

ハイパースペクトル画像を用いた土壌の走破性の判定

山内 統広† 筑紫 彰太† 田村 雄介† 山川 博司† 永谷 圭司† 藤井 浩光‡
坂井 郁也§ 千葉 拓史§ 山本 新吾§ 茶山 和博§ 山下 淳† 浅間 一†

† 東京大学大学院 工学系研究科 精密工学専攻
‡ 千葉工業大学 先進工学部 未来ロボティクス学科
§ 株式会社フジタ

E-mail: yamauchi@robot.t.u-tokyo.ac.jp

1 序論

現在、日本では土砂災害が多発している。土砂災害の発生後にさらなる被害の拡大を阻止するためには迅速な復旧工事が必要であり、迅速な復旧工事のためには、建設機械を使用する必要がある。土砂災害の現場で建設機械を活用するためには、最初に、現場での建設機械の走破性を素早く調査する必要がある。走破性の調査については、走破性の指標の1つであるコーン指数を測定して行うことが多い [1]。しかし、災害現場では、二次災害の危険性が存在し、現場に人が立ち入ることは難しいため、無人で走破性を調査することが望ましい。無人で走破性を調査する先行研究には、無人地上車両 (UGV) にコーン指数を測定する機器を搭載して遠隔操作した研究がある [2] [3]。しかし、この手法では、走破性の調査に多くの時間が必要となるだけでなく、さらに、UGV が進入できない場所の調査は不可能である。従って、この手法では適用可能な土砂災害が限定されてしまう可能性が大きい。一方、画像を使用して走破性を判定することが可能となれば、短時間での判定が可能となるだけでなく、さらに UGV や人の進入が困難な場所の走破性についても、その外側から撮影した画像さえあれば判定が可能となる。画像を使用して走破性を判定する先行研究には、可視近赤外、短波長赤外、長波長赤外の波長を撮影出来るカメラを使用した研究がある [4] [5]。しかし、これらの先行研究では、含水比と走破性の関係にのみ注目しており、走破性に影響すると考えられる土壌の種類には、注目していない。

そこで、本研究では、画像から土壌の種類と含水比の推定の双方を行うことによって、土壌の走破性を判定することを目的とする。なお、一般的な RGB 画像では土壌の種類と含水比の推定を同時に行うことが不可能であると考えられるので、ハイパースペクトル画像を使用することとした。ハイパースペクトル画像の分類には、最尤推定法や多変量解析

が使用されることが多い。しかし、ニューラルネットワークの方が、学習データやラベルの定義に左右されにくく [6]、重要な特徴量を自動で探索できることが知られている [7]。そこで、本研究では、ニューラルネットワークを利用し、土壌のハイパースペクトル画像を分類することとした。本稿では、土壌の走破性を判定する手法を提案すると共に、複数の土壌を用いて実施した走破性判定試験について述べる。

2 提案手法

本章では、土壌の種類と含水比の推定によって、土壌の走破性を判定する提案手法について説明する。

2.1 土壌の走破性判定の流れ

含水比とは、土壌の土粒子の質量に対する、土壌に含まれている水の質量の比である。また、粒度分布とは、土粒子の直径とその直径までの土粒子の累積質量百分率の関係を表す分布である。そして、建設機械の走破性は、その土壌の含水比、粒度分布、鉱物組成に依存する。従って、粒度分布と鉱物組成が同じである土壌を同じ種類の土壌であると定義すると、土壌の種類と含水比が分かれば土壌の走破性を判定することが可能となる。そこで、土壌の種類と含水比の推定を画像から行うことで走破性を判定する。本研究では、分光反射率に注目する。分光反射率とは、光源から放射された光のエネルギーの内、物質が反射する光のエネルギーの割合である。分光反射率は物質により異なる。また、水は特定の波長の光を吸収するためその波長における分光反射率は水の量に比例する。従って、分光反射率を用いて土壌の種類と含水比の推定の両方が可能である。そこで、本研究では、分光反射率を取得できるハイパースペクトル画像を使用する。ハイパースペクトル画像とは、対象物からの反射光を多くの波長に分光させ、それぞれの波長の強度を面で観測した画像である [8]。土壌の分類と含水比の推定手法の詳細な説明については、それぞれ 2.2 節、2.3 節で行う。

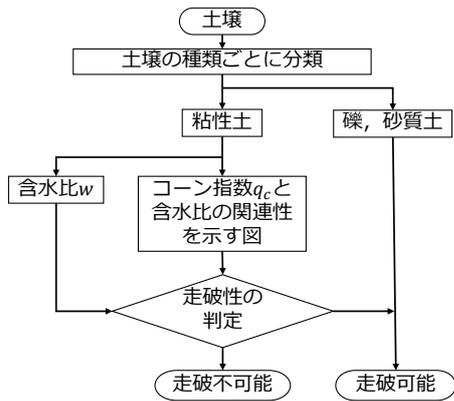


図 1: 走破性判定のフローチャート

また、土壌を大まかに礫、砂質土、粘性土の3つのグループに分類した場合、礫と砂質土は、含水比に関わらず建設機械が走破可能であることが知られている [9]。そこで、まず土壌の種類を判別し、そのあとに判別した土壌の種類が礫と砂質土に分類される場合は、走破可能であると判定し、粘性土に分類される場合のみ含水比の推定も行って走破性を判定することとする。この場合、土壌の種類が判明すれば、コーン指数と含水比の関連性が一意に定まるため、その関連性と推定した含水比から、おおよそのコーン指数が算出出来る。最終的にこのコーン指数を用いて、粘性土に分類された土壌の走破性を判定する。上述の走破性の判定のフローチャートを図 1 に示す。

2.2 土壌の種類判別

本研究では、ハイパースペクトル画像をニューラルネットワークを用いて分類することによって土壌の種類を判別する。本研究で使用するニューラルネットワークの概要を、図 2 に示す。一般的な RGB 画像が R, G, B の 3 波長なのに対して、ハイパースペクトル画像は多くの波長を取得出来るため、1 ピクセルごとに物体の分光反射率のスペクトルを取得することが可能となる。本研究では、土壌の分光反射率に注目しているため、1 ピクセルごとにニューラルネットワークに学習させることとする。また、照度が激しく変動した場合、土壌の分光反射率に大きく影響するため、照度変化のない条件でハイパースペクトル画像の撮影を行うこととする。

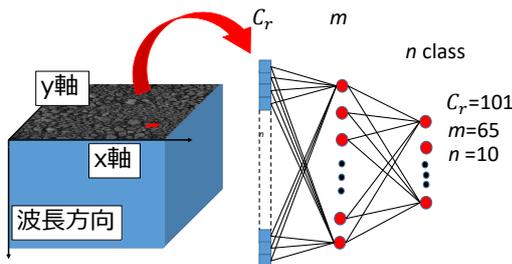


図 2: ニューラルネットワーク

2.3 含水比の推定

水は 1450nm 周辺の波長の光を吸収する。よって、1450nm における分光反射率のスペクトルの勾配の度合いを示す一次微分値から水の量が推定可能である。また、1440nm と 1460nm の分光反射率の差を 2 つの波長の差である 20nm で割ることによって、1450nm における分光反射率のスペクトルの一次微分値を近似的に計算することが出来る。従って、1440nm と 1460nm のスペクトル強度の差を 2 つの波長の差である 20nm で割った値を近似式に代入することで含水比を推定することとした。

2.4 走破性判定のためのコーン指数算出

コーン指数と含水比の関連性は、含水比を変えていった場合のコーン指数の値を記録することで得ることが出来る。また、コーン指数と含水比の関連性は、土壌の種類ごとに一意に決まっている。従って、任意の種類 of 土壌に対してコーン指数を算出するためには、まず土壌の種類ごとに、含水比を変えていった場合の、含水比とコーン指数の値の組み合わせを事前に調査した後、推定された含水比が事前に記録された含水比の内、どの 2 つの値の間に位置するかを確認する。最後に、その事前に記録された 2 つの含水比に対応するコーン指数から、内分を用いてコーン指数を算出する。

3 実験

本章では、具体的な実験方法と実験結果について説明する。

3.1 実験方法

3.1.1 ハイパースペクトル画像とその撮影方法

本研究で使用したハイパースペクトル画像の撮影に使用したハイパースペクトルカメラは、株式会社エバ・ジャパンが製造している NH-7 である。NH-7 が取得できるスペクトルの範囲は、350nm から 1100nm である。ただし、センサの感度の低い 350nm から 450nm、また 950nm から 1100nm の部分は使用しなかった。また、撮影時の照明としてハロゲンランプを使用した。ハロゲンランプを使用したのは、NH-7 を使用してハイパースペクトル画像を撮影するのに十分な照度を確保し、ハイパースペクトル画像を取得する波長全ての光を発生させることが出来るからである。本実験で使用したハイパースペクトル画像は、全国の異なる 10 カ所で採取された土壌の画像である。

本研究では、これらの土壌を土壌 A, B, C, D, E, F, G, H, I, J と呼称する。これらのハイパースペクトル画像の撮影時には、照度変化のない条件を達成するために、土壌の試料を入れたケースを屋内の暗室に設置して撮影した。ターゲットである土壌の試料はケースの

中に入れ、そのケースを3方向からハロゲンランプで照らして十分な明るさを確保し撮影を行った。実験の構成図を図3に示す。

3.1.2 ニューラルネットワークの学習・評価方法

本研究で使用するハイパースペクトル画像には、影が映りこんでいた。影が映りこんだハイパースペクトルの生画像を図4(a)に、影の部分と土壌の部分のスペクトルの違いを図4(b)に示す。図4(a)において、黄色と青の枠で囲まれた部分がそれぞれ影、土壌の部分を示しており、それぞれの部分内のスペクトルの平均を図4(b)内の黄色と青のスペクトルに示した。影の部分のピクセルを除外した。

3.2 実験結果

3.2.1 土壌の種類の判別結果

ニューラルネットワークによる土のハイパースペクトル画像の分類結果である混同行列を図5に示す。図5の混同行列は、横軸が予測結果を示し、縦軸が実際のカテゴリを示す。実際のカテゴリと予測結果が高い精度で一致したため、左上から右下にかけての対角線上にデータが集まりそこだけ青色になった。分類の精度は、学習データの精度が79.65%、テストデータの精度が81.57%となった。この結果から、ニューラルネットワークによって、10種類の土壌の分類に成功したことが分かった。

3.2.2 含水比の推定結果

10種類の土壌の内、粘性土である土壌A, B, D, F, Gの5種類において、含水比の推定試験を行った。具体的な手順としてまず、分光反射率のスペクトルから近似的に計算した一次微分の値と含水比の関連性に対して線形近似線、指数近似線を引いた。その結果を図6に示す。実際の一次微分の値と含水比の関連性を黒の実線、その線形近似線を黒の点線、指数近似線を赤の実線で示した。この結果から、近似線を引くが可能

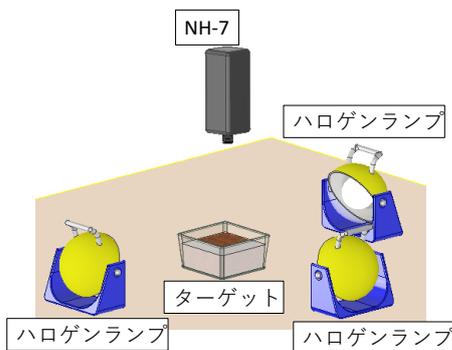


図3: 実験の構成図

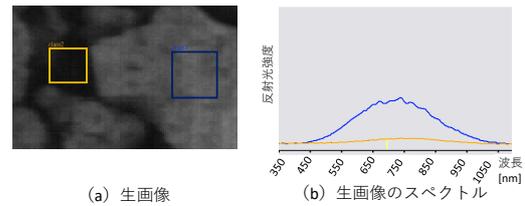


図4: (a) 影が映ったハイパースペクトルの生画像 (b) 影と土壌の部分の生画像のスペクトル

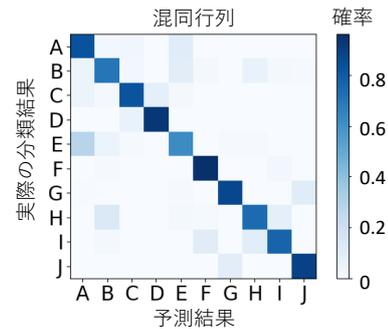


図5: 判別結果を示した混同行列

となるため、ハイパースペクトル画像から含水比の推定が可能であることが分かった。

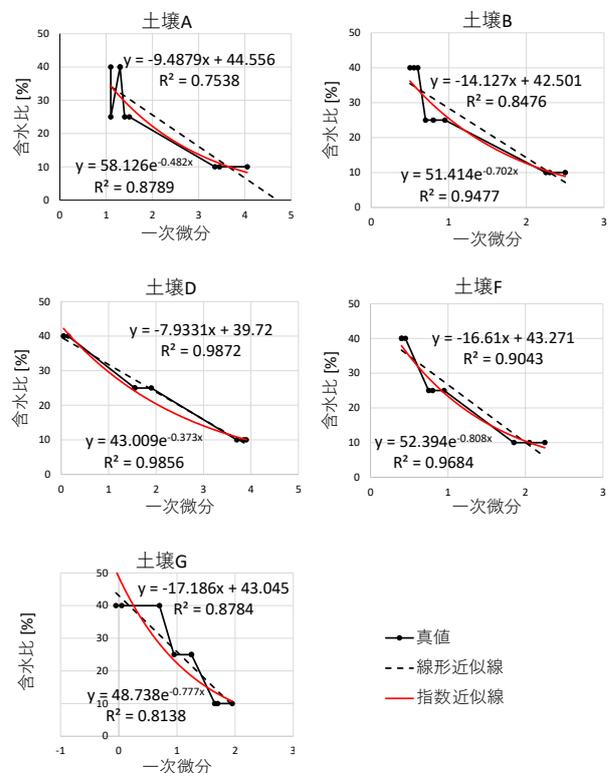


図6: 粘性土A, B, D, F, Gの吸光波長帯(1450nm)の一次微分値と含水比の関係及び近似線

3.2.3 走破性の判定

コーン指数と含水比の関連性は、土壌の種類ごとに一意に決まる。また、3.2.1 項と 3.2.2 項において、ハイパースペクトル画像からそれぞれ土壌の種類と含水比の推定が可能であることが分かった。従って、図 1 で示した走破性の判定のフローチャートを用いることによって、まず粘性土と礫・砂質土を分け、その後、粘性土のコーン指数を算出することによって、土壌の走破性を判定することが理論的には出来る。

4 結論

4.1 考察

ハイパースペクトル画像から土壌の種類と含水比の推定が可能であることが分かった。従って、本研究で示したフローチャートに従い、土壌の種類が判明すれば走破性の判定が理論上可能であると言える。また、3.2.1 項において高い精度で分類できた理由と、3.2.2 項において近似線を引くことが出来た理由として考えられる点は、屋内で撮影されたハイパースペクトル画像を使用した点である。屋内で撮影したため、土壌の種類と含水比の違い以外の条件を同じにすることが出来た。一方、屋外で撮影したハイパースペクトル画像は、大気や照度の条件が画像ごとに変化するために、うまく分光反射率を取り出すことが出来ないと予想される。これにより、屋内で撮影した画像を用いて学習した分類器や作成した含水比推定のための近似式では、屋外の画像には対応できないと考えられる。

4.2 今後の予定

本研究の最終的な目的は、土砂災害の発生現場における走破性の判定である。従って、本研究で考案したフローチャートが屋外で撮影したハイパースペクトル画像でも走破性を判定できるかどうか確認する必要がある。そこで、今後の予定として、まずは屋外において粘性土のハイパースペクトル画像の撮影と撮影地点のコーン指数、含水比の測定を行う。次に、その画像を用いて分類器と含水比推定の近似式を作成し、算出したコーン指数と実際のコーン指数を比較することによって、フローチャートの評価を行う。

謝辞

本研究の一部は、JSPS 科研費 JP18K13810 の支援を受けた。

参考文献

- [1] St. Joseph, "Soil Cone Penetrometer", Michigan, ASAE S313.3, Feb. 1999.
- [2] S. Chhaniyara, C. Brunskill, B. Yeomans, M. C. Matthews, C. Saaj, S. Ransom and L. Richter, "Terrain Trafficability Analysis and Soil Mechanical Property Identification for Planetary Rovers: A Survey", *Journal of Terramechanics*, vol. 49, pp. 115–128, Feb. 2012.
- [3] K. Zacny, J. Wilson, J. Craft, V. Asnani, H. Oravec, C. Creager, J. Johnson and T. Fong, "Robotic Lunar Geotechnical Tool", *Proceeding of the 2010 ASCE Earth and Space, Honolulu, HI*, Mar. 2010.
- [4] R. Fernández, H. Montes and C. Salinas, "VIS-NIR, SWIR and LWIR Imagery for Estimation of Ground Bearing Capacity", *Sensors*, pp. 13994–14015, Jun. 2015.
- [5] A. L. Rankin, and L. H. Matthies, "Passive Sensor Evaluation for Unmanned Ground Vehicle Mud Detection", *Journal of Field Robotics*, vol. 27, no. 4, pp. 473–490, Mar. 2010.
- [6] Justin D. Paola and Robert A. Schowengerdt, "A Detailed Comparison of Backpropagation Neural Network and Maximum-Likelihood Classifiers for Urban Land Use Classification", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 33, no. 4, pp. 981–996, Jul. 1995.
- [7] Wei Hu, Yangyu Huang, Li Wei, Fan Zhang and Hengchao Li, "Deep Convolutional Neural Networks for Hyperspectral Image Classification", *Journal of Sensors*, vol. 2015, pp. 1–12, Jan. 2015.
- [8] Naoto Yokoya and Akira Iwasaki, "Hyperspectral Image Processing for Advanced Earth Observation (〈 Special Issue 〉 AI Technology Advancing into Space)", *The Japan Society for Artificial Intelligence*, vol. 29, no. 4, pp. 357–365, Jul. 2014.
- [9] M. P. Meyer and S. J. Knight, "Trafficability of Soil Soils classification", U.S. Army Engineer Waterways Experiment Station Corps of Engineers, Vicksburg, Mississippi, Technical Memorandum no. 3-240, sixteenth supplement. pp. 1–182, Aug. 1961.