

機械学習や画像処理技術を援用した 衛星画像からの被災箇所抽出に関する研究

STUDY ON EXTRACTION OF DISASTER AREA FROM SATELLITE IMAGE USING MACHINE LEARNING AND IMAGE PROCESSING TECHNOLOGY

妹尾 大輝¹⁾, 久保 栞²⁾, 磯打 千雅子³⁾, 吉田 秀典⁴⁾

Daiki SENO, Shiori KUBO, Chikako ISOUCHI and Hidenori YOSHIDA

- 1) 香川大学大学院工学研究科 (〒761-0396 香川県高松市林町 2217-20, E-mail: s21g404@stu.kagawa-u.ac.jp)
2) 東京大学生産技術研究所 (〒277-8574 千葉県柏市柏の葉 5-1-5, E-mail: shiori_kubo@metall.t.u-tokyo.ac.jp)
3) 香川大学 四国危機管理教育・研究・地域連携推進機構 (〒760-8526 香川県高松市幸町 1-1, E-mail: isouchi.chikako@kagawa-u.ac.jp)
4) 香川大学創造工学部 (〒761-0396 香川県高松市林町 2217-20, E-mail: yoshida.hidenori@kagawa-u.ac.jp)

In recent years, heavy rain disasters which are occurred frequently in various parts of Japan are caused severe damages. It is important to identify the damaged area for recovery and reconstruction. In this study, we focus on optical satellite images that are easy to process and interpret, and estimate the damaged area by combining existing methods such as land cover classification by machine learning and additive color mixing method. As a result, it is possible to visually express the land cover changes before and after the disaster in a specific categories and estimate the damaged area.

Key Words: satellite image, machine learning, land cover classification, additive color mixture

1. 緒言

近年, 地球規模の気候変動に起因して, 大規模な豪雨災害が日本各地で頻発しており, 治水構造物などの能力を上回るものが増加している. 日本の平均気温は 100 年あたり 1.19 °C の割合で上昇し, 猛烈な雨 (1 時間降水量 80mm 以上の雨) の年間発生回数も増加しているため, 今後, さらに大規模な水災害が発生する可能性が高い. こうしたことを受け, 風水害について事前の治水対策を行うことも重要であるが, 被害が起きた後の治水構造物や企業・施設などの復旧・復興を迅速に進めていくことも重要であると言える.

豪雨災害の中でも広範囲におよぶ被害をもたらした平成 30 年 7 月豪雨では, 豪雨の影響によって内水氾濫や土砂・洪水氾濫等

の複合的な要因による被害が発生した. これより, 災害把握に時間を要し, 復旧・復興が難航したという課題が挙げられている⁽¹⁾. したがって, 災害後において広域にわたる被災箇所を把握することが重要であると言える.

広域におよぶ被災箇所の把握には, リモートセンシングにより得られた衛星画像が使用されることが多くなっている. 特に, 豪雨災害に関しては, 災害直後, 雲が多く発生するという点から, 全天候型で昼夜観測が可能である合成開口レーダ (SAR: Synthetic Aperture Radar) を使用した研究が多く行われている. しかし, 合成開口レーダは, 処理が複雑かつ高価であるという課題があり, 専門的な知識を持たないユーザーにとっては敷居が高いものとなっている. 一方で, 光学衛星画像は, 豪雨による雨雲や台風通過後の晴天を狙った日中でしか観測が行えないが, 可視光・近赤外など多くのバンド情報の取得が可能であり, 合成開口レーダ




Fig.1 Optical satellite images of before(left) and after(right) disaster

と比較して判読が容易であるという利点がある。

衛星画像からの被災箇所抽出の手法については、金城ら⁽²⁾や本田ら⁽³⁾のように合成開口レーダを用いて浸水域を評価するなどの手法が多く提案されている。しかし、光学衛星画像に関しては、前述した撮影条件の課題から豪雨災害における被災箇所抽出手法が少ないのが現状である。作野ら⁽⁴⁾や洲濱ら⁽⁵⁾のように光学衛星画像を使用した豪雨災害の災害観測も行われてはいるが、速報レベルの研究に留まっているものが多い。

本論文では、処理が容易で安価な光学衛星画像に着目し、機械学習と画像処理技術を組み合わせて被災箇所の抽出を行い、災害復旧・復興に有用な情報の取得を目指す。

2. 衛星画像データ

被災箇所の抽出を行うにあたり、産業技術総合研究所が提供する LandBrowser⁽⁶⁾ という衛星データプラットフォームより、Landsat8 (解像度 30m) の衛星画像を取得した。LandBrowser では、主に Landsat8, ASTER, Sentinel-2 の 3 種類のグローバルデータが利用可能である。人工衛星はそれぞれに観測バンドを持ち、バンドごとに得られる画像を組み合わせることで実際に近い色の画像を作成することができる。しかし、ASTER は青色に相当するバンドが存在せず、Sentinel-2 は LandBrowser の仕様でバンドごとの保存が不可能となっている。本研究では、バンドを組み合わせ、航空写真のようなカラー画像を分析に使用するため、可視域の波長を観測するバンドの保存が可能である Landsat8 のデータを採用した。提供されている Landsat8 の画像は、観測バンドごとに観測される波長が異なっているため、バンド単体ごとの画像では分析が行えない。そこで、オープンソースの地理情報システムツールである QGIS を使用し、赤、緑、青の波長を観測する

Band 4, Band 3, Band 2 に対して RGB 合成を行った。RGB 合成を行った衛星画像データに関しては、災害前後の土地被覆変化により被災箇所を抽出するため、災害前の画像と災害後の画像を用意した (Fig. 1)。ここで、二時期の画像を分析する際の留意すべき点として、対象地域の季節による土地被覆変化が挙げられる。例えば、水田は河川に隣接した広い平野に存在し、さらに初夏の田植えの時期ならば水田に水が張っている。そのため、本来水域でない箇所が土地被覆分類などの画像分析によって水域として判断されてしまう可能性がある。水田の水位は季節ごとに管理されているため、同時期の画像データを使用することで、土地被覆分類を行う際にも同じカテゴリとして分類することができるようになる。こうしたことから二時期の画像分析を行う際は季節に注意して衛星画像を選定する必要がある。対象とした地域は、平成 30 年 7 月豪雨で甚大な被害を受けた岡山県倉敷市真備町である。真備町は、住居や構造物が少なく、山・草地といった植生が豊富な箇所が散見され、市街地周辺には田畑が広く分布している。また、Fig. 1 に示すように、東部を縦断するように流れる高梁川や真備町南部を流れる小田川、高梁川の流域付近にある貯水池など水域も多く存在している。真備町の地形の特徴として、真備町の北部にあたる山側は高くなっており、一方で南部の小田川付近は低い平野になっている。

また、使用する光学衛星画像の撮影日は以下の通りである。災害前の画像として、真備町での浸水被害がピークを迎えた 2018 年 7 月 7 日に最も近い日に撮影された 2018 年 4 月 20 日の画像を、災害後の画像として、災害発生日から約 10 ヶ月経過した 2019 年 5 月 25 日に撮影された画像を使用する。災害後の画像に関しては、人工衛星の周回軌道上の関係から、必ずしも対象地

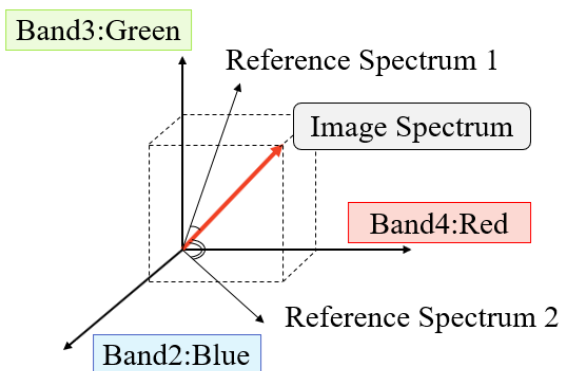


Fig2 Conceptual diagram of SAM

域の画像を撮影しているとは限らないため、災害発生日に直近で撮影されたものは LandBrowser では入手困難である。したがって、前述した留意点を踏まえ、誤分類を防ぐために災害発生日に直近であり、かつ季節の影響が少ない撮影時期のものを選択した。1章において、発災時には治水構造物や企業・施設の復興・復旧を迅速に進めていくことが必要と記述したが、本来であれば災害直後の画像を使用することで迅速な被災箇所の把握が可能になる。しかし、本研究では以下に示す手法を用いることで、衛星画像から被災箇所が把握できるか否かを確認するため、取得が容易な衛星画像を使用している。その結果、手法の有用性が認められたならば、発災直後の衛星画像を用いたとしても、同様に被災箇所の抽出が可能であると言える。

3. 画像分析手法

本研究では、光学衛星画像に対し、機械学習手法を用いた土地被覆の分類を行った後、分類図に加色混合法を適用することで被災箇所を抽出する。

3.1. 機械学習手法

土地被覆分類を行う手段として、機械学習手法の中で教師つき分類という手法がある。教師つき分類とは、教師あり学習を画像処理に応用したもので、画像内に含まれる特定の地物の分類を教師データを用いて行う方法である。一般的に、分類前に特定箇所の地物が既知である場合、地物の特徴データを教師データとして分類する。教師つき分類のアルゴリズムの内、本研究では最尤法と SAM (Spectral Angle Mapping) を使用して土地被覆分類を行った。

最尤法とは、地物の特徴量を各バンドの平均輝度値と分散で表し、それらを教師データとして分類する手法である。分類対象画像の各バンドにおける輝度値と、地物の各バンドの平均輝度値から計算される偏差行列と偏差の転置行列、そして分類対象地物の分散共分散行列と地物の分散共分散逆行列を使用し、Eq. (1)

に示す値（尤度）が最大になる地物に分類する。尤度とは、あるカテゴリにおけるデータの分布を表す関数であり、正規分布に従うと仮定する。すなわち、あるカテゴリに特定のデータが属することが尤もらしい度合いを示す。

最尤法における尤度の計算では、まず、画像ピクセルから得られる特徴を n 次元のベクトル x で表し、 $x = [x_1, x_2, \dots, x_n]$ とする。ここで、 n とは衛星画像のバンド数のことを表す。光学衛星画像は、複数のバンドが組み合わさっており、航空写真のようなカラーで表示するためには、赤・緑・青のバンドを使用する。2章で示したように、使用した衛星画像は赤・緑・青を示す Band 4, Band 3 ならびに Band 2 を合成しているため、バンド数は $n = 3$ となる。また、 x の要素の平均ベクトルを

$m = [m_1, m_2, \dots, m_n]$, 分散行列を

$$\Sigma = \begin{pmatrix} \sigma_{11}^2 & \sigma_{12}^2 & \dots & \sigma_{1n}^2 \\ \dots & \dots & \dots & \dots \\ \sigma_{n1}^2 & \sigma_{n2}^2 & \dots & \sigma_{nn}^2 \end{pmatrix}$$

とすると、ある分類カテゴリ k のベクトルは $x_k = [{}_k x_1, {}_k x_2, \dots, {}_k x_n]$, その平均ベクトルは $m_k = [{}_k m_1, {}_k m_2, \dots, {}_k m_n]$, 分散行列は

$$\Sigma_k = \begin{pmatrix} {}_k \sigma_{11}^2 & {}_k \sigma_{12}^2 & \dots & {}_k \sigma_{1n}^2 \\ \dots & \dots & \dots & \dots \\ {}_k \sigma_{n1}^2 & {}_k \sigma_{n2}^2 & \dots & {}_k \sigma_{nn}^2 \end{pmatrix}$$

と表される。分類カテゴリ k に対する未分類の画像ピクセル x の尤度が正規分布で表されるとして、Eq. (1) のように尤度が計算される。

$$L(x, k) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma_k|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} d_M^2(x, k) \right\} \quad (1)$$

ここで、 $L(x, k)$ はカテゴリ k に対するデータ x の尤度、 $|\Sigma_k|$ はカテゴリ k の分散共分散行列式、 n はバンド数（特徴量の数）、 $d_M^2(x, k)$ はマハラノビス距離である。マハラノビス距離とは、空間上の点と点との距離を表すユークリッド距離 (Eq. (2)) を分散・共分散で正規化した値であり、Eq. (3) のように表される。

$$d_E^2(x, k) = (x - m_k)(x - m_k)^t \quad (2)$$

$$d_M^2(x, k) = (x - m_k) \Sigma_k^{-1} (x - m_k)^t \quad (3)$$

ここで、 x は n 次元ベクトル、 m_k はカテゴリ k の平均ベクトル、 $(x - m_k)$ は偏差行列、 $(x - m_k)^t$ は偏差の転置行列、 Σ_k^{-1} はカテゴリ k の分散共分散逆行列である。すなわち、Eq. (1) は Eq. (3) を用いて、Eq. (4) のように書き換えることができる。

$$L(x, k) = \frac{1}{(2\pi)^{\frac{n}{2}} |\sum_k|^{-\frac{1}{2}}} \exp \left\{ -\frac{(x - m_k) \sum_k^{-1} (x - m_k)^t}{2} \right\} \quad (4)$$

しかし、実際のカテゴリ処理では、尤度に対して対数を取ることで Eq. (5) のように計算量を削減している。

$$L'(x, k) = \ln(|\sum_k|) + \{(x - m_k) \sum_k^{-1} (x - m_k)^t\} \quad (5)$$

すなわち、最尤法は、以上の式から求められる値が最小になる地物に分類されるような手法である (7)(8)。

SAM は、画像ピクセルスペクトルと参照ピクセルスペクトル間のスペクトル類似性を計算することにより、ピクセルの分類を行うアルゴリズムである。画像における各ピクセルは、 n 個の異なるバンドにおける場所 (x, y) での強度を示す値のベクトルとなっており、このベクトルがピクセルスペクトルと呼ばれる。前述したように、光学衛星画像は赤・緑・青の3つのバンドを組み合わせているため $n = 3$ となり、Fig. 2 に示すように三次元のベクトルとして扱う。スペクトルの類似性は、画像ピクセルスペクトルと参照ピクセルスペクトル間の角度を計算することにより判断でき、その角度を類似度として最近傍法により分類を行う。Fig. 2 において、座標系を x 軸 (赤 (Red)), y 軸 (緑 (Green)), z 軸 (青 (Blue)) に設定し、各方向の単位ベクトルをそれぞれ \vec{e}_R , \vec{e}_G , \vec{e}_B とすると、未知のスペクトル t と参照スペクトル r は以下のように表せる。

$$\vec{t} = t_R \vec{e}_R + t_G \vec{e}_G + t_B \vec{e}_B \quad (6)$$

$$\vec{r} = r_R \vec{e}_R + r_G \vec{e}_G + r_B \vec{e}_B \quad (7)$$

この未知のスペクトル t と参照スペクトル r の類似性を次式によって決定する (9)。

$$\theta(x, y) = \cos^{-1} \left(\frac{\vec{t} \cdot \vec{r}}{\|\vec{t}\| \cdot \|\vec{r}\|} \right) \quad (8)$$

Eq. (8) は、次のように書くこともできる (7)(10)。

$$\theta(x, y) = \cos^{-1} \left(\frac{\sum_{i=1}^n x_i y_i}{\left(\sum_{i=1}^n x_i^2 \right)^{\frac{1}{2}} \left(\sum_{i=1}^n y_i^2 \right)^{\frac{1}{2}}} \right) \quad (9)$$

ここで、 x_i は画像ピクセルスペクトル、 y_i は参照ピクセルスペクトル、 n は画像のバンド数を表す。すなわち、画像ピクセルスペクトルを n 次元のベクトル $x_i = [x_1, x_2, \dots, x_n]$ 、参照ピク

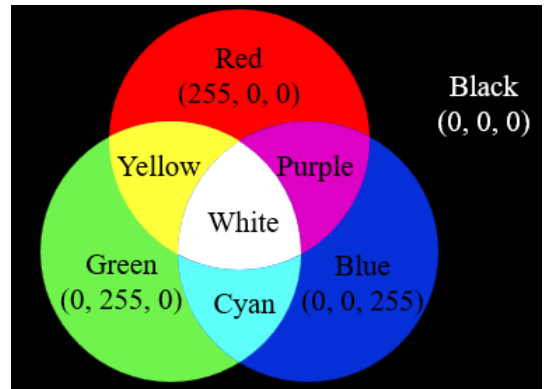


Fig3 Conceptual diagram of additive color mixture

セルスペクトルを n 次元のベクトル $y_i = [y_1, y_2, \dots, y_n]$ として計算を行う。画像ピクセルは、Eq. (9) によって計算された角度が最も小さいカテゴリに分類される。したがって、以下のような式で表すことができる。

$$x \in C_k \iff \theta(x, y_k) < \theta(x, y_j) \forall k \neq j \quad (10)$$

ここで、 C_k は土地被覆カテゴリ k 、 y_k はカテゴリ k のピクセルスペクトル、 y_j はカテゴリ j のピクセルスペクトルである。参照ピクセルのスペクトルは、画像から直接抽出することにより取得することが可能である (11)。

本研究では、以上に示した2つの機械学習手法を使用して、光学衛星画像の土地被覆分類を行った。その結果から、本研究において優位な手法となったSAMについて論ずる。SAMは、土地被覆分類を行うための計算に使用するパラメータが画像のバンド数を除けば画像のピクセルスペクトルだけであり、必要なパラメータ数が最尤法と比較して少ないため、計算処理速度が速い。また、作成した土地被覆分類の精度は、後述する判別効率表から総合精度として求めることができるが、SAMの分類精度は最尤法の分類精度よりも高くなった。以上の点を考慮し、本研究においては土地被覆分類手法としてSAMの方が優位であると判断し、SAMを用いて作成した土地被覆分類図を使用して、加色混合のプロセスへ進んだ。

3.2. 加色混合法

画像分析における加色混合法とは、画像の色を表現するRGB値を使用し、レッドスケール化ならびにシアンスケール化した二時期の画像を加算処理を行うことにより、画像変化を確認する手法である。画像で表現される色はRGB値と呼ばれ、(R, G, B)のように表記される (Fig. 3)(12)。このとき、R, G, Bには各色の明度の0~255の数値が記述される。RGB値において赤

色は (255, 0, 0), 緑色は (0, 255, 0), 青色は (0, 0, 255) と表される. また, 緑+青がシアン (0, 255, 255), 赤+緑が黄色 (255, 255, 0), 青+赤が紫 (255, 0, 255) となっている. 画像分析における加色混合では, 画像は二値化して分析に用いるが, 二時期の画像のうち一方を赤 (255, 0, 0) と黒 (0, 0, 0), もう一方をシアン (0, 255, 255) と黒 (0, 0, 0) に設定し, 加算処理を行う. 二時期の画像のうち前画像が「赤」と「黒」の2色で表され, 後画像が「シアン」と「黒」で表せている場合, 両画像を加算すると, Eq. (11) から Eq. (14) の4パターンが考えられる. 赤 (255, 0, 0) とシアン (0, 255, 255) の和 (これを加色という) は, Eq. (13) より (255, 255, 255), つまり白となる. 一方で, (0, 0, 0) で色が表現されるとき, その色は Eq. (14) に示すように黒で表示される.

前画像が赤, 後画像が黒の場合

$$(255, 0, 0) + (0, 0, 0) = (255, 0, 0) \quad (11)$$

前画像が黒, 後画像がシアンの場合

$$(0, 0, 0) + (0, 255, 255) = (0, 255, 255) \quad (12)$$

前画像が赤, 後画像がシアンの場合

$$(255, 0, 0) + (0, 255, 255) = (255, 255, 255) \quad (13)$$

前画像が黒, 後画像が黒の場合

$$(0, 0, 0) + (0, 0, 0) = (0, 0, 0) \quad (14)$$

一般的に, 加色混合の原理を用いた画像分析は, SAR 画像を対象としたものが多い. 飛田ら⁽¹³⁾は, 2004, 2005年のスマトラ沖地震に伴う隆起沈降域を把握するため, SAR 画像の後方散乱強度から地表面粗度の変化抽出手法を開発した. SAR 画像で加色混合を行う際は, SAR 画像の後方散乱強度の彩度を RGB 値で表し, 加算処理が行われる.

本研究では, SAR 画像ではなく, 光学衛星画像に対して加色混合法の適用を試みる. 土地被覆分類図中の特定カテゴリを示すピクセルのみを抽出し, 前述した二値化処理を施す. 同様の処理を災害前後の画像で実施し, それらに対して加算処理を行うことで加色混合の原理により災害前後での変化を確認することとした. 地物に変化がなければ白, 前図での赤が後図で黒になっているときは赤, 逆に前画像での黒が後画像でシアンになっているときはシアン, それ以外は黒で表現される.

4. 光学衛星画像を用いた被災箇所抽出

4.1. 教師つき分類を用いた土地被覆分類

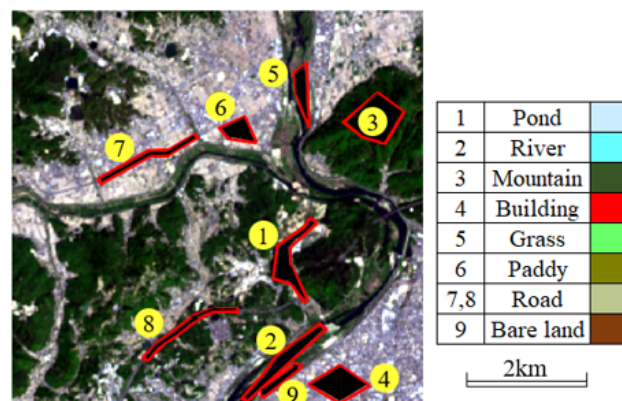


Fig.4 Training data of each category

4.1.1. 教師データ

教師付き分類を行うにあたり, 災害前と災害後の画像において Fig. 4 内の赤枠で示す箇所・範囲において教師データを設定する. Fig. 4 の右側に示す凡例の番号は, 図中の黄色丸印中の番号と対応している. 各教師データについては, まず衛星画像に対して目視で特定カテゴリを示す領域を赤枠で選定した. 赤枠で囲った箇所は, それぞれ便宜的にナンバリングを行い (Fig. 4 の黄色丸印中の番号), 各番号に対応した領域のカテゴリを示す色を設定 (Fig. 4 の右側の凡例) することにより, 教師データとして作成した. 例えば, Fig. 4 の図中で池 (Pond) がある箇所を選定し (黄色丸印1), 池を示す色として薄水色を決定する (Fig. 4 の凡例番号1). 以上の作業を, 河川, 山 (植生), 建物 (都市), 草地, 田畑, 道路のカテゴリに対しても行い, 合計9つのカテゴリの教師データを作成した. それぞれのカテゴリについて, 河川は水色, 山 (植生) は深緑色, 建物 (都市) は赤色, 草地は黄緑色, 田畑はオリーブ色, 道路は薄茶色, 裸地は茶色とし, 色で土地被覆が判別しやすいよう設定した. 教師データの領域に関しては, 地物を適切に表現している箇所を選択し, 教師データの個数に関しては地物を表す最低限の個数で設定した. 土地被覆分類の結果により, 特定の地物において誤分類が目立つ場合は, 適宜教師データを追加する. ここで, 教師データを追加しすぎると, 追加したカテゴリへ分類が偏りがちになることに留意する.

4.1.2. 災害前の土地被覆分類結果

災害前の衛星画像 (Fig. 1 左) において, 土地被覆分類を行った結果を Fig. 5 に示す. まず, 使用した衛星画像 (Fig. 1 左) と土地被覆分類結果を目視判読を行った. 真備町北部はため池が点在しており, 土地被覆分類の結果, ため池の箇所は水色が着色されていることから, 教師データとして設定した高梁川や柳井原貯水池以外の河川やため池も水域として分類することが可能となっている. このことから, 衛星画像において目視だけでは判断しづ

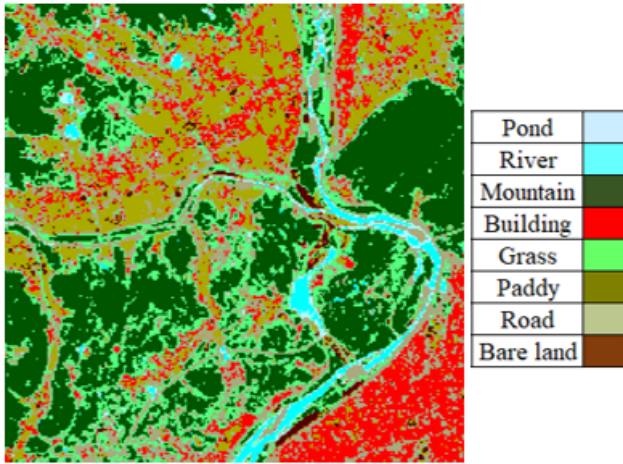


Fig.5 Result of land cover classification(Before the disaster)

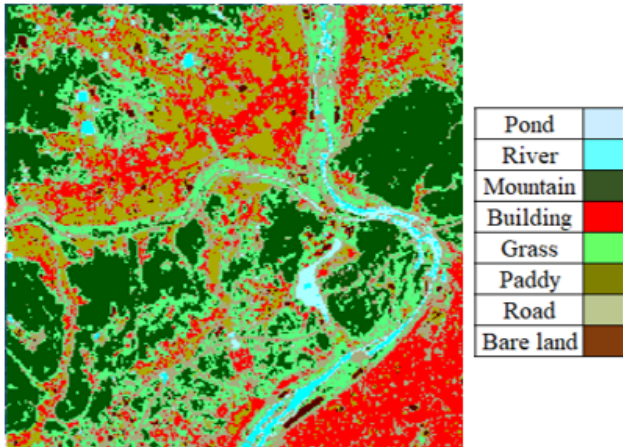


Fig.6 Result of land cover classification(After the disaster)

らい箇所も分類が行われていることが分かる。また、住居などが密集する市街地は屋根の反射によって、衛星画像内ではグレーに近い色で確認することができ、その箇所に関しては建物域を示す赤色が着色されている。加えて、衛星画像内の市街地において肌色で確認することができる田畑についても、建物との色分けがなされており、両者の違いによる分類は可能となっている。しかし、市街地中の建物と道路の違いに関しては、解像度の観点から土地被覆を分類するのは困難である。今回、道路の教師データとして、衛星画像中央あたりを東西に向けてのびる幹線道路と真備町市街地を東西に走る国道を採用した。土地被覆分類の結果、四車線ある幹線道路は正しく分類できたものの、二車線しかない国道は建物や田畑に誤分類された。このことから、解像度 30m の衛星画像では二車線の道路の判別までは困難であることが示された。誤分類の原因として、低解像度の衛星画像では 1 ピクセルに

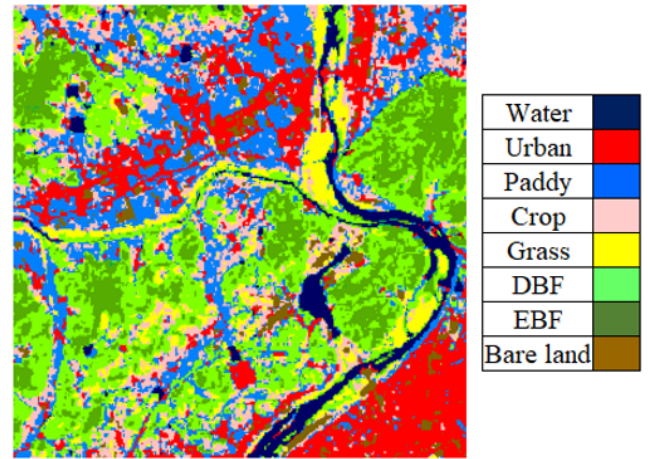


Fig.7 Reference of land cover classification

複数の地物が含まれてしまうということが挙げられる。そのピクセル全体のスペクトルは、含まれる地物の平均を取るようになるため、特定の地物のみを示す値とは言い難い。実用化を図るためには、高解像度の衛星画像を使用し、1 ピクセルに含まれる地物を 1 つに近づけることが望ましい。

4.1.3. 災害後の土地被覆分類結果

前項と同様に、災害後の衛星画像について土地被覆分類を行い、使用した衛星画像 (Fig. 1 右) との目視判読を行った。災害後の衛星画像 (Fig. 1 右) において、土地被覆分類を行った結果を Fig. 6 に示す。市街地における建物と田畑、道路に関しては、建物と田畑の分類は可能であるが、災害前と同様、建物と解像度以下の道路の分類は困難である。水域についても、災害前と同様の理由により、目視では判読が困難な箇所の土地被覆分類も行うことが可能となっている。植生に関しては、植生が存在しない箇所に植生が分類されてはいないことから、Fig. 1 右の土地被覆を概ね適切に分類できている。しかし、高梁川と小田川の合流地点の河川敷に着目し、Fig. 5 と Fig. 6 を比較すると、災害前では草地という土地被覆であった箇所が災害後では、山として分類されている。撮影された季節に大幅な違いがないにもかかわらず、このような結果になっている原因として、植生の分布が異なっていた可能性が考えられる。該当箇所を Fig. 1 左で確認すると植生が少なく、裸地に近い状態として確認できるが、Fig. 1 右は植生が生い茂り、青々としているため、このような結果になったと考えられる。以上のことから、災害前・災害後どちらの画像も解像度以下の道路のような地物の分類は困難ではあるが、どのカテゴリにおいても衛星画像の土地被覆を概ね適切に分類できると言える。

4.1.4. 土地被覆分類の精度検証

本研究で作成した土地被覆分類図は、目視判読に加え、参照データを基にピクセルごとに RGB 値の比較を行い、精度検証を

Table1 Confusion matrix for SAM classification result

		Results						
		Water	Urban	Grass	Vegetation	Paddy,Bare Land	Total	PA(%)
Reference	Water	10010	62	508	140	3408	14128	70.9
	Urban	169	38252	409	64	18670	57564	66.5
	Grass	21	953	12753	1488	6597	23812	62.0
	Vegetation	664	330	25709	77419	10797	114919	67.4
	Paddy,Bare Land	0	18479	18597	1505	80088	118669	67.5
Total		10864	58076	59976	80616	119560	329092	
UA(%)		92.1	65.9	24.6	96.0	67.0		

行った。精度検証に使用した画像（参照データ）は、国立研究開発法人宇宙航空研究開発機構（JAXA）が提供している高解像度土地利用土地被覆図を使用した（Fig. 7）。JAXAの土地被覆図は、本研究でも使用した衛星画像を撮影した人工衛星のLandsat8によって撮影された衛星画像を基に作成されている。精度検証の際には、参照データと検証データ（本研究の土地被覆分類結果）のカテゴリ数を合わせる必要がある。ここでのカテゴリ数とは、土地被覆分類を行う際に設定した地物の数のことである。特に、参照データについては、植生においては常緑広葉樹・落葉広葉樹に分かれており、水田と畑についても分けて土地被覆分類を行っている。災害での被災状況を把握するには、建物とそれ以外の地物の変化に主に着目するため、植生や水田と畑はそれぞれ一括りとして、精度検証を行う。例えば、参照データにおける常緑広葉樹と落葉広葉樹はまとめて山（植生）として、水田と畑はまとめて田畑として考える。一方で、検証データについても、池と河川、道路と裸地はまとめてそれぞれ水域、裸地というように設定する。この作業を行うことによって、参照データと検証データのカテゴリ数が同一となり、精度検証が容易になる。精度検証には、Table 1に示す判別効率表を作成し、全画素の何割が正しく分類されたかを表す精度評価指標である総合精度（Overall accuracy；OA）を算出することにより評価する。総合精度は、判別効率表内の総画素数を N 、判別効率表の (i, j) 成分を x_{ij} 、カテゴリ数を m としたとき、以下の式で表される⁽¹⁴⁾。

$$OA = \frac{1}{N} \sum_{i=1}^m x_{ii} \quad (15)$$

ここで、 x_{ii} は判別効率表対角成分、すなわちカテゴリ i において正しく分類された画素数である。

また、総合精度以外にも参照データの何割が正しく分類されて

いるかを表す精度評価指標の作成者精度（producer's accuracy；PA）、分類結果の何割が正しいかを表す指標の使用者精度（user's accuracy；UA）を以下の式により計算した。

$$PA_i = \frac{1}{x_{+i}} x_{ii} \quad (16)$$

$$UA_i = \frac{1}{x_{i+}} x_{ii} \quad (17)$$

ここで、 x_{+i} は参照データの総ピクセル数、すなわち i 列の要素の合計、 x_{i+} は検証データの総ピクセル数、すなわち i 行の要素の合計である。

Thomlinson らは総合精度である OA は最低 85% という基準を設けている⁽¹⁵⁾。85% という値は、Thomlinson らによる土地被覆分類の実用精度基準を示す数値である。Eq. (15) を用いて総合精度を算出した結果、本研究における土地被覆分類図の OA は 68% であり、基準値を大幅に下回る結果となった。Table 1 の草地（Grass）に着目すると、参照データで山（植生：Vegetation）となり検証データでは草地となったピクセル数が草地として正しく分類されたピクセル数（参照データ・検証データともに山（植生）よりも多くなっている。すなわち、草地における誤分類が顕著であることを示しており、カテゴリごとの精度を Eq. (16) や Eq. (17) で計算した際にも、PA は 60% を超えているが、草地全体での UA が低くなっている。草地の分類精度が低くなってしまった原因としては、「衛星画像の解像度の低さ」や「使用画像枚数の違い」が挙げられる。解像度の低さによって草地と山（植生）のピクセルスペクトルの違いが不明瞭となり、誤分類が多く発生したと考えられる。そのため、解像度の高い衛星画像を使用することで、ピクセルスペクトルの明瞭な違いが表現でき、誤分類が低減すると考えられる。また、参照データとして使用してい

る画像は、土地被覆分類の精度を向上させる目的で、多時期の衛星画像を使用して土地被覆カテゴリを決定している。そのため、一時期だけでは判別の難しい土地被覆（例えば、水張り時期でない水田と草地）を多時期の解析結果を使用することで最も適切な土地被覆分類を行っている。一方、本研究の土地被覆分類に使用した衛星画像は、特定時期に撮影された1枚の画像のみであるため、完全に土地被覆を分類できているとは言い難い。以上のことから、草地の分類精度が低下したと考えられ、草地のピクセルの誤分類は、結果的にOAの低下につながっている。橋本ら⁽¹⁶⁾は、PAとUAはトレードオフ、すなわちPAは高いがUAが低いケース（そのカテゴリを過剰に分類していて、誤分類が多い状態）やUAは高いがPAが低いケース（そのカテゴリを過少に分類していて、出した結果は正しいが未検出が多い状態）があり、クラス別の精度を評価する場合にはPAとUAの両方がバランスよく高くなっていなければならないとしている。精度向上を図るためには、ピクセルスペクトルのより明瞭な違いが表現でき、誤分類が低減すると思われる解像度の高い衛星画像を使用する必要があると言える。しかし、本研究の主眼は「被災箇所の抽出」であることから、低解像度であっても土地被覆の変化を確認可能かが重要である。Fig.5とFig.6の内、真備町の市街地を目視で比較すると、二時期で土地被覆が変化している（赤色が増加している）ことを確認できる。以上に示すような土地被覆分類の結果から2枚の画像間での変化は概ね抽出可能であると考え、以下に示す加色混合法によって土地被覆の変化を捉えることとした。

4.2. 加色混合による画像分析結果

前述したように、衛星画像に対して加色混合法を用いるにあたり、特定カテゴリを示すピクセルを適宜抽出し、二値化処理を施したのち、加算処理を行った。加算処理を行い、白色に変化した部分は災害前後で変化がなかった箇所であるため、黒色に変換する。本論文では、加色混合により最も特徴的であった以下の2つのカテゴリについて示す。

4.2.1. 建物域

まず、建物域について、災害前の画像（Fig.5）と災害後の画像（Fig.6）に対して、加色混合法を行った結果をFig.8に示す。Fig.8の対象地域全域は、赤のピクセルがシアン色のピクセルと比較して、数多く分布していることが分かり、これは何らかの理由で二時期の間に建物の多くが消失していることを表している。この変化は、分析を行う前の衛星画像を目視しただけでは判読が難しく、カテゴリごとに加色混合を行うことで明らかとなった事象であると言える。特に、実際の浸水被害を受けた真備町に着目すると、前述したように赤のピクセルが特に多くなっている。真備町において建物数の減少による変化を表す赤色ピクセルが分布し

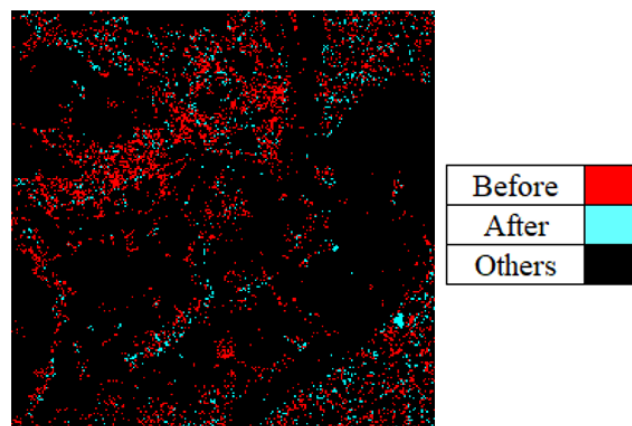


Fig8 Result of additive mixed(Urban area)

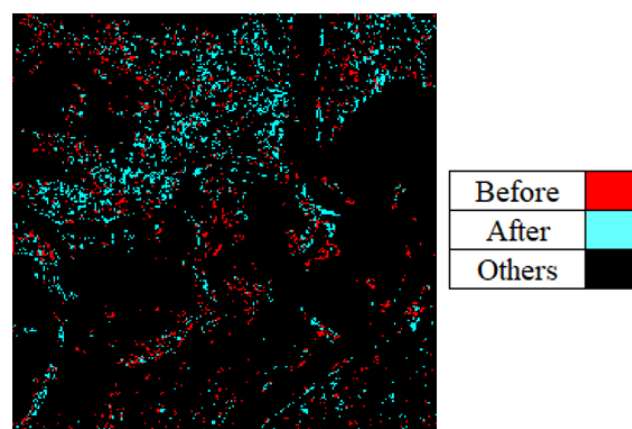


Fig9 Result of additive mixed(Field area)

ている箇所は、浸水が発生した小田川付近の平野部分に集中しており、国土地理院が提供する浸水推定図と比較すると、豪雨による浸水域と合致している。このことから、真備町における建物数の減少による変化は、大部分が災害によるものとして考えることができ、本研究手法によって被災箇所を概ね適切に抽出できていると言える。ここで注意すべきは、建物が存在していた箇所の住人が被災し別の土地へ移り住んだことによって更地になっている、被災した土地に新しい建物を建設中である、建物は残存しているが屋根などに土砂が残ったままである、など建物と判定されない要因が含まれているということである。一方で、豪雨災害の被害を直接受けていない真備町以外の土地（倉敷市や総社市）においても、真備町までとはいかずとも赤やシアン色のピクセルが見られる。これらの箇所による建物の増減は、災害と直接関係ないものがほとんどであると考えられるため、こうした災害と直接関係のない箇所の土地被覆変化を見極めることも重要になってくる。

4.2.2. 田畑域

また、建物域と同様に、田畑域の災害前の画像 (Fig. 5) と災害後の画像 (Fig. 6) に対して、加色混合法を用いた結果を Fig. 9 に示す。Fig. 9 の画像全体は、前述した建物域と比較するとシアンのピクセルが多いことから、何らかの理由で二時期の間に田畑と分類された地物が多くなっていることを表している。建物域と同様に、真備町の市街地においてはその特徴が顕著であり、豪雨によって浸水した小田川付近の平野にシアンのピクセルが多くなっている。建物域と比較すると、豪雨災害によって被災した建物を取り壊しや修復中などにより土地被覆分類で建物と認識されず、田畑として認識されているため、このような結果になっていると考えられる。このことから、真備町の田畑が増加したことを表すシアンのピクセルが多い理由も災害によるものが大部分を占めると考えることができる。田畑域の加色混合結果により、建物であった箇所が田畑として認識されることが確認された。すなわち、田畑域の加色混合結果は、真備町において災害により建物が減少していることを裏付けることができ、被災箇所抽出の手助けとすることができる。

4.2.3. 分析結果からの考察

以上に示す土地被覆分類からの加色混合の結果は、災害後に建物が被災により減少し、土地被覆が変化したことを視覚的に表現することができている。すなわち、建物域と田畑域の土地被覆変化の関係性から被災箇所を簡易的に抽出することが可能になったと言える。しかし、本研究で使用した光学衛星画像は、前述したように撮影頻度や季節の観点から災害から約1年が経過した画像を使用している。そのため、被災箇所において浸水した箇所の水はすでに引いてしまった状態である。発災直後に衛星画像を即座に取得することが可能であるならば、本研究の手法を適用した場合、「水域」のカテゴリに関して加色混合の結果はシアンのピクセルが被災箇所でも多く散見されることになると考えられる。その際は、建物域と水域との関係性から被災箇所の抽出を行うことになる。

5. 結言

本研究では、豪雨災害により被災した箇所を抽出するため、機械学習と画像処理技術を組み合わせて被災箇所の抽出を行った。被災箇所を抽出するにあたり、機械学習を用いて土地被覆分類を行い、分類図に対して加色混合法を適用し、加算処理を行った。

土地被覆分類では、教師データとして分類するカテゴリを、河川、建物というように土地用途に合わせて設定した。衛星画像の解像度が30mであることから、建物や田畑が密集する市街地や河川・植生などの解像度以上の領域を持つ場合は適切なカテゴリ

に分類されるが、二車線の道路のような解像度を下回る領域を持つ場合は分類が適切に行われていない箇所があった。このことから、機械学習による土地被覆分類では、解像度30mであっても概ね土地被覆分類は可能であるが、衛星画像の解像度を下回る大きさの地物は適切な分類を行うのは困難であることが分かった。金田らの研究⁽¹⁷⁾では、浸水被害把握を行うにあたり、光学画像で解像度0.5~1.5mのものを使用している。この程度の解像度であれば二車線の道路だけでなく、建物や水域に関してより正確な判読が可能となるため、土地被覆分類の精度向上に繋がると考えられる。

さらに、加色混合法を用いることで、災害前から災害後にかけて増加したカテゴリ、減少したカテゴリ、変化のないカテゴリを各ピクセルの色によって視覚的に判断することが可能となった。被災地域においては建物域の加色混合結果より、建物は減少していると分かり、一方で、田畑域の加色混合結果より、田畑が増加していると分かる。これらを照らし合わせることで、建物が被災し、田畑という別のカテゴリとして認識されていると判断できる。以上のことから、土地被覆分類と加色混合法を組み合わせることで、カテゴリの二時期における変化から被災箇所の抽出が可能になると示された。

本研究は、発災直後の被災箇所抽出の基礎的研究として位置づけ、実用化のためには前述した課題に留意する必要がある。今後は、その課題への対策の一例として土地被覆分類の精度や加色混合の信頼性を向上させる目的で、解像度の高い衛星画像を用いて本研究手法の実用化に向けた検討を行う。

参考文献

- (1) 国土交通省：【本文】大規模広域豪雨を踏まえた水災害対策のあり方について、「大規模広域豪雨を踏まえた水災害のあり方について」答申(平成30年12月)、https://www.mlit.go.jp/river/shinngikai_blog/shaseishin/kasembunkakai/shouinikai/daikibokouikigou/pdf/daikibokouikigou_toushin_honbun.pdf, (2021年9月30日閲覧可)
- (2) 金城海輝, 白水元, 朝位孝二: SAR画像を用いた岡山県真備町の浸水状況解析, 自然災害研究協議会 中国地区都会研究論文集(2019), 5, pp. 31-34.
- (3) 本田謙一, 泉祐輔, 引地慶多, 虫明成生, 浅田典親, 津野浩一: 衛星SARを用いた豪災害時の迅速な浸水範囲および浸水深抽出の試み 日本リモートセンシング学会誌(2019), 40, 3, pp. 158-162.
- (4) 作野裕司: 西日本豪雨災害時における Landsat-8 と

- Sentinel-1 を使った新水域の推定, 日本リモートセンシング学会誌 (2018), **3**, **5**, pp. 435-437.
- (5) 洲濱智幸, 福島雄也, 石垣昭寿, 古藤智行, 早川智洋: Airbus DS 社および MDA 社による平成 30 年 7 月豪雨災害の観測対応, 日本リモートセンシング学会誌 (2018), **38**, **5**, pp. 431-434.
- (6) 岩田敏彰: 7. 産総研が提供する衛星データプラットフォーム LandBrowser, 写真観測とリモートセンシング (2019), **58**, **6**, pp. 292-295.
- (7) Shafri, H.Z.M., Suhaili, A., Mansor, S.: The performance of maximum likelihood, spectral angle mapper, neural network and decision tree classifiers in hyperspectral image analysis, J. Comput Sci.(2007), **3**, pp. 419-423.
- (8) 石田晴海, 稲村實: 多重分光画像データを利用する土地被覆カテゴリー分類法の分類傾向解析, 日本リモートセンシング学会誌 (2003), **23**, **2**, pp. 126-136.
- (9) Kruse, F.A., A.B Lefkoff, J.W. Boardman, K.B Heide-brechth, A.T. Shapiro, J.P. Barllom and A.F. Goetz. : The spectral image processing system (SIPS)-Interactive visualization and analysis of imaging spectrometer data., Remote Sensing of environment(1993), **44**, pp. 145-163.
- (10) De Carvalho, O.A. and Meneses, P. R. : Spectral Correlation Mapper (SCM); An Improvement on the Spectral Angle Mapper (SAM) Summaries of the 9th JPL Airborne Earth Science Work-shop(2000), pp. 9p.
- (11) Girouard,G., Bannari, A., El Harti, A. and Desrochers, A. : Validated Spectral Angle Mapper Algorithm for Geological Mapping: Comparative Study between Quickbird and Landsat-TM, Geo-Imagery Briding Continents Istanbul, Turke(2004), pp. 599-604.
- (12) 松尾芳雄: 景観シミュレーションの基礎と応用 (その 2), 農業土木学会誌 (2000), **68**, **9**, pp. 973-974.
- (13) 飛田幹男, 今給黎哲郎, 水藤尚, 加藤敏, 林文, 村上亮: 衛星 SAR 画像分析による 2004・2005 年スマトラ沖地震に伴う隆起沈降域の把握, 国土地理院時報, 農業土木学会誌 (2006), **109**, pp. 21-32.
- (14) 児島利治, 宝馨, 岡太郎: リモートセンシングの分解能が土地被覆分類精度に及ぼす影響, 京都大学防災研究所年報 (1996), **39**, **B-2**, pp. 1445-458.
- (15) Thomlinson, J. R., V Bolstad, P. and Cohen, W. B.: Co-ordinating Methodologies for Scaling Landcover Classifications from Site-Specific to Global, Remote Sensing of Environment(1999), **70**, **1**, pp. 16-28.
- (16) 橋本秀太郎, 田殿武雄, 小野里雅彦, 堀雅裕, 塩見慶: 多時期光学観測データを用いた高解像度土地被覆分類手法の開発, 日本リモートセンシング学会誌 (2014), **34**, **2**, pp. 102-112.
- (17) 金田真一, カピララトナ ジーワンティニー: 光学衛星画像を用いた災害時における浸水被害調査法についての検討, 日本リモートセンシング学会誌 (2020), **40**, **3**, pp. 163-166.