

## ハイパースペクトルカメラによる蛇紋岩の判別と含有アスベスト濃度の定量技術

## Development of Technique for Detecting Serpentinite and Asbestos Using Hyperspectral Camera

飛田 南斗      白鷺    卓      宮嶋 保幸  
 戸邊 勇人      升元 一彦      川村 洋平<sup>1)</sup>  
 安達 毅<sup>2)</sup>      大和田 済熙<sup>2)</sup>      不破 勢登<sup>2)</sup>

## 要 約

蛇紋岩は、葉片状や粘土状の場合に膨張性地山となり、また蛇紋石の一種であるクリソタイル（アスベスト）を含有する可能性があるため、山岳トンネル掘削工事における施工上要注意の岩種である。そのため、蛇紋岩の出現は早期に把握することが望ましいが、超長尺ボーリングで取得されるカッティングスから蛇紋岩・クリソタイルを検出するには、専門技術者の詳細な観察と分析が不可欠である。本研究では、特殊なカメラで撮影された画像を畳み込みニューラルネットワーク（CNN）により深層学習し、カッティングスの岩種判定とクリソタイルの検出を誰でも簡易に実施できる技術の開発を試みた。

見た目がよく似た4種のカッティングス（蛇紋岩、緑色岩、蛇紋岩と緑色岩の混合、緑色岩と玄武岩の混合）の画像を深層学習した結果、蛇紋岩と緑色岩を99.4%の確度で分類できるCNNモデル、全4種のカッティングスを73.1%で分類できるCNNモデルを作成できた。また、クリソタイルをほとんど含まない蛇紋岩とクリソタイル鉱物標本の画像とを深層学習した結果、両者をほぼ100%分類できるCNNモデルの作成に成功した。本研究で開発したCNNモデルにより、蛇紋岩か疑わしいカッティングスが出現した場合、カメラの撮影のみで現場において迅速に蛇紋岩およびクリソタイルを検知できるため、蛇紋岩を含む地山における掘削工事の合理化と安全性の向上に貢献できると考えている。

## 目 次

- I. はじめに
- II. 実験方法・手順
- III. 実験結果
- IV. 考 察
- V. おわりに

## I. はじめに

山岳トンネル掘削工事において切羽前方の岩種を事前に把握することは、蛇紋岩のように要注意とされる岩種の出現が予測される場合において特に重要である。切羽トラブルを未然に防ぐためのトンネル施工最適化を目的として、従来は先進コアボーリングや不完全ながらもコアを取得する工法が適用されてきたが、最近、さらに早く要注意岩種の出現有無やその位置を把握することができる1000m級のボーリング工法が適用されている。しかしながら、粒径数mm～数十

mm程度のカッティングスのみしか取得できないため、岩種を正しく判定するにはX線回折測定や地質専門家の判断が必要であり、施工へのフィードバックが難しい。

本研究では、蛇紋岩が出現する地山で実施した1000m級ボーリングで取得されたカッティングスを対象とした。蛇紋岩は葉片状や粘土状の場合に膨張性を発するだけでなく、蛇紋石の一種であるクリソタイル（アスベスト）を含有する場合には換気などの特殊な対策を講じる必要がある。そのため、蛇紋岩は山岳トンネル掘削工事における施工上要注意の岩種であり、その出現と分布はできるだけ早期に把握しなければならない。しかしながら、カッティングスの岩種判定から蛇紋岩の出現位置を予測し、さらにクリソタイルの有無を調べるには、専門技術者の詳細な観察と分析が不可欠であり、コストも時間もかかる。

Sinaice *et al.*(2017)<sup>1)</sup>は、ハイパースペクトル（以下、HS）カメラで撮影されたHSイメージと畳み込みニューラルネ

1) 北海道大学 Hokkaido University

2) 秋田大学 Akita University

**キーワード** : 蛇紋岩, アスベスト, カッティングス, ハイパースペクトルカメラ, 深層学習

**Keywords** : serpentinite, asbestos, cuttings, hyperspectral camera, deep learning

ットワーク（以下、CNN）を利用し、岩石の標本を対象とした岩種判定技術を開発した。この技術を先進ボーリングで取得したカッティングスに応用できれば、写真撮影だけで現場で簡単に蛇紋岩の出現位置およびクリソタイル発生の有無を推察できるため、施工へのフィードバックが容易になる。

本研究は蛇紋岩を含む地山における掘削工事の合理化と安全性の向上を目的とし、先進ボーリングのカッティングスから簡便に蛇紋岩およびクリソタイルを検知できる技術の開発を試みたので報告する。

## II. 実験方法・手順

### 1. 対象試料

(1) カッティングスの岩種判定に用いた試料

カッティングスにおける蛇紋岩の識別を目的として、緑色岩、蛇紋岩、玄武岩が混在して出現する地山のノンコアボーリングから取得された4種のカッティングス試料を用いた。いずれのカッティングス試料も粒径 5~20mm 程度であり、全てが暗緑色系を呈す (Photo 1) ため、地質専門家でも目視による判別が困難である。

試料の総数は 84 袋 (5m の削孔につき 1 袋を取得) であり、地質専門家の目視による判定では、緑色岩 100% (以下、“緑 100”と表記) のものが 78 袋、緑色岩 90%+玄武岩 10% (以下、“緑 90 玄 10”と表記) のものが 4 袋、緑色岩 90%+蛇紋岩 10% (以下、“緑 90 蛇 10”と表記) のものが 1 袋、蛇紋岩 100% (以下、“蛇 100”と表記) のものが 1 袋であった。

(2) 蛇紋岩中のクリソタイル検知に用いた試料

蛇紋岩中に含まれるクリソタイルの検知では、次の 4 試料

※写真一辺は約10cm




Photo 1 カッティングスの岩種判定に用いた試料 (Samples Employed for Rock-identification Technique of Cuttings)

※()内はクリソタイル濃度  
写真一辺は約5cm




Photo 2 蛇紋岩中のアスベストの検出に用いた試料 (Samples Employed for Detection Technique of Asbestos in Serpentinite)

を用いた (Photo 2) : 2-①クリソタイル繊維の鉱物標本, 2-②蛇紋岩を含む地山から取得された蛇紋岩カッティングス (粒径 5-20mm), 2-③クリソタイルを多量に含む蛇紋岩を粉砕したもの (粉末), 2-④2-②と同一地山で取得された蛇紋岩を粉砕したもの (粉末)。各試料におけるクリソタイルの重量濃度は、2-①100wt.%, 2-②0.05wt.% (同地域 10 試料の中央値), 2-③1.82wt.%, 2-④0.47wt.%である。このうち、試料 2-①と試料 2-②を用いて深層学習を行い、試料 2-③と試料 2-④を用いて作成した CNN モデルをテストした。

### 2. HS カメラによる撮影

HS カメラは、通常のデジタルカメラと異なり、x, y 方向の二次元の平面データに加え、100 以上に分光されたバンド帯を持つ波長データを取得可能な特殊なカメラである。このため、縦横の二次元平面に加えて波長方向への奥行を持つ三次元データが得られる。本研究で使用した Spectral Imaging 社の Specim IQ は、波長 400nm~1000nm (可視光領域から近赤外線領域の一部の波長まで) を 204 個の波長帯に分光することが可能である。

暗室において、撮影対象を 20cm 四方に広げ、光源むらを少なくするためのソフトボックス越しに、左右よりハロゲンライトで照らし撮影した (Photo 3)。ハロゲンライトは、使用した HS カメラの取得する波長帯域を一樣に照射することができる。クリソタイルを含む試料は、飛散防止のために透明な袋に入れ撮影を行ったが、HS への影響がないことは事前に確認した。光源の照度は撮影対象の位置で 3000-3500ルクスとなるように調整した。



Photo 3 HS カメラの撮影状況  
(Setting of HS Camera)

### 3. HS データの処理

HS データの前処理工程を Fig.1 に示す。得られた HS データは縦横それぞれ 512 ピクセル、奥行き 204 バンドのデータである。カッティングスの岩種判定では、このデータを縦横それぞれ 32 ピクセル（縦横それぞれ 16 等分）に、蛇紋岩中のアスベスト検知では縦横それぞれ 4 ピクセル（縦横それぞれ 128 等分）に分割した。その後、この分割されたデータの各バンドにおいて全ピクセル（ $32 \times 32 = 1024$  ピクセルまたは  $4 \times 4 = 16$  ピクセル）の平均をとり、縦横 1 ピクセル、奥行き 204 バンドのデータセットとした。この操作により、一度の撮影で得られる HS データは、カッティングスの岩種判定では 256 個、蛇紋岩中のアスベスト検知では 16384 個となる。各試料について撮影を三度ずつ実施し、カッティングスの岩種判定では 1 試料につき 768 個、蛇紋岩中のアスベスト検知では 1 試料につき計 49152 個の HS データを準備した。

### 4. 深層学習

#### (1) カッティングスの岩種判定のための深層学習

カッティングスの岩種判定では、緑 100 と蛇 100 の 2 種類の試料を分類するための学習と、緑 100、蛇 100、緑 90 玄 10、緑 90 蛇 10 の全 4 種類の試料を分類するための学習を行った。HS データとして、緑 100 は 59904 個、蛇 100 は 768 個、緑 90 玄 10 は 3072 個、緑 90 蛇 10 は 768 個のデータセットを用いた。学習では、各試料のデータが同数となるようデータ数が最小の試料に合わせ、緑 100 および緑 90 玄 10 からは無作為に 768 個を取り出した。学習条件はモデルの精度が高くなるよう調整を行い、学習データ、検証データ、テストデータをそれぞれ 8:1:1 に、ミニバッチサイズ<sup>\*1</sup>を 256 に、エポック数<sup>\*2</sup>を 200 に設定した。

#### (2) 蛇紋岩中のクリソタイル検知のための深層学習

試料 2-①の HS データを「クリソタイル」、試料 2-②の HS データを「蛇紋岩」とラベリングし、CNN による深層学習を行った。学習データ:検証データは 9:1 に設定し、エポック数

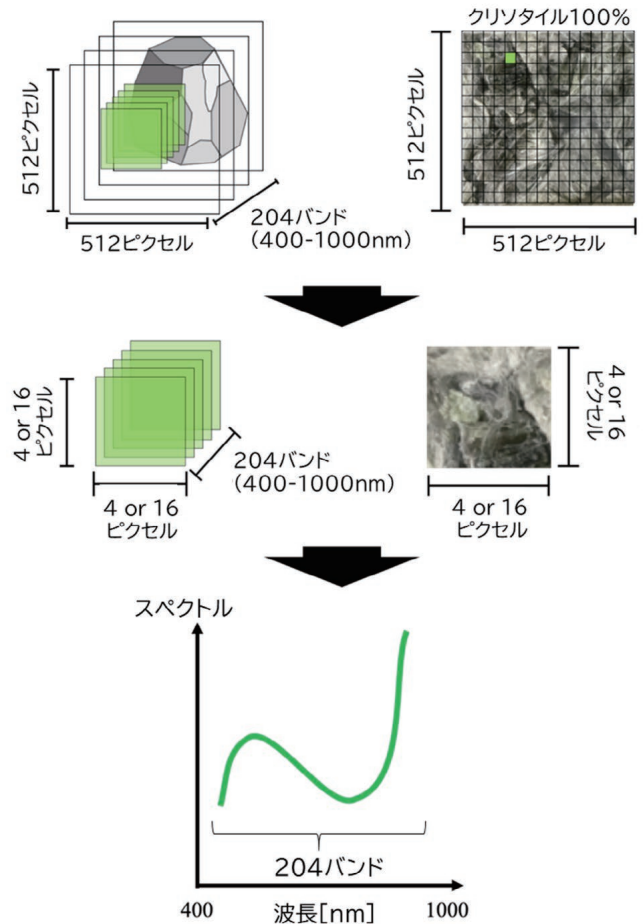


Fig.1 HS データの前処理方法  
(Data Processing of HS Data)

は 50 とした。

なお、実際には試料 2-②にもわずかにクリソタイルが含まれている。しかしながら、粉碎しておらず粒径が大きい試料 2-②中では、その多くが粒子内に存在すると推定される。そのため、撮影画像中にクリソタイルはほとんど出現せず、HS への影響は軽微と考えた。

作成した CNN モデルを検証するため、試料 2-③と試料 2-④について Fig.1 の処理で得られた HS データの一つずつを、「クリソタイル」または「蛇紋岩」で分類した。

<sup>\*1</sup> 同時学習させるデータサイズのこと。

<sup>\*2</sup> 一つの教師データを繰り返して学習させる回数。

## III. 実験結果

### 1. カッティングスの岩種判定

カッティングスの岩種判定に用いた各試料の HS データを Fig.2 に示す。HS データは試料ごとに平均をとり、最大値、最小値を用いて正規化したものである。これより、緑 100 と蛇 100 のスペクトル形状ではピークの位置に明瞭な違いがあること、蛇 100 と緑 90 蛇 10 のスペクトル形状、緑 90 玄 10 と緑 100 のスペクトル形状ではピークの位置がそれぞれ




Fig.2 カッティングスの岩種判定に用いた HS (The HS Employed for Rock-identification Technique of Cuttings)

よく一致していることが分かる。

緑 100 と蛇 100 を入力した CNN モデルについて、検証データに対しては 100%の正答率で分類することができたが、テストデータに対しては 99.40%となった (Table 1)。Table 2 にテストデータで予測した分類 (Output Class) を行、真の分類 (Target Class) を列に対応させた混同行列を示す。緑色岩であるものを蛇紋岩と分類してしまったものが 1 つ存在したが、それ以外の誤答はなく正答率の高い結果になった。

全 4 試料を入力した CNN モデルについて、検証データに対する精度は 77.27%，テストデータに対する正答率は 73.10%となった (Table 1)。Table 3 にテストデータで予測した分類 (Output Class) を行、真の分類 (Target Class) を列に対応させた混同行列を示す。これより、緑 100 の正答率が最も高く 87%であった。また、蛇 100 と緑 90 玄 10 はどちらも正答率が 70%を超える結果となった。最も低い正答率とな

Table 1 カッティングスの岩種判定の学習結果 (Result of CNN Models Employed for Rock-identification Technique of Cuttings)

正答率	検証	テスト
緑100 と蛇100を入力	100%	99.40%
全 4 試料を入力	77.27 %	73.10%

Table 2 緑 100 と蛇 100 の混同行列 (Confusion Matrix of Greenstone 100% and Serpentine 100%)

	緑色岩 (77)	蛇紋岩 (77)
緑色岩	98.7% (76)	0.0% (0)
蛇紋岩	1.3% (1)	100% (77)

※ ( ) 内はデータ数

Table 3 全 4 試料の混同行列 (Confusion Matrix of the Four Cuttings Samples)

	蛇 100	緑 100	緑90 蛇10	緑90 玄10
蛇 100	73%	0%	45%	0%
緑 100	0%	87%	0%	21%
緑90 蛇10	27%	12%	55%	1%
緑90 玄10	0%	1%	0%	78%

ったのは緑 90 蛇 10 で 55%であった。誤答は緑 100 と緑 90 玄 10 の組み合わせ、蛇 100 と緑 90 蛇 10 の組合せで多く、特に緑 90 蛇 10 を蛇 100 と誤判定した数が多かった。

## 2. 蛇紋岩中のクリソタイル検知

試料 2-①と試料 2-②について、代表的な反射光のスペクトルを示す (Fig.3)。530nm 以降の波長において、スペクトルのパターンに大きな違いがあることが確認できる。深層学習の結果、学習データ内と検証データに対する確度はいずれも 100%となり、試料が純粋なクリソタイルまたは蛇紋岩であれば、ほぼ確実に分類できる CNN モデルが作成できた。

この CNN モデルを用いて、試料 2-③と試料 2-④から Fig.1 の処理で得られた HS データの一つずつを判定した結果、試料 2-③は総数 3804 ピクセルの内 3804 ピクセル (100%) が、試料 2-④は総数 2209 ピクセルの内 125 ピクセル (5.7%) がクリソタイルと判定された。Fig.4 において、CNN モデルによる判定結果を横軸に、実際のクリソタイル含有量を縦軸にプロットした。クリソタイル含有量が多いほど、画像中でクリソタイルと判定されるピクセル数が多く、作成した

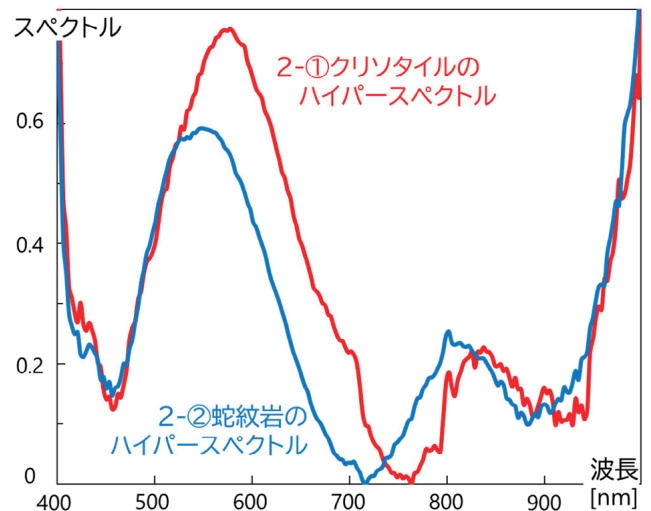


Fig.3 蛇紋岩中のクリソタイル検出に用いた HS (Samples Employed for Detection Technique of Asbestos in Serpentine)




Fig.4 CNNモデルによる判定とクリソタイル含有量 (Result of AI Classification and Actual Amount of Asbestos in Serpentine)

CNNモデルにより蛇紋岩天然試料中のクリソタイルを検知できることが確認できた。

#### IV. 考察

##### 1. カッティングスの岩種判定

緑100 と蛇100 の分類では誤答が1つのみとなり、ほとんどのテストデータを99.4%という高い正答率で分類することができた (Table 1)。これは緑100 と蛇100 のスペクトル形状における400~500nm 波長帯域で明瞭な差異があったため、その特徴を学習し正しく分類できたものと考えられる。

一方、4種類の試料の分類では、2種類の分類と比べ正答率が20%以上低下した (Table 1)。これは緑90 蛇10 と蛇100 の2試料のスペクトルが類似していたこと、緑90 蛇10, 緑100 の2試料もスペクトルの傾向が似ていたことが要因であると考えられる。特に、前者の2試料はピークの位置や高さがほとんど同じであるため、それぞれに固有な特徴を学習することが困難だった可能性が高い。地質技術者の目視で鑑定した緑90 蛇10を検証するために、得られた緑100 と蛇100 のスペクトルから緑色岩のスペクトルが9割、蛇紋岩のスペクトルが1割のスペクトル (緑90 蛇10 (偽)) を人為的に作成し比較したところ (Fig.5)、目視鑑定の緑90 蛇10のスペクトルとは一致せず、緑100のスペクトルとほぼ一致することが分かった。つまり、緑色岩と蛇紋岩が9:1の試料である場合には緑色岩とほぼ同じスペクトルを示すと考えられるが、緑90 蛇10の試料は蛇100に似たスペクトルを示したことから、目視鑑定が誤っており、緑90 蛇10には蛇紋岩の方が有意に多い可能性がある。したがって、混在試料の判定精度を向上させるためには、混在割合が明らかな試料を人為的に作成しそのスペクトルを学習データとすることが必要であると考えられる。

##### 2. 蛇紋岩中のクリソタイル検出




Fig.5 (偽) 緑90 蛇10 と他試料のスペクトル比較 (Calculated HS of 90% Greenstone + 10% Serpentine in Comparison with Other HS)

Fig.4において、試料2-③と試料2-④の結果に加え、グラフの原点を通過する回帰曲線を求めた。今後データを蓄積することで、HSカメラの撮影とAIによる判定だけでクリソタイル含有量を予測できる検量線が作成できると考えている。しかしながら、実際のクリソタイル含有量に対して、CNNモデルによるクリソタイル判定率は非常に大きかった (1.82wt.%に対して100%, 0.47wt.%に対して5.7%)。この理由としては、次の二点が考えられる：1) 繊維状鉱物のクリソタイルは、ほかの鉱物と比較して単位重量あたりの面積が大きいため、画像中でより大きな割合を占めている。2) 単位ピクセル中のクリソタイルが100%に達しない場合でも、CNNモデルはクリソタイルと判定している。

CNNモデルによる判定率 (%) が実際のクリソタイル含有量 (wt.%) を上回る場合、CNNモデルによる判定率100%と対応する含有量以上にクリソタイルが含まれる試料では定量分析が実施できなくなる。含有量が多い試料を定量分析するには、単位ピクセル中にどの程度クリソタイルが存在すればCNNモデルが「クリソタイル」と判定するかを調べ、「クリソタイル」と分類される閾値を調整すればよい。しかしながら、Fig.4の検量線のようにCNNモデルによる判定率が実際のクリソタイル含有量を大きく上回る場合には、わずかな含有量の違いでもCNNによる判定率が大きく変化するため、クリソタイル含有量が少ない試料への定量精度は高くなる。CNNモデルが「クリソタイル」と分類する閾値を調整することで、対象とする試料のクリソタイル含有量に適した定量分析が実施できるようになると考えている。

#### V. おわりに

HSカメラで撮影したHSの深層学習から、純粋な緑色岩または蛇紋岩から成るカッティングスであれば、99.40%の高確度で岩種判別を行えることが分かった。今回実施した撮影方法で適切なHSデータを取得し、今回の学習の結果得られ

たモデルを適用することで、地質専門家の判定を待たずにカッティングスから緑色岩と蛇紋岩を正しく判定できるため、蛇紋岩に対する施工の最適化に迅速にフィードバックできる。

一方、混在試料を含む4つのカッティングス試料の岩種判定では、2種類の分類と比べ正答率が20%以上低下した。これは、混在試料のラベリングが不正確であったためで、人為的に作成した混在試料のHSを学習することで正答率は大きく向上すると期待される。正答率が十分に向上するまでの現場での判断においては、蛇100のモデルスペクトルに近ければ「蛇紋岩を有意に含む」と安全側に判断し、蛇紋岩に対する施工の最適化にフィードバックできると考えている。

蛇紋岩中のアスベスト検知では、純粋な蛇紋岩とアスベストであればほぼ確実に分類できるCNNモデルを作成することに成功し、これを蛇紋岩に適用することでアスベスト含有量を定量できる可能性があることを示した。今後は、クリソタイト含有量が異なる蛇紋岩をCNNモデルで判定し、その結果を蓄積することで、Fig.4の検量線の精度を向上させていく。確度が十分に向上すれば専門業者の分析が不要となり、施工現場でもクリソタイト含有量が定量的に把握できるようになる。

本研究で開発した3つのCNNモデルにより、蛇紋岩の可

能性があるカッティングスが出現した場合、これまで時間とコストを要していた蛇紋岩の判別およびアスベストの検知をカメラの撮影のみで現場において迅速に実施できる。そのため、本技術は蛇紋岩を含む地山のトンネル施工合理化に大きく貢献できると考えている。

#### 参考文献

- 1) Sinaice, Brian et al.; Development of a differentiation and identification system for igneous rocks using hyper-spectral images and a convolutional neural network (CNN) system., Sapporo Journal of MMIJ, 2017.12, Vol. 4, No.2,.
- 2) 白鷺卓ほか; 先進ボーリングのカッティングスを利用したハイパースペクトルカメラによる切羽前方の岩種判定技術(その1), 令和2年度土木学会全国大会第75回年次学術講演会講演集, 2020.9, III-54
- 3) 上杉祥文ほか; 先進ボーリングのカッティングスを利用したハイパースペクトルカメラによる切羽前方の岩種判定技術(その2), 令和2年度土木学会全国大会第75回年次学術講演会講演集, 2020.9, III-55.

## Development of Technique for Detecting Serpentinite and Asbestos Using Hyperspectral Camera

*Minato Tobita, Suguru Shirasagi, Yasuyuki Miyajima, Hayato Tobe, Kazuhiko Masumoto, Youhei Kawamura<sup>1)</sup>, Tsuyoshi Adachi<sup>2)</sup>, Narihiro Owada<sup>2)</sup> and Narito Fuwa<sup>2)</sup>*

When excavating rock tunnels, careful attention must be paid to serpentinite because it can cause squeezing while tunnelling and may include chrysotile (asbestos). Thus, it is necessary to predict where and when serpentinite will appear as soon as possible during excavation. A long advancing boring from the working face gives helpful information not from rock cores but with cuttings, mixtures of small (~20 mm or smaller) fragments of multiple kinds of rocks. Detecting serpentinite and asbestos in cuttings requires detailed observation and analyses by experts, which is costly and time-consuming. In this study, we developed a technique based on a convolutional neural network (CNN) that enables anyone to easily detect serpentinite and asbestos in cuttings by only taking a picture with a special camera, a “hyperspectral (HS) camera.”

Deep learning of HS images of samples containing four kinds of visually similar cuttings (serpentinite, greenstone, a mixture of serpentine and greenstone, and a mixture of greenstone and basalt) produced CNN models that discriminate serpentinite and greenstone with 99.4% accuracy and all of four cuttings with 73.1% accuracy. Deep learning of HS images of serpentinite (with almost no chrysotile included) and a mineral specimen of chrysotile produced a CNN model that classifies these two samples with almost 100% accuracy. Combining the CNN models developed in this study, cuttings suspected to be serpentinite are able to be quickly investigated in-situ to determine whether the cuttings are serpentinite and, if so, whether they also include asbestos without any special skills. This technique will be of great help in avoiding trouble and contribute to safety and profitability in excavating tunnels through the ground that includes serpentinite.