

〔論 文〕

衛星リモートセンシングを利用した機械学習による ボルネオ島の土地利用変化検出

白石 知弘*, 平木 功明*², 清田 雄二*³, 衛藤 俊寿*⁴

*日本文理大学工学部

*²日本文理大学医療専門学校

*³日本文理大学工学部情報メディア学科

*⁴日本文理大学経営経済学部経営経済学科

Detecting Land Use Changes in Borneo Using Machine Learning and Remote Sensing

Tomohiro SHIRAISHI*, Noriaki HIRAKI*², Yuji KIYOTA*³, Toshihisa ETO*⁴

*School of Engineering, Nippon Bunri University

*²Department of Clinical Engineering, Nippon Bunri University Medical College

³Department of Media Technologies, School of Engineering, Nippon Bunri University

*⁴Department of Business and Economics, School of Business and Economics, Nippon Bunri University

Abstract

Many countries agreed that reducing anthropogenic greenhouse gas emissions and improving the carbon uptake of forests are pivotal steps toward limiting increases in the global average temperature in the Paris Agreement in 2015. Understanding land use changes is essential for comprehending the sources of greenhouse gas emissions and implementing countermeasures to reduce them, especially in terrestrial contexts. The severe deforestation in southeast Asia is largely due to its agricultural sector, which has to continuously expand, further encroaching into more natural habitats, to feed an ever-growing human population. In this study, we created annual land use maps using satellite data from 2000 to 2020 throughout Borneo and detected the land use changes by comparing the maps on an annual basis. The accuracy of the created land use maps was $92.5 \pm 1.4\%$ on average (± 1 standard deviation) over the 20 years. Specifically, there was an 8% reduction in land use changes in forests, whereas oil palm plantations expanded by 185%. The resultant maps should not only facilitate accurate carbon budget estimations from terrestrial sources in Borneo, but also act as input data for biomass estimation, atmospheric transport, terrestrial ecosystem, and meteorological models.

キーワード：土地利用変化, 熱帯泥炭湿地林, オイルパーム農園, 光学データ, ランダムフォレスト

Keywords : land use changes, tropical peat swamp forest, oil palm plantation, optical data, random forest

1. はじめに

2015年にパリ協定で締結された世界の平均気温上昇を抑制する目標を達成するために、人間活動による温室効果ガス放出量の低減と森林による炭素吸収量の増強は喫緊の課題である。森林は大気中の二酸化炭素を吸収し有機物として隔離するため、大気中の二酸化炭素濃度の緩和・生物多様性・水循環・土壌保全・防災など、地球環境と人間活動において重要な役割を担っている⁽¹⁻³⁾。世界の総森林面積は、全陸地の31%に相当する40.6億 ha であり、手付かずの自然として残っている森林は森林全域に対しわずか28%の11.1億 ha である⁽²⁾。世界の森林の純損失率を1990年から10年単位で見ると、1990年から2000年の年間780万 ha、2000年から2010年の年間520万 ha、2010年から2020年の年間470万 ha と減少傾向ではあるが⁽²⁾、九州の面積（約370万 ha）よりはるかに広大な面積の森林が毎年消失していることになる。森林の分布は熱帯林が全体の45%を占め、南米アマゾンと並び東南アジアは重要な炭素蓄積域である。しかしながら、2000年から2012年にかけて森林損失の増加率が最大である国がインドネシアであることが報告された⁽⁴⁾。森林破壊は農業・インフラ・居住地・鉱業などを目的とした人間活動による影響が大きく、森林破壊と農業拡大には強い相関関係があることが報告されている⁽¹⁾。東南アジアの森林破壊も同様に、広大な自然林は食品産業のために開発されたオイルパーム農園に転換されている⁽¹⁾。特に、インドネシアとマレーシアはパーム油の主要な生産国であり、この2ヵ国で全世界の生産量の80%以上を占める⁽⁵⁾。この生産量を支えるように、森林はマレーシアで1990年から2005年にかけて推定100万 ha 以上が、インドネシアで1990年から2000年にかけて170万から300万 ha がオイルパーム農園に転換した⁽⁶⁾。

東南アジアの泥炭は何千年にもわたって土壌に完全に分解されていない大量の植物炭素を蓄積している。蓄積された炭素量は全世界で479.7Pg とされ、東南アジアの蓄積量は全体の14%に相当する68.5Pg と推定されている⁽⁷⁾。この巨大な炭素貯蔵庫である東南アジアの熱帯泥炭湿地林が、オイルパーム農園の開発に伴う土地利用変化⁽⁸⁾、排水⁽⁹⁾、火災⁽¹⁰⁾により、バイオマスの損失、泥炭の酸化、燃焼を通じて大気へ大量の二酸化炭素を放出する。東南アジアは豊富な樹木炭素を蓄積する森林や泥炭を有する一方、森林の農地転換や森林火災が頻発する地域であり、地球環境への影響が注目されている地域である。

陸域生態系からの温室効果ガス収支を推定するために、正確な森林域とそのバイオマスを理解することは重要である。広大で人のアクセスが困難である森林域を含めた土地被覆情報を大陸・地球規模で取得するために、定期的に均質なデータを取得できる衛星リモートセンシングは最適解である。衛星による地球観測は1960年4月にアメリカ航空宇宙局（NASA）が打ち上げた TIROS 1号から始まり、1972年に光学センサを搭載した Landsat 1号により本格的な地球観測が始まった。土地被覆図の作成は、衛星データ活用の黎明期から今なお取り組まれている課題であり、土地被覆／土地利用図の自動生成は計算機や分類アルゴリズムの発展と共に高精度化している。

全球規模の土地被覆図は NASA が無償公開しているが、土地被覆種別が全球共通で、東南アジアのオイルパーム農園のように、特定地域の重要な土地利用種別に焦点を当てたデータではない。一方、Gaveau et al. (2016)⁽¹¹⁾は、ボルネオ島全域の森林とオイルパーム農園に焦点を当てた土地利用図を作成したが、2016年以降更新されていない。また、Indonesian National Carbon Accounting System (INCAS)⁽¹²⁾はインドネシア全域の土地利用面積とそこからの二酸化炭素収支を公開しているが2012年以降更新されていない。そこで本研究では、衛星光学データを利用して2000年から2020年のボルネオ島全域の土地利用図を年単位で自動生成し、得られた結果から各土地利用種別の面積変化を計測する。分類する土地利用種別は二酸化炭素収支を推定するために重要な5種類（森林、低木／草地、オイルパーム農園、水域、都市）とした。土地利用図の作成は、Shiraishi et al. (2014)⁽¹³⁾による土地利用分類へ機械学習アルゴリズムを適用した比較研究において最も高評価であったランダムフォレストを使用して自動生成する。この結果作成された土地利用図は、ボルネオ島の二酸化炭素収支の推定に必要なデータであるだけでなく、バイオマス推定、陸域生態系モデル、大気輸送モデル、気象モデルなどの重要な入力データである。本稿では、使用したデータセット、土地利用図の自動作成手法を説明した後、2000年から2020年にかけて年単位で作成した土地利用図の結果、各土地利用種別の面積変化について評価する。

2. 手法

2-1 研究領域

研究対象の領域は東南アジアのボルネオ島である（図1）。ボルネオ島は世界で3番目に大きい島（約74.3




図1. 解析域のボルネオ島 緑色はインドネシア領、橙色はマレーシア領、赤色は泥炭域⁽¹⁴⁾を示す図は Shiraishi et al. (2023)⁽¹⁵⁾ から引用した

Mha)で、インドネシア・マレーシア・ブルネイの3ヶ国の領土である。インドネシアは、北・東・西・中央・南カリマンタン州の5州、マレーシアは、サバ州・サラワク州の2州で構成される。島は赤道を挟んで北緯8度から南緯5度、東経108度から120度の間に位置し、ケッペン気候区分の熱帯雨林気候に区分される。季節は、湿った北東モンスーンの影響を受け11月頃から3・4月頃まで雨季、乾燥した南西モンスーンの影響を受ける5月頃から10月頃まで乾季に区別される。

2-2 データ

土地利用図を作成するために、NASAが運用するModerate Resolution Imaging Spectroradiometer (MODIS)MCD43A4 Version 6を使用した。MCD43A4は7バンドの観測データと品質データを有し、日次の観測頻度、約500mの空間分解能である。

機械学習による土地利用分類のための特徴量は総計228種を生成して使用した。MCD43A4の7バンドデータを基に、毎日のデータから、画素ごとに1年間の平均・標準偏差・最大値・最小値・範囲・傾き・歪度・尖度を算出した。また、特定のバンドデータを組み合わせで算出できる13種類の指数を使用した。さらに、画素単位の特徴量とは別に、これら全データのウィンドウサイズ9×9の平均値・標準偏差も算出し使用した（詳細は Shiraishi et al. (2023)⁽¹⁵⁾を参照）。

機械学習による土地利用分類において、分類モデルの

訓練と分類結果の検証に使用するツールズデータ（訓練と検証データ）は、ボルネオ島全域を対象に2000年と2016年でそれぞれ約6700地点を設定し、各地点の土地利用種別をGoogle Earth Proから目視判読によって設定した。ツールズデータは各年のデータが同一地点となるように設定した。

2-3 土地利用図の作成と土地利用変化面積の算出

光学衛星データMCD43A4からの土地利用図の作成は、図2の手順により、機械学習を使用して画素単位で土地利用分類を行った。MCD43A4のオリジナルデータは研究領域の部分的なデータであるため、ボルネオ島全域をカバーするように1つの画像データとしてモザイクした。光学データの特徴として、被雲や煙霧などの影響を受け地表面情報が得られないという短所がある。ここでは年単位で土地利用図を作成するため、処理対象年の最新データ（12月31日）を基準に特徴量を算出するが、被雲などの影響で地表面情報が得られない場合は、12月31日以前のより新しく有効なデータを最新データとするコンボジット処理を行った。ただし、1年間を通じて有効なデータがない場合は、該当画素を分類対象から除外し、土地利用図の作成後に周囲画素から最多の土地利用種別に決定した。土地利用分類は、ツールズデータを5等分し、訓練データと検証データをそれぞれ4対1で分けた5種の組み合わせにより、5回の土地利用分類を行った。つまり、年ごとに5種の土地利用図を作成した。この5種の土地利用図の画素ごとに、最多の土地利用種別を選択することにより年ごとの土地利用図を作成した。最後に後処理として、一度オイルパーム農園と分類された領域（画素）は、その年以降継続してオイルパーム農園とする処理を加えた。また、都市域や水域として分類された領域が、次の年に森林と分類された場合は、低木／草地として修正した。これらの後処理は、現実的に考えにくい土地利用変化が、衛星データのノイズや分類精度の影響などで誤分類されることを防ぐ目的で追加した。

土地利用変化の検出は、最終的に作成された2000年から2020年までの年次土地利用図から、土地利用種別ごとに面積を算出した。

2-4 評価

作成した年次土地利用図は、森林・低木／草地・オイルパーム農園・都市・水域の5種類の土地利用種別を持つ土地利用分類と、森林と低木／草地・オイルパーム農園・都市・水域の4種を非森林としてまとめた2種類の




図2. 土地利用図の作成手順

森林／非森林分類とで分類精度を評価した。評価方法は5分割の交差検定を行った。土地利用分類は、5分割されたトゥルースデータを4対1で機械学習モデルの訓練データと分類結果の検証データに分割して行った。従って、組み合わせにより5種の土地利用図が作成されるため、各土地利用図に対応した検証データにより個別に分類精度を算出した。その後、最終的な分類精度は、5種の各評価結果を総計して算出した。

土地利用分類後、後処理により最終的に土地利用図が完成した。そこで、最終的な土地利用図の精度は、土地利用図とトゥルスデータとの一致度を精度とした。森林とオイルパーム農園に関する面積とその年次変化は2000年から2016年までのボルネオ島全域で Gaveau et al. (2016)⁽¹¹⁾の研究と比較評価した。

3. 結果

3-1 機械学習による土地利用分類

ランダムフォレストアルゴリズムを使用して2000年から2020年まで年単位で土地利用分類を行った分類精度を図3に示す。図3 (a) の総合精度に注目すると、2000年から20年間の土地利用分類の平均精度は $90.3 \pm 3.4\%$

(± 1 標準偏差), 森林/非森林分類の平均精度は $93.5 \pm 1.9\%$ である。森林/非森林分類に対して土地利用分類の精度が低い結果は, 非森林域の 4 クラスで誤分類が多く発生したことを示唆する。

正しく分類された教師データの割合を示す作成者精度（図3（b））に注目すると、20年間の平均分類精度は、森林が $93.2 \pm 0.8\%$ 、低木／草地が $87.5 \pm 0.8\%$ 、都市が $80.2 \pm 2.4\%$ 、水域が $88.2 \pm 2.2\%$ という結果に対し、オイルパーム農園は $18.7 \pm 14.7\%$ であり精度が低い。しかし、正しく分類されたデータの割合を示す使用者精度（図3（c））に注目すると、オイルパーム農園は $96.2 \pm 3.8\%$ と精度が高い。これは、分類モデルがオイルパーム農園であると推定した領域は精度高く分類できたが、トゥルースデータがオイルパーム農園である多くの領域を別の土地利用種別に分類したことを示唆する。

低木／草地の使用者精度は5種類の土地利用種別の中で最も低い77.8±2.0%であり、作成者精度のオイルパーム農園の精度が2000年から2005年にかけて58.5%から6.5%に低下した際に、使用者精度の低木／草地の精度が81.6%から75.7%に低下した結果から、多くのオイルパーム農園を低木／草地と誤分類したことが示唆される。

3-2 土地利用図

土地利用分類後の後処理により最終的に得られた土地利用図の精度を図4に、2000年と2020年の土地利用図を図5に示す。図4(a)の総合精度は土地利用図が $92.5 \pm 1.4\%$ 、森林／非森林図が $94.7 \pm 0.8\%$ とどちらの精度も高い。また、土地利用図の各種別に対する作成者精度と使用者精度の平均値はそれぞれ、森林が $93.2 \pm 0.8\%$ と $96.4 \pm 1.8\%$ 、低木／草地在 $91.7 \pm 2.3\%$ と $88.7 \pm$




図 3. 土地利用分類の精度 (a) は土地利用分類と森林／非森林分類の総合精度, (b) と (c) はそれぞれ土地利用分類の生産者精度と使用者精度を示す

1.6%, オイルパーム農園が $91.6 \pm 7.3\%$ と $85.7 \pm 2.4\%$, 都市が $92.9 \pm 3.3\%$ と $95.8 \pm 1.7\%$, 水域が $94.1 \pm 3.5\%$ と $94.0 \pm 1.4\%$ であった。特に, 機械学習による分類精度が低かったオイルパーム農園が作成者精度と使用者精度共に85%を超え, 作成した土地利用図が精度高くトゥールズデータを反映した結果であることを示した。

3-3 土地利用変化

作成した土地利用図において, 2000年から2020年の土地利用種別ごとの面積の年次推移を図6に示す。ボルネオ島における5種の土地利用種別の中で最も広い面積の

土地利用種別は森林であった。2000年時点では島の約56%を占めていた森林が, $0.7\% \text{year}^{-1}$ の減少率で2020年に約52%まで減少した。森林以外の4種類の土地利用種別は2000年からの20年間で低木／草地域は3%, オイルパーム農園は185%, 都市域は26%, 水域は27%面積が拡大した。特に, 北部のマレーシアサバ州と, 南西部のインドネシア中央・南カリマンタン州にオイルパーム農園が拡大していることが視認できる(図5)。東南アジア域における森林域が減少して農地が拡大しているという先行研究と同様の結果が本研究の解析からも示唆された。




図4. 土地利用図の精度 (a) は土地利用図と森林／非森林図の総合精度, (b) と (c) はそれぞれ土地利用図の生産者精度と使用者精度を示す




図5. 土地利用種別ごとの年次面積変化 緑色は森林, 灰色は低木／草地, 黄色はオイルパーム農園, 赤色は都市, 青色は水域を示す




図6. 2000年と2020年の土地利用図 緑色は森林, 灰色は低木／草地, 黄色はオイルパーム農園, 赤色は都市, 青色は水域を示す

4. 考察

森林面積について Gaveau et al. (2016)⁽¹¹⁾と比較する。2000年と2015年の森林面積は、本研究がそれぞれ41.5Mhaと38.0Mha、Gaveau et al. (2016)⁽¹¹⁾が41.9Mhaと37.3Mhaであった。両者の推定結果による森林面積は、わずか1%程度の相違であり、共に、2000年からの15年間に森林面積が減少したことを示した。同様に、オイルパーム農園面積の2000年と2015年の比較は、本研究がそれぞれ1.2Mhaと2.8Mha、Gaveau et al. (2016)⁽¹¹⁾が3.6Mhaと9.2Mhaと推定結果に大きな差が生じた。本研究の土地利用分類の分類精度で示されたように、オイルパーム農園の分類精度は低く、トゥルースデータがオイルパーム農園である地点の多くが他の土地利用種別に分類されていたことがこれらの差が生じた要因である可能性がある。中程度の空間解像度の光学データ (MODIS) において、成熟したオイルパーム農園は低木域や森林域と見分けることは人間による目視判別も含めて非常に困難である。Gaveau et al. (2016)⁽¹¹⁾は機械学習による自動分類の後、現地専門家の手作業により土地利用図の更新が施されている。Gaveau et al. (2016)⁽¹¹⁾の土地利用図を Google Earth Pro にて目視確認をしたところ、オイルパーム農園域の中には、裸地・草地・低木域と思われる領域も多くあった。オイルパーム植林前の未開発地を含めて、開発初期の領域をオイルパーム農園として土地利用図を作成している可能性が考えられる。これらの詳細な土地利用情報は機械学習の訓練データとして、また土地利用図の評価データとして非常に重要である。高精度の土地利用図の作成のために正確なトゥルースデータの作成は不可欠であり、Google Earth Pro による目視判読だけでは得られない現地情報の収集のために現地の専門家とのコラボレーションは重要である。

5. おわりに

本研究は衛星光学データに機械学習を適用して2000年から2020年におけるボルネオ島の年次土地利用図を作成した。これらの結果から、ボルネオ島の森林減少とオイルパーム農園の拡大が示唆された。土地利用図の作成は、森林／非森林域において20年間の平均で94%を超える分類精度であったが、オイルパーム農園の分類に課題が残った。土地利用分類の精度向上のために、地上バイオマス計測に有用である合成開口レーダデータ、森林の

鉛直構造が計測可能なライダーデータなど、光学データに加えて異なる特性を持つ衛星データの適用が解決策として考えられる。気候変動の適応と緩和に対する取り組みの1つとして、新たなデータを加えた分類アルゴリズム開発やデータ分析に持続的に取り組む必要がある。

謝辞

本研究はJSPS 科研費 JP19H05666の助成を受けたものである。解析に使用したMCD43A4はUSGS EROS センターを通じNASA LP DAAC から入手した。記して感謝の意を表す。

参考文献

- (1) Food and Agriculture Organization (FAO). (2016). State of the World's Forests 2016. Forests and agriculture: land-use challenges and opportunities. Rome.
- (2) Food and Agriculture Organization (FAO). (2020). Global Forest Resources Assessment 2020—Key findings. Rome.
- (3) Intergovernmental Panel on Climate Change (IPCC). (2019). IPCC Special Report on Climate Change, Desertification, Land Degradation, Sustainable Land Management, Food Security, and Greenhouse gas fluxes in Terrestrial Ecosystems. Summary for Policymakers Approved Draft.
- (4) Hansen, M. C., Potapov, P. V., Moore, R., Hancher, M., Turubanova, S. A., Tyukavina, A., Thau, D., Stehman, S. V., Goetz, S. J., Loveland, T. R., Kommareddy, A., Egorov, A., Chini, L., Justice, C. O., & Townshend, J. R. (2013). High-resolution global maps of 21st-century forest cover change. *Science*, 342 (6160), 850–853.
- (5) Koh, L.P. and Wilcove, D.S. (2007) Cashing in palm oil for conservation. *Nature*, 448 (7157), 993–994.
- (6) Fitzherbert, E., Struebig, M., Morel, A., Danielsen, F., Bruhl, C., Donald, P., & Phalan, B. (2008). How will oil palm expansion affect biodiversity? *Trends in Ecology & Evolution*, 23 (10), 538–545.
- (7) Page, S. E., Rieley, J. O., & Banks, C. J. (2011).

- Global and regional importance of the tropical peatland Carbon Pool. *Global Change Biology*, 17 (2), 798–818.
- (8) Langner, A., Miettinen, J., & Siegert, F. (2007). Land cover change 2002–2005 in Borneo and the role of fire derived from Modis imagery. *Global Change Biology*, 13 (11), 2329–2340.
- (9) Hooijer, A., Page, S., Jauhiainen, J., Lee, W. A., Lu, X. X., Idris, A., & Anshari, G. (2012). Subsidence and carbon loss in drained tropical peatlands. *Biogeosciences*, 9 (3), 1053–1071.
- (10) Langner, A., & Siegert, F. (2009). Spatiotemporal fire occurrence in borneo over a period of 10 years. *Global Change Biology*, 15 (1), 48–62.
- (11) Gaveau, D. L., Sheil, D., Husnayaen, Salim, M. A., Arjasakusuma, S., Ancrenaz, M., Pacheco, P., & Meijaard, E. (2016). Rapid conversions and avoided deforestation: Examining four decades of industrial plantation expansion in Borneo. *Scientific Reports*, 6 (1).
- (12) Indonesian National Carbon Accounting System (INCAS). (2017, February 27). Retrieved September 22, 2021, from <http://incas.menlhk.go.id/>.
- (13) Shiraishi, T., Motohka, T., Thapa, R. B., Watanabe, M., & Shimada, M. (2014). Comparative assessment of supervised classifiers for land use-land cover classification in a tropical region using time-series palsar mosaic data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7 (4), 1186–1199.
- (14) Gumbrecht, T., Román-Cuesta, R. M., Verchot, L. V., Herold, M., Wittmann, F., Householder, E., Herold, N., & Murdiyarso, D. (2017). Tropical and subtropical wetlands distribution version 2. Bogor City, Indonesia: Center for International Forestry Research (CIFOR).
- (15) Shiraishi, T., Hirata, R., Hayashi, M., & Hirano, T. (2023). Carbon dioxide emissions through land use change, fire, and oxidative peat decomposition in Borneo. *Scientific Reports*, 13 (1).

