

# BD6 CNN を用いた顕微鏡画像中のアスベスト繊維の自動判別方法の検討

Examining automatic classification method of asbestos fiber in microscope image using CNN

共生環境評価領域

08E16042 高井美佑 (Miyu TAKAI)

**Abstract:** Asbestos monitoring is very important to prevent health problem caused by asbestos. In this study, I proposed a method to identify asbestos fibers in microscope images using CNN, a kind of deep learning, instead of relying on human intuition. I chose chrysotile and amosite as asbestos fibers, which had been widely used for building materials, and constructed two CNN models: one for classifying chrysotile and non-asbestos, and the other for classifying amosite and non-asbestos. The former was built with 36 chrysotile images and 36 non-asbestos images, and the latter with 120 amosite images and 120 non-asbestos images. The accuracy of the former and the latter was 0.842 and 0.744, respectively.

**Keywords:** Asbestos, Microscope image, CNN, Deep learning

## 1. はじめに

アスベストはその優れた特徴から建材として広く使用されていたが、アスベストに曝露することで肺がんや中皮腫を発症するリスクが高まることが明らかとなり、段階的に使用が禁止された。一方、アスベストが使用された建築物は残存しており、解体時にアスベストが飛散し健康被害を及ぼすことが危惧されている。そのため、解体現場ではアスベストのモニタリングが行われている。モニタリングには、従来、人が繊維を判別する位相差顕微鏡法と呼ばれる手法が用いられているが、この手法には膨大な労力と時間を要する。そこで本研究では、機械学習の一種である CNN (畳み込みニューラルネットワーク) を用いて顕微鏡画像中の繊維をアスベスト又は非アスベストに判別する方法を検討する。

## 2. 方法

### 2. 1 繊維の顕微鏡画像の取得

兵庫県環境研究センターより、建築物の解体現場で採取された繊維を位相差顕微鏡で撮影した画像データの提供を受けた。アスベスト繊維のうち、クリソタイルとアモサイトが大部分を占めていたため、この 2 種類のみを使用した。

### 2. 2 画像の前処理

撮影した顕微鏡画像に、トリミング、グレースケールへの変換、輝度の正規化を行った。トリミングでは、画像の大きさを 200×200 ピクセルに統一した。輝度の正規化では、画像の最も暗いところが 0、明るいところが 255 となるように輝度を調整し、画像間での明るさの偏りを調整した。

### 2. 3 CNN による繊維の判別

まず、CNN の構成やトレーニングの設定を決定づけるハイパーパラメータの決定を行い、CNN を構築した。ハイパーパラメータは複数の組み合わせを試行し、CNN の精度が最も向上する組み合わせを選んだ。次に、構築した CNN のトレーニングとテストを行った。トレーニングデータとテストデータは、全データからおよそ 8:2 の割合でランダムに振り分けた。

トレーニングとテストは、クリソタイルと非アスベストの判別、アモサイトと非アスベストの判別に分けて行い、前者ではそれぞれ 36 枚ずつの計 72 枚、後者ではそれぞれ 120 枚ずつの計 240 枚の画像

を用いた。

### 3. 結果と考察

用いた CNN の構成を表 1、表 2 に示し、クリソタイルの判別結果の正答率を図 1、アモサイトの判別結果の正答率を図 2 に示す。なお、エポック数はクリソタイルの判別で 50、アモサイトの判別で 100 とし、最適化手法はどちらも Adam を用いた。正答率は、クリソタイルの判別で 0.842、アモサイトの判別で 0.744 となり、クリソタイルの判別では比較的良好な精度が得られたが、アモサイトの判別では十分に精度を上げることができなかつた。両者とも、トレーニングデータにおける正答率は 1 に達しているが、テストデータにおける正答率はそれを下回っていることから、過学習が生じていると考えられる。過学習はデータの不足などにより引き起こされるため、より多くのデータを用いることで精度の向上を達成できると考えられる。また、アモサイトの判別において、画像を回転させることで 1 枚の画像から新たな画像を 3 枚作成し、トレーニングデータを 4 倍に水増ししたところ、正答率は 0.045 上昇した。このことから、データの水増しは精度の向上に有効な手段の一つであると考えられる。

表 1 クリソタイルの判別をする CNN の構成

層	目的	フィルターサイズ	フィルターの数	ストライド	出力データサイズ
1	入力	-	-	-	200×200×1
2	畳み込み +ReLU	5×5	5	3	66×66×5
3	Maxプーリング	3×3	-	3	22×22×5
4	畳み込み +ReLU	5×5	15	1	18×18×15
5	Maxプーリング	3×3	-	3	6×6×15
6	畳み込み +ReLU	3×3	30	1	4×4×30
7	Maxプーリング	2×2	-	2	2×2×30
8	畳み込み +ReLU	2×2	60	1	1×1×60
9	全結合	-	-	-	1×1×360
10	全結合 +Softmax	-	-	-	1×1×2

表 2 アモサイトの判別をする CNN の構成

層	目的	フィルターサイズ	フィルターの数	ストライド	出力データサイズ
1	入力	-	-	-	200×200×1
2	畳み込み +ReLU	5×5	40	3	66×66×40
3	Maxプーリング	3×3	-	3	22×22×40
4	畳み込み +ReLU	5×5	80	1	18×18×80
5	Maxプーリング	3×3	-	3	6×6×80
6	畳み込み +ReLU	3×3	120	1	4×4×120
7	Maxプーリング	2×2	-	2	2×2×120
8	畳み込み +ReLU	2×2	120	1	1×1×120
9	全結合	-	-	-	1×1×80
10	全結合 +Softmax	-	-	-	1×1×2

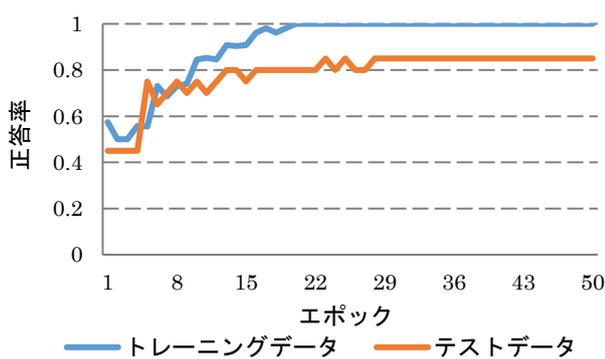


図 1 クリソタイルの判別結果の正答率

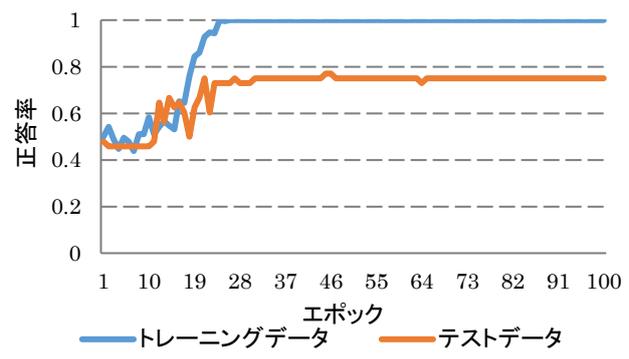


図 2 アモサイトの判別結果の正答率

### 4. 結論

本研究では、クリソタイルと非アスベスト、アモサイトと非アスベストを判別する CNN を構築した。正答率はそれぞれ 0.842、0.744 となり、クリソタイルの判別ではまずまずの結果が得られたが、アモサイトの判別では十分に精度を上げることができなかつた。今後の課題は、データの増量、データの水増し、ハイパーパラメータの見直しを実施し、さらに精度の向上を図ることである。