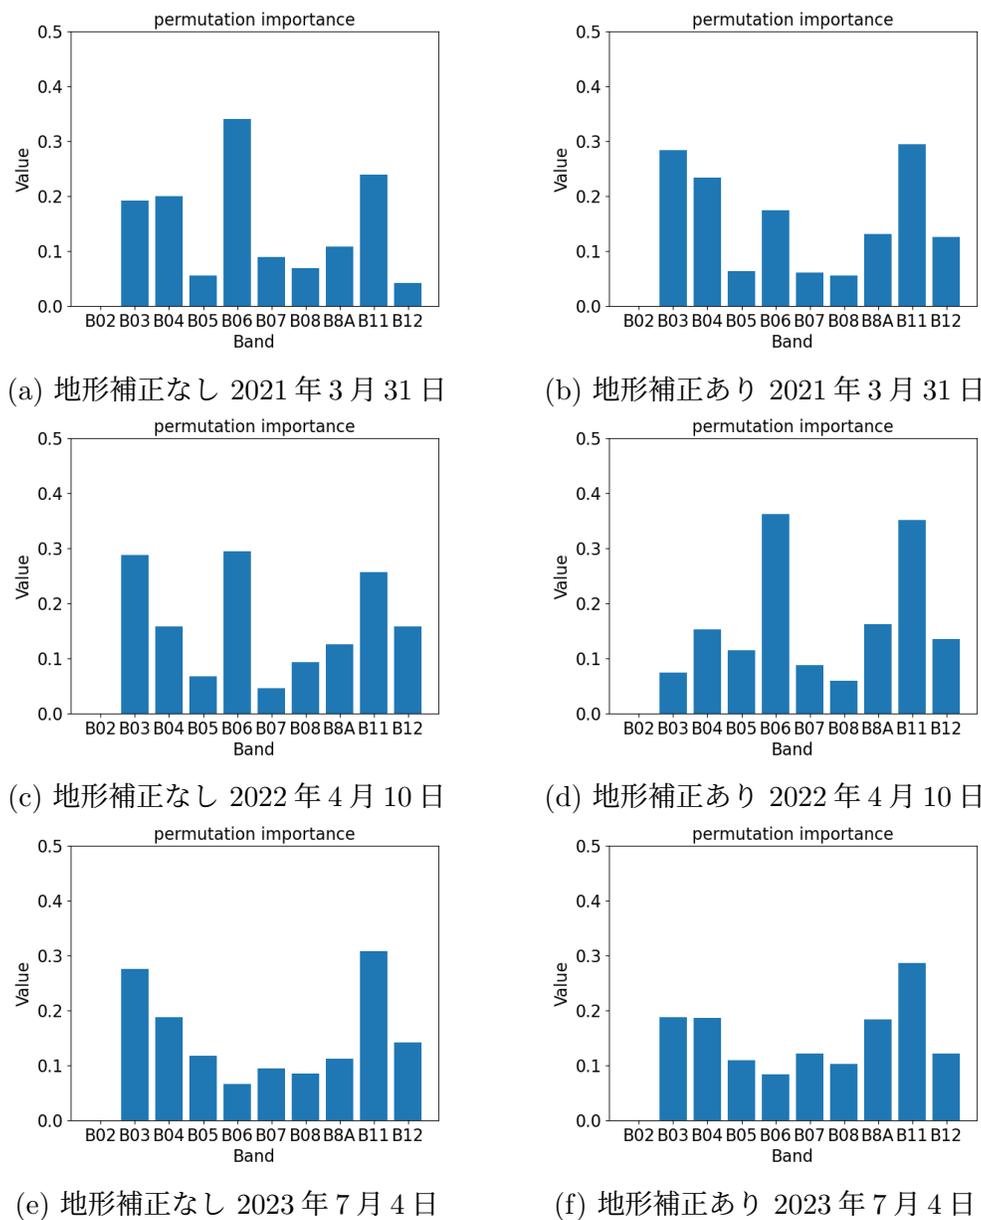


図 4.11: 各波長帯の重要度 精度の高い時期

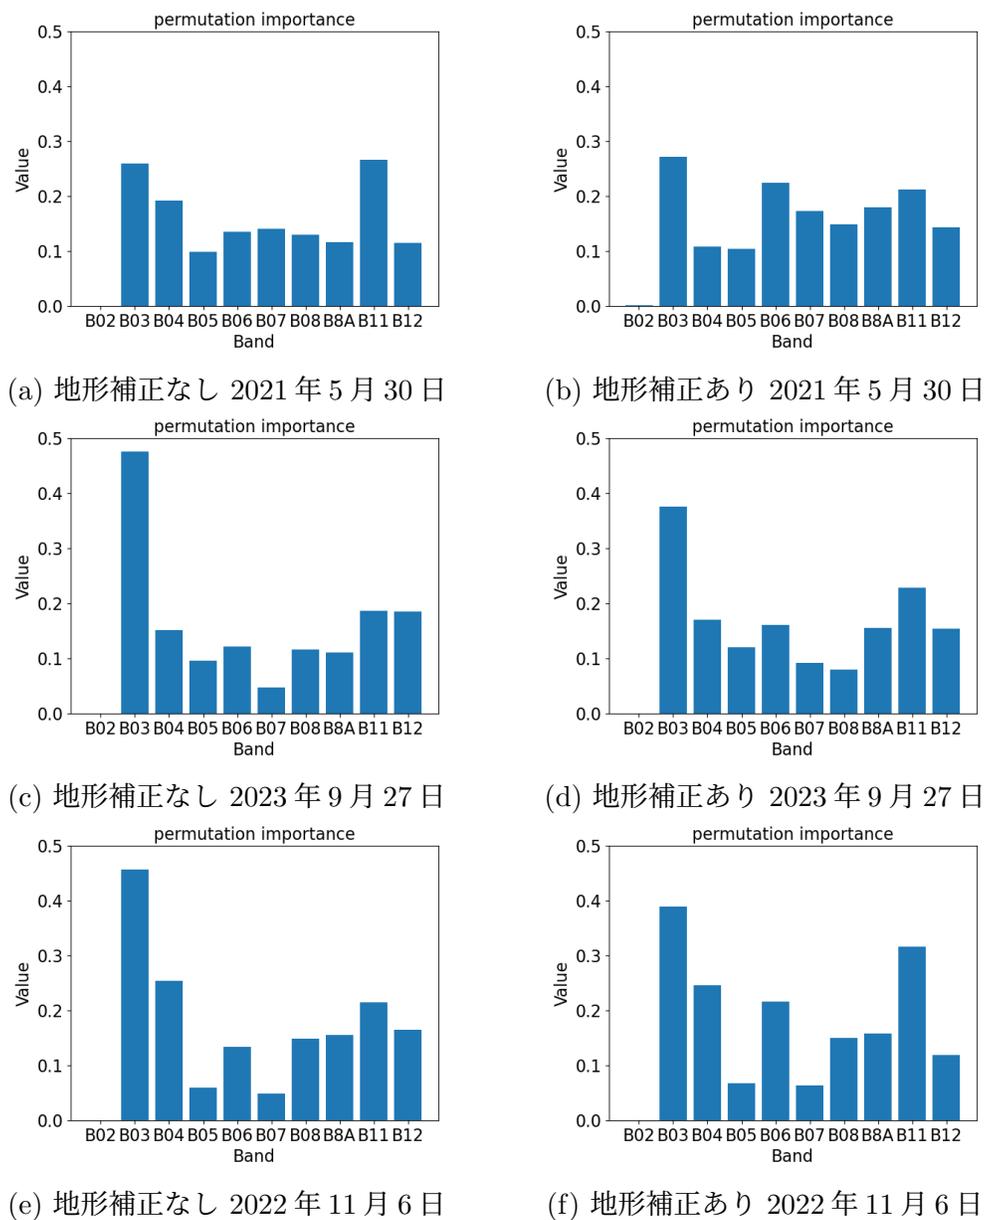


図 4.12: 各波長帯の重要度 精度の低い時期

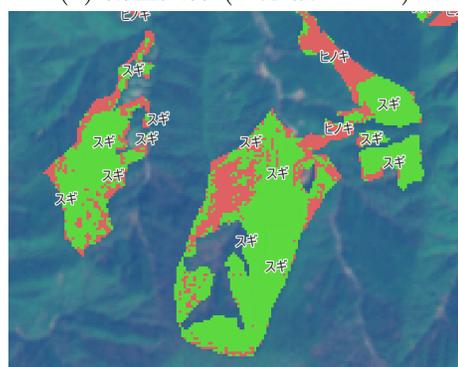
範囲で正しく分類できている。しかし、地形補正のあるデータではヒノキと分類されており、誤分類が多い。衛星画像を見ると、地形補正なしのデータでは地形の影のエリアが正しく分類されていることがわかる。図 4.14 には、地形補正なしのデータが地形補正ありのデータよりも誤分類が多くなっている例を示す。左下にある地形の日照エリアでは地形補正なしのデータは半分以上がヒノキに誤分類されているが、地形補正ありのデータでは正しく分類されている。



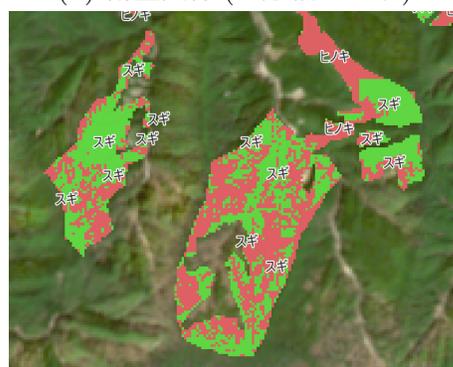
(a) 衛星画像 (地形補正なし)



(b) 衛星画像 (地形補正あり)



(c) 分類結果 (地形補正なし)



(d) 分類結果 (地形補正あり)

図 4.13: 地形補正なしのデータが地形補正ありのデータよりも正確に分類した例

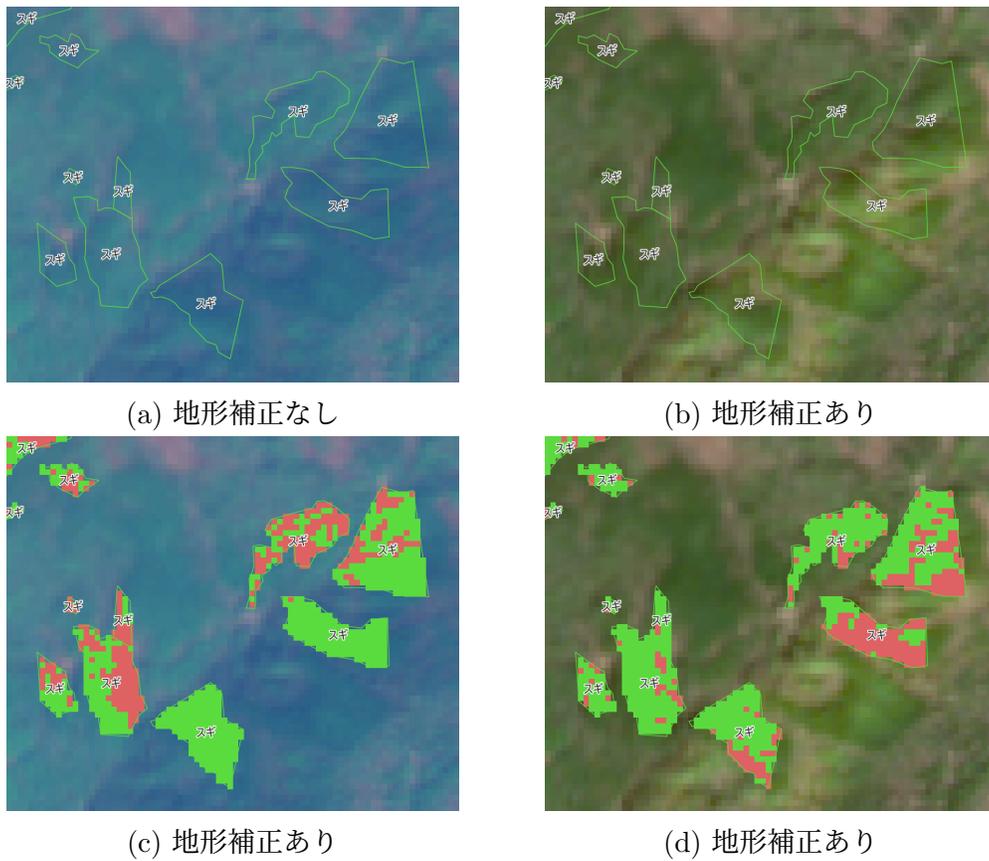


図 4.14: 地形補正ありのデータが地形補正なしのデータよりも正確に分類した例

5 おわりに

5.1 まとめ

本研究では、三重県と和歌山県と奈良県の森林を対象に Sentinel-2/MSI を用いて Random Forest によるスギとヒノキの分類を画素ごとに行った。年間のデータの各時期で分類を行い、時期による精度への影響を評価した。地形補正のあるデータと無いデータで精度の比較を行い、地形補正の有効性を評価した。Permutation Importance を用いて、機械学習の際の各特徴量の重要度を算出することで、スギとヒノキの分類において分類に有効な波長帯を評価した。実験の結果、時期による評価では、3、4月と6、7月の精度が高く、地形補正前のデータでの分類精度は約86%となり、地形補正後のデータでの精度は約84%となった。5月や9月から1月のデータは精度が低くなった。各波長帯の重要度については、3月から4月はバンド6、11の重要度が高く、3月31日ではバンド6、11の Permutation Importance がそれぞれ30%を超えた。また、9月から12月はバンド3の重要度が高く40%を超えるなど、季節により違いがみられた。また、バンド2の重要度は全ての時期で0.1%未満と小さかった。地形補正については、地形補正なしの分類精度は約82%～約87%、地形補正ありでは約80%～約85%と、ほとんどの時期で地形補正なし分類精度が2%程度高くなった。この原因として、スギは谷に、ヒノキは尾根に植林されることが多いため、樹種の分布が地形と関連することで分類精度が高くなったことが考えられる。

5.2 今後の課題

本研究では、地形の影響を減らすために地形補正を行うという手法を行ったが、スギとヒノキの分布が地形と関連していたために、地形補正をする前よりも精度が下がるという結果となった。土地被覆分類において、地形の影響を考慮する手法として、分類のクラスを地形の日照部分と日陰部分で分けるというものがある。この手法と本研究の手法の比較を今後の課題とする。

参考文献

- [1] 林野庁 スギ・ヒノキ林に関するデータ (https://www.rinya.maff.go.jp/j/sin_riyou/kafun/data.html), (参照 2024-1-31)
- [2] 内閣官房 花粉症に関する関係閣僚会議 <https://www.cas.go.jp/jp/seisaku/kafun/index.html>(参照 2024-1-31)
- [3] 斎藤英樹, 鹿又秀聡, 山田茂樹, ”オブジェクトベース分類を用いたスギ・ヒノキ林の分類”, 九州森林学会 vol.62, pp. 7-10, 2009
- [4] Yasumasa Hirata, Naoyuki Furuya, Atsushi Sakai, Tomoaki Takahashi, Yoshio Awaya, Toru Sakai, ”Segmentation and Classification with Discriminant Analysis of QuickBird Multispectral and Panchromatic Data to Distinguish Cryptomeria

- japonica and Chamaecyparis obtusa Patches”, Journal of Forest Planning, Volume 16, Special Issue, 2010
- [5] Alika Polyakova, Svetlana Mukharamova, Oleg Yermolaev, ”Automated Recognition of Tree Species Composition of Forest Communities Using Sentinel-2 Satellite Data”, Remote Sens. Volume 15, Issue 2, pp 329-349, 2023
- [6] 後藤 誠二郎, 栗屋 善雄, ”RapidEye 衛星の Red edge バンドを用いた森林タイプ分類の精度向上に関する検討”, システム農学 (J. JASS), 29 卷, 4 号, pp. 145-153, 2013
- [7] Markus Immitzer, Clement Atzberger, ”Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-band WorldView-2 Satellite Data”, Remote Sens, 2012, Volume 4, Issue 9, pp. 2661-2693, 2012
- [8] Martina Deur, Mateo Gašparović, Ivan Balenović, ”Tree Species Classification in Mixed Deciduous Forests Using Very High Spatial Resolution Satellite Imagery and Machine Learning Methods”, Remote Sens, 2020, Volume 12, Issue 23, pp. 3926-3944, 2020
- [9] Fang Zhang, Xiaojun Yang, ”Improving land cover classification in an urbanized coastal area by random forests: The role of variable selection”, Remote Sensing of Environment Volume 251, 112105

- [10] André Twele, Martin Kappas, Johannes Lauer, Stefan Erasmi, "The effect of stratified topographic correction on land cover classification in tropical mountainous region", 2006
- [11] 日本工営(株) 自然環境(森林・植生)調査 (https://www.jasdim.or.jp/gijutsu/jisuberi_joho/tyosa/sizenkankyo/sezenkankyo.html)(参照 2024-3-14)
- [12] 林野庁, 都道府県別森林率・人工林率(令和4年3月31日現在) <https://www.rinya.maff.go.jp/j/keikaku/genkyou/r4/1.html>, (参照 2024-1-31)

謝辞

本研究を遂行するにあたって、松岡真如准教授には、データの収集や助言など惜しみない協力をいただきました。深く感謝いたします。ありがとうございました。