

機械学習による X 線 CT 画像からの亀裂の自動抽出 — 多クラスセマンティックセグメンテーションの適用 —

下茂道人

深田地質研究所

Automated fracture extraction from X-ray CT images using machine learning
— Application of multi-class semantic segmentation —

SHIMO Michito

Fukada Geological Institute

要旨：本報では、畳み込みニューラルネットワーク（CNN）を用いて、X 線 CT 画像から亀裂を自動的に抽出する技術について検討する。セマンティックセグメンテーションは、個々の画素に機械学習によるラベル付けを行う手法であり、自律走行の景観識別、医療画像からの腫瘍抽出などに広く用いられている。同様の手法は、X 線 CT 画像や露頭写真からの亀裂抽出にも適用可能と考えられるが、(1) 抽出対象が「領域」ではなく、「線分」である、(2) 画像中の亀裂の画素比率が極めて小さい、など特有の条件を考慮する必要がある。本研究では、U-Net と呼ばれる CNN アーキテクチャを用いて、30cm 角のチャートブロックの CT 画像から亀裂トレースを抽出した。自動抽出の結果、特にデータ不均衡に対処するために Focal Loss を損失関数に用いた場合、開口幅の異なる 2 つのクラスの亀裂について、人間が抽出した亀裂トレースと良好な一致を見た。キーワード：亀裂、ノイズ、深層学習、U-Net、損失関数、不均衡問題

Abstract: This paper explores a technique to automatically extract rock fractures from X-ray CT images using a Convolutional Neural Network (CNN). Semantic segmentation, a method for labeling individual pixels in image processing with machine learning, has found widespread use in scene recognition for autonomous driving, and extracting tumors from medical images. A similar approach can be applied to extract rock fractures from X-ray CT images or outcrop photographs, with specific considerations: (1) the extraction target is not a 'region' but a thin 'line segment', and (2) the pixel ratio of fractures in the image is extremely small. In this study, fracture traces were extracted from CT images of a 30 cm cube of a fractured chert block using a U-Net model, a prominent CNN in image processing, to validate the feasibility of the machine-learning approach for automated fracture extraction. The segmentation results (predictions) aligned with manually extracted fracture traces (ground truths) for two classes of fractures with different apertures, particularly when utilizing the Focal Loss, which addresses data imbalance, as a loss function.

Keywords: fracture, noise, deep learning, U-Net, loss function, imbalanced problem

1. はじめに

岩盤内に存在する亀裂は、地下水流の移動経路、あるいは変形や破壊現象を促進する弱面として岩盤の水理・力学特性に大きな影響を与える (National Research Council, 1996). このため、地下空間利用、資源開発、地下水管理、斜面防災、環境保全など様々な分野で、亀裂の分布や性質に関する情報を取得することが求められる。近年、X線CT技術の進歩により、岩石内の3次元構造を非破壊的に調べることが可能となっている (Cnudde and Boone, 2013). CT画像には、複雑な亀裂構造に関する詳細な情報が含まれているが、多数の画像から亀裂を人手により抽出するには多大な労力と時間を必要とする。また、CT画像には、X線検出量の統計的変動に起因するノイズが含まれている。これらのノイズは、平均値フィルターやガウシアンフィルターなどの単純な画像処理では取り除けないため、亀裂の判別が難しい場合も少なくない。近年、機械学習による画像データ処理技術が急速に進歩し、画像認識やコンピュータビジョンなどの分野で大きな成果を上げている (Saraf, et al., 2021). なかでも、畳み込みニューラルネットワーク (CNN) による深層学習は、画像データから高度な特徴抽出と識別が可能なることから、セグメンテーションと呼ばれる画像からの物体検出にも用いられている (LeCun et al., 1989 ; Krizhevsky et al., 2012 ; Long et al., 2015 ; Sarraf et al., 2021). 機械学習により亀裂の自動抽出が可能になると、岩石のCT画像や露頭写真などから、人間よりも高速かつ定量的な指標に基づいた亀裂情報の取得が可能となると期待される。

岩盤画像からの亀裂抽出は、亀裂に対応する画素とそれ以外の画素とのセグメンテーションを

目的とすることから、CNNを用いた物体検出が適用できる可能性がある。しかし、亀裂抽出には次のような独自の課題が存在する。

- ① 検出対象が「領域」ではなく細長い「線分」である：このため、CNNモデルの適用性、アノテーション方法、学習データ量などの検討が必要である。
- ② 画像全体に占める亀裂の画素比率が極端に小さい：不均衡データ (後述) に対応するため、適切な損失関数の選定が重要である。

本研究では、亀裂を有する30cm角のチャートブロック内を撮影したCT画像を用いてCNNモデルによる多クラスセマンティックセグメンテーション (Guo et al., 2018) を実施し、亀裂の自動抽出の可能性について検討するとともに、実データを用いた学習の過程で得られた上記課題に関連する知見をまとめる。

2. セマンティックセグメンテーション

セマンティックは、「意味のある」、「意味論の」などと訳される形容詞で、セグメンテーションは、「区分」を意味する。画像処理におけるセマンティックセグメンテーションは、画像内の各画素について、人、車、道路など、意味や特徴が異なる領域 (セグメント) に分割するタスクを指す。CT画像からの亀裂抽出は、画素毎に亀裂と亀裂以外を区分するセマンティックセグメンテーションの画像処理タスクである。

画像を2つのクラスに分割するタスクをバイナリセグメンテーションと呼び、3つ以上のクラスに分割するタスクをマルチクラス (多クラス) セグメンテーションと呼ぶ。

近年、機械学習による画像処理手法が数多く提案されており、中でも、画像のパターン認識に畳

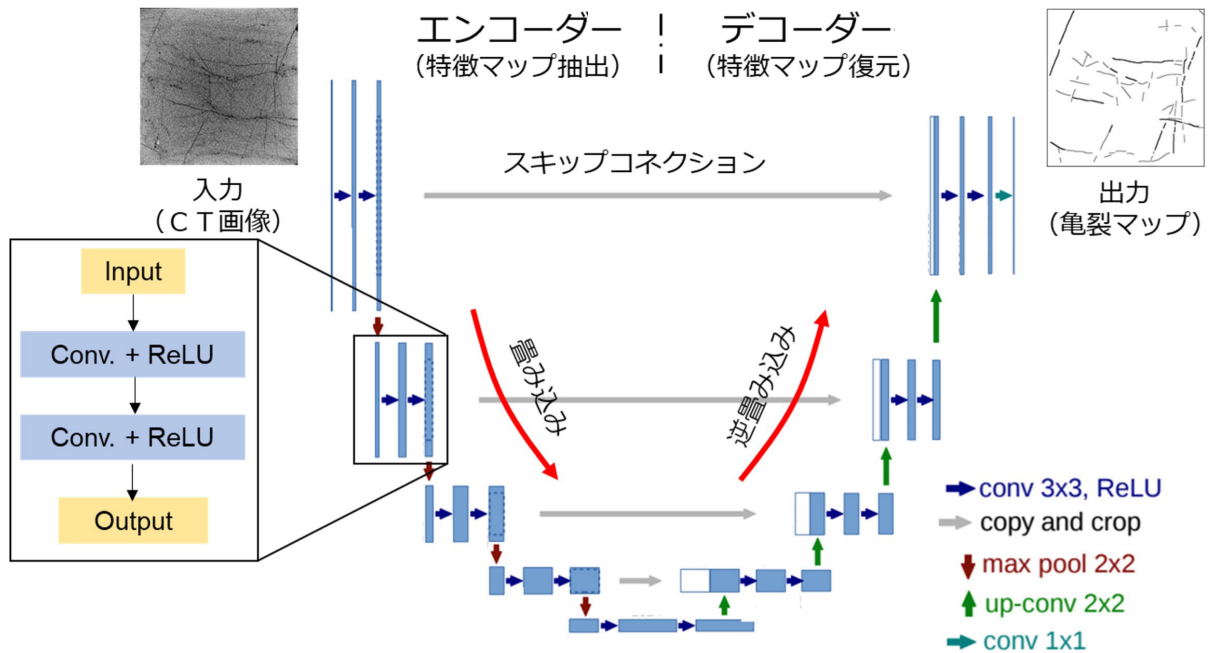


図 1 U-Net モデルによる画像からの自動亀裂抽出の流れ (Ronneberger et al., 2015 の Fig.1 をもとに作成).

畳み込み積分を用いる CNN (Convolutional Neural Network, 畳み込みニューラルネットワーク) は、医療画像診断、自動運転のための物体認識など様々な分野で活用されている。CNN は、入力画像に、様々なサイズのカーネル (またはフィルター) を用いて畳み込みを行うことで、局所的な特徴量 (形、パターン、テキストチャなど) を抽出することができる。

画像処理における一般的な CNN では、畳み込みの最後に全結合層を配置して、画像ごとの分類を行う。手書き文字認識、物体検出、犬猫識別、顔認識などがこの例である。一方、CNN の全結合層を畳み込み層に置き換えた FCN (Fully Convolutional Network, Long et al., 2015) は、画像内の空間情報が保持されることから、画素単位の分類、すなわち画像セグメンテーションを行うことができるため、画像処理、自動運転、医療画像診断などで広く用いられる。

本研究では、FCN をベースとして開発された

アーキテクチャの一つである U-Net (Ronneberger et al., 2015) を用いる。U-Net は、2015 年に発表されたセマンティックセグメンテーションのための学習モデルであり、畳み込み積分による特徴マップの作成 (エンコーダー) と、逆畳み込み積分による画像復元 (デコーダー) からなる、いわゆるエンコーダー・デコーダーモデルの一種である。CNN をベースにした画像セグメンテーションモデルは数多く発表されているが、U-Net (およびその改良版) は、その画像分類精度の高さから、現在でも医療分野などで広く用いられている。図-1 に示すように、モデルの構造はアルファベットの U の形をしており、前半では、畳み込み積分と Max Pooling (区画内の画像から最大値を選択し、画像サイズを縮小する特徴抽出法) による特徴マップ抽出を行い、後半では、逆畳み込みによる Upsampling (特徴マップのサイズを拡大し、画像の解像度を増加させる手法) により入力画像と同じ解像度を持つ特徴マップの復元を行

う。U-Net の特徴は、画像圧縮の際に失われる画素の位置情報を、Upsampling 時の対応する解像度の画像に受け渡すスキップコネクションという機能を用いて復元精度を向上させている点にある (図 1)。

X線 CT 画像からの亀裂抽出は、U-Net モデルに学習データを用いて学習させる、いわゆる教師あり学習を行うことで可能となる。すなわち、(入力画像) とそれに対応する亀裂マップ (正解データ) の組み合わせを多数用意し、これを U-Net モデルに学習させることにより、X 線 CT 画像から亀裂マップを自動抽出するモデルパラメータ (ネットワークの重みやバイアス) を決定する。(図 6)。モデルパラメータが決まれば、U-Net を用いて、新しい画像 (異なる CT 断面など) からの亀裂の自動抽出が可能となる。

3. 学習に用いる損失関数と評価関数

教師あり学習は、ニューラルネットワーク上で順伝播と誤差逆伝播と呼ばれる反復的なプロセスにより、訓練データと正解データとの間の誤差を最小化する機械学習アルゴリズムである。図 6 において、順伝播は右方向の計算プロセスで、画像から予測した亀裂分布と正解の亀裂分布との誤差を求める。一方、誤差逆伝播は左方向の計算プロセスで、誤差が最小となるように、勾配降下法を用いて CNN の各フィルターに作用するパラメータを微調整する。順伝播と誤差逆伝播を反復的に繰り返すことで、モデルの予測精度を向上させる。

誤差の指標となる損失関数には、様々なものがあるが、本研究では、画像処理で一般的に使用される 3 種類の損失関数、すなわち、Cross Entropy Loss, Focal Loss, Dice Loss を用いてそ

れぞれの結果を比較した。

評価指標 (Metrics) は、モデルの性能や成果を総合的に評価するための指標であり、訓練データとは異なるデータセットに対して学習したモデルを適用して、所定の性能が得られることを確認する。本研究では、画像処理で一般的に用いられる IoU を使用した。以下に、それぞれの誤差関数と評価指標について説明する。

3.1 Cross Entropy Loss

Cross Entropy Loss (クロスエントロピー誤差、交差エントロピー誤差ともいう) は、分類問題 (文字認識、景観分類など) で一般的に用いられる損失関数である。ピクセル単位の分類問題であるセマンティックセグメンテーションにも、Cross Entropy Loss を用いることができる。

Cross Entropy Loss は、次式で表される。

$$CE(p, t) = - \sum_x t(x) \log p(x) = -\log(p_t) \quad (1)$$

ただし、

$$p_t = \begin{cases} p(x) & \text{if } t(x) = 1 \\ 1 - p(x) & \text{otherwise} \end{cases} \quad (2)$$

ここに、 $p(x)$ は学習モデルによる予測結果、 $t(x)$ は正解ラベルである。 $t(x)$ は、正解のインデックスのみ 1 で、それ以外は 0 である。Cross Entropy Loss は、(1) 式に示したように正解ラベルに対応するピクセルの予測結果 (確率) の対数の負値を、画像全体で足し合わせたものに等しい。正解ラベルに対する予測結果が、 $p(x)=1$ 、すなわち予測と正解が一致するときに 0 となり、 $0 < p(x) < 1$ のときに正の値を取る。このことから、Cross Entropy Loss は、予測と真値の類似度を示す情報量とみなすことができる。多クラス問題に対しては、クラス毎に求めた Loss の平均値が一般に用いられる。

3.2 Focal Loss (Lin et al., 2017)

本研究で取り扱う問題においては、亀裂が占める面積は非常に小さい。このような場合、仮にすべてを亀裂以外と予測（認識）しても、誤差は非常に小さい。すなわち、Cross Entropy Loss のようにすべてのピクセルを同等に評価する傾向がある損失関数は、亀裂の抽出に対して十分な感度を有しない可能性がある。セマンティックセグメンテーションにおいて、背景（本研究では岩石）が画像の大部分を占めるデータを「不均衡データ (Imbalanced Data)」と呼ぶ。Focal Loss は、このような不均衡問題に対応するために提案された損失関数の一種であり、次式で表される。

$$FL(p_t) = -(1 - p_t)^\gamma \log(p_t), \gamma \geq 0 \quad (3)$$

(1) 式との比較から分かるように、Focal Loss は、Cross Entropy Loss に重み $(1 - p_t)^\gamma$ を乗じたものである。すなわち、 p_t が 1 に近い、判別しやすいピクセルの誤差への寄与を小さくすることで、判別が難しい少数のピクセルの全体誤差への寄与を大きくしている (図 2)。 γ は重み付けの割合を変化させるパラメータであり、 $\gamma = 0$ のとき、Focal Loss と Cross Entropy Loss とは等しくなる。多クラス問題に対しては、Cross Entropy Loss と同様クラス毎の結果の平均値が一般的に用いられる。

3.3 Dice 係数および Dice Loss

Dice 係数は、2 つの画像の各領域の重なり具合を表す指標である。いま、ラベルデータで与えた亀裂の画素 A (真値) に対してモデルによる予測 B が得られたときに、Dice 係数 (DC) は次式で計算される。

$$DC(A, B) = \frac{2|A \cap B|}{|A| + |B|} \quad (4)$$




図 2 Focal Loss における γ パラメータの影響 (Lin et al., 2017). γ が大きいほど、判別が難しい画素の Loss への寄与が大きくなる。

Dice 係数は、A と B が完全に一致したとき（予測と真値が一致するとき）1 となり、全く重ならないときに 0 となる。Dice Loss は、1 から Dice 係数を差し引いたもので、CNN モデルによる学習の損失関数として用いられる。

3.4 IoU

IoU (Intersection over Union) は、次式で示すような、真値と予測値の重なり具合を評価する指標 (Metrics) で、0 から 1 の値をとる。

$$IoU(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (5)$$

正解画像と予測画像の一致度が向上するに従って 1 に近づくことから、画像セグメンテーションの予測精度の評価指標として用いられる。

4. X 線 CT 画像を用いた亀裂抽出

4.1 画像データの取得

X 線 CT 撮影には、図 3 に示す 30 cm 角の立方体に整形した層状の赤色チャートブロック試料を用いた (下茂, 1995)。直径数 cm 程度の岩石コアは、医療用 X 線 CT 装置を用いて、試料内部の可視化が可能である。しかし、この大きさの岩



図3 30cm角のチャートブロック (下茂, 1995).

石ブロック試料では透過エネルギーが不足するため、今回の撮影には産業用高エネルギー X 線 CT 装置 (HiXCT-9M) を用いた。同装置は、X 線源として 1MeV 以上の高エネルギー X 線パルスを生じさせる電子線形加速器 (LINAC) を使用し、検出器に検出効率が高い CdTe 半導体センサを用いている (額賀ほか, 2008)。撮影条件を表1に示す。撮影では、X線エネルギーを 9MeV に設定し、2mm ピッチ (撮影スライス厚は 1mm) で、合計 150 枚の CT 画像 (試料画像の解像度: 750 ピクセル × 750 ピクセル、符号付き 16bit) を取得した。このうち、2つの断面 (断面番号 25 および 75) の画像を図4に示す。CT 画像には、ランダムノイズが多く含まれているものの、試料内部の亀裂が捉えられている。今回は、これらの画像から CNN を用いたセマンティックセグメンテーションによる亀裂の自動抽出を試みた。

4.2 学習用データセットの作成

教師あり学習では、入力データに対する予測結果と正解を比較し、その差が小さくなるようにモデルを最適化する。亀裂抽出に用いる学習用データは、入力画像とラベル付き

表1 X 線 CT の撮影条件.

撮影装置	HXCT-9M
X 線発生方式	線形加速器
X 線エネルギー	9MeV
撮影方向	1 方向のみ
測定スライス間隔	2.0mm
画素サイズ	0.4mm × 0.4mm

画像 (正解の亀裂マップ) のペアで構成される。両者は、同じ解像度の画像である。

ラベル付き画像は、入力画像の画素毎にラベル (亀裂, 亀裂以外などを示す符号) を割り当てて作成する。この作業をアノテーション (annotation) という。今回のアノテーションには、Adobe




図4 X 線 CT 画像とラベル付き画像 (黒線は、幅が 4 ピクセル以上の亀裂 (クラス 0), グレーの線は、4 ピクセル未満の亀裂 (クラス 1) を示す).




図5 データ拡張の例 (モデルの汎化性や頑健性を向上させるための画像処理)。

Photoshop を用いた。各断面の CT 画像から、ペンツールを用いて、亀裂を幅 5 ピクセルの線でなぞった。全亀裂のうち、開口幅が 4 ピクセル以上の亀裂と 4 ピクセル未満の亀裂を別々に抽出した。図 4 に、各画像に対するラベル付き画像を示す。濃い黒線が 4 ピクセル以上の亀裂、グレーの線が 4 ピクセル以下の亀裂を示す。今回の亀裂抽出は、画像から開口幅の異なる 2 種類の亀裂、および亀裂以外の 3 つのクラスに分類することから、多クラスセグメンテーションのタスクに分類される。クラス名は、それぞれ、クラス 0: 4 ピクセル以上の亀裂、クラス 1: 4 ピクセル未満の亀裂、クラス 2: 亀裂以外とした。

学習用データセットは、750×750 ピクセルの CT 画像とラベル付きデータから 256×256 ピクセルの領域をランダムに 100 セットずつ、2 断面で合計 200 セット取り出して作成した。このうち、120 セット (CT 画像とラベル付き画像のペア) を訓練用、20 セットを検証用、60 セットをテスト用に、それぞれ振り分けた。

4.3 データ拡張

U-Net のような深層学習モデルでは、多層にすることで多様な特徴抽出が可能になる一方で、モデルを構成するパラメータの数が飛躍的に増大する。このため、学習用データの数が少ないと過学習 (特定の画像に影響を受け、未知のデータに対する予測性能、すなわち汎化性能が低下すること) に陥ることが知られている。今回の場合は、2 枚の CT 画像のみからデータセットを作成しており、岩盤ブロック内の亀裂パターンを全て網羅する情報が得られていない可能性が否定できない。さらに多くの断面についての学習用データを準備することも考えられるが、作業の効率化の観点からはできるだけ少ないデータで結果が得られることが望ましい。そこで、深層学習による画像処理の分野で用いられているデータ拡張 (Data Augmentation) という手法を採用した (Buslaev et al., 2020)。データ拡張とは、学習データ (画像とラベル付きデータ) に様々な変換を施すことにより、データの「水増し」を行う処理である。デー

表 2 CNN モデルの学習パラメータ.

名称	モデル (値)
エンコーダー	EfficientNet-b4
デコーダー	U-Net++
最適化手法	Adam
活性化関数	Softmax2d
損失関数	Cross Entropy Loss, Dice Loss, Focal Loss
γ (Focal Lossの係数)	2
ステップ数	500
ミニバッチ数	10
学習率	1×10^{-4}

タ拡張を行うことで、ノイズやひずみに影響を受けにくい、モデルの汎化性や頑健性が向上することが知られている。今回は、図 5 の例に示すように、入力画像に対して、左右・上下反転、拡大・縮小、ぼかしなどの変換をランダムに行うことでデータ拡張を行った。

4.4 学習モデルとハイパーパラメータ

セマンティックセグメンテーションには、PyTorchのライブラリの一つである segmentation_models.pytorch (https://github.com/qubvel/segmentation_models.pytorch) を用いた。同ライブラリには、セグメンテーションを簡易に行うため、学習モデル、活性化関数、最適化アルゴリズムなどが多数収められており、データセットの作成や学習の実行を支援する機能も備わっている。タスクの実行は、クラウドベースの機械学習実行

環境である Google Colaboratory 上で行い、処理を効率的に進めるため GPU を利用した。

表 2 に、学習に用いたモデルやハイパーパラメータ (ユーザーが指定する学習パラメータ) を示す。エンコーダーには、画像認識タスクで高い精度と計算効率を実現できる EfficientNet (Tan and Le, 2019) を用いた。また、収束性を向上する目的で、初期の重みには ImageNet で学習させたものを用いた。

5. 学習結果

表 3 に、テストデータセットに対して、3つの損失関数を用いた学習結果について、クラス毎の IoU の最高得点を示す。亀裂以外 (クラス 2) の IoU は 0.98 以上の値であるのに対し、亀裂 (クラス 0 および 1) は 0.66 ~ 0.85 程度の値となった。これは、亀裂に対応する画素の抽出が亀裂以外の画素の抽出より難易度が高いことを示している。

図 6 に、学習に用いた 2 断面 (断面番号 25 および 75) について、Focal Loss を損失関数に用いたケースで得られた亀裂抽出結果を示す。左が元画像、中央が正解データ、右が予測結果である。正解データおよび予測画像において、黒線が開口幅が 4mm 以上の亀裂 (クラス 0)、グレーの線が 4mm 以下の亀裂 (クラス 1) をそれぞれ示す。

表 3 異なる損失関数に対する精度評価指標 IOU の比較 (テストデータセットの結果).

損失関数の種類	IOU		
	クラス 0 幅 4mm 以上の亀裂	クラス 1 幅 4mm 未満の亀裂	クラス 2 開口亀裂以外の領域
Cross Entropy Loss	0.8340	0.6763	0.9890
Dice Loss	0.8507	0.6623	0.9891
Focal Loss	0.8344	0.7341	0.9905

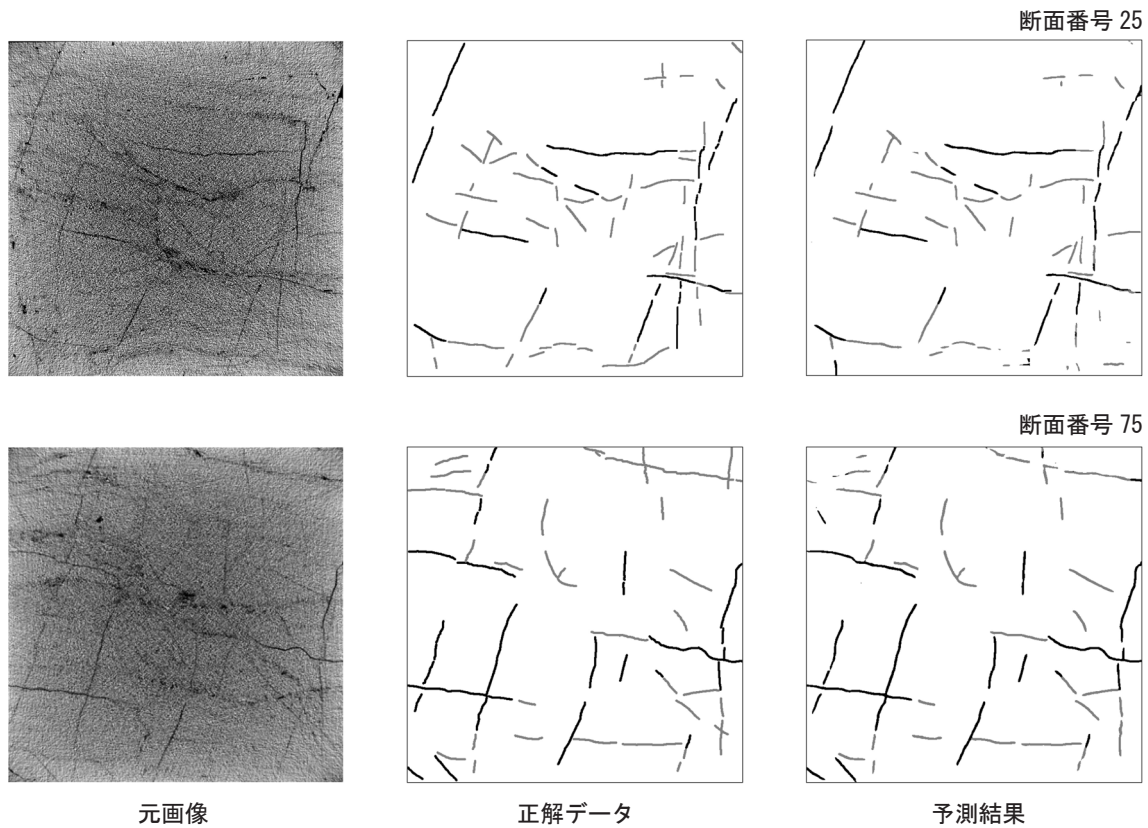


図 6 亀裂の自動抽出結果. 損失関数に Focal Loss を用いた結果. 正解データと予測結果の黒線は開口幅 4mm 以上の亀裂 (クラス 0), グレーの線は開口幅 4mm 未満の亀裂 (クラス 1), 白は亀裂以外の領域 (クラス 2) を示す.

6. 考察

表 3 において, 幅 4mm 以上の亀裂 (クラス 0) と幅 4mm 以下の亀裂 (クラス 1) の結果を比較すると, 後者の IoU が相対的に小さく, クラス 1 亀裂の抽出が, より難しいことを示している. この理由としては, 細かい亀裂ほど, CT 画像のノイズの影響を受けやすいことが考えられる. 実際, 目視による亀裂抽出でも, ノイズの多い画像からある程度以下の幅の亀裂を判読するのは難しい場合がある. 細かい亀裂ほど IoU が低下するもう一つの理由として, アノテーション方法が関係していると考えられる. 前述のように, 正解画像を作成する際の亀裂画素の抽出において, 亀裂はクラスによらず幅一定 (5 ピクセル) のライン

として抽出した. これは, 今回取得した CT 画像が, 開口幅の分布を判別できるほどの分解能がなかったためである. このようなアノテーションでは, 亀裂ラベルを付与した画素の一部に, 亀裂以外の画素も含まれるため, 亀裂幅の小さい亀裂ほど IoU が小さくなる傾向にある. 分解能の高い CT 画像の場合は, 亀裂のみを正確にアノテーションすることで, より正確な IoU の評価が可能になると考えられる.

学習に用いた損失関数による IoU の違いに着目すると, クラス 0 亀裂の抽出については, Dice Loss の IoU が最も高かったものの, 損失係数による違いは少ない (0.8340 ~ 0.8507). 一方で, クラス 1 亀裂については, Focal Loss の IoU が, 他の 2 つの損失関数を用いた結果 (0.6763,




図7 学習に用いなかった断面画像からの亀裂抽出結果(比較のため、通常の画像処理の結果をあわせて示す。画像処理には、ImageJを用いた)。

0.6623)と比較して有意に高い値(0.7341)を示した。すなわち、Focal Lossを損失関数に用いることで、開口幅の小さい亀裂の抽出精度が向上することが示された。亀裂以外の領域については、Focal LossのIoUが最も高い値を示したが、損失関数による差異は少ない(0.9890～0.9905)。

以上から、今回用いた3つの損失関数の中では、Focal Lossを用いたケースが、クラス間の精度の差異が最も少ない結果となった。これは、「難しいクラスの学習精度を向上する」ことを目的としたFocal Lossの特徴が表れた結果と言える。

図6に示したように、学習に用いた2断面(断面番号25および75)については良好な亀裂抽出が行われた。しかし、細かくみると、開口幅の大きいクラス0の亀裂(黒線)については、ほぼ正

確に抽出されているものの、クラス1の亀裂(グレー)については、細部で相違が見られる。これは、亀裂幅の小さい亀裂ほど、アノテーションデータに不確実性が含まれることが影響していると考えられる。すなわち、「建物」、「道路」、「猫」、など対象物がはっきりしている物体検出に対し、アノテーションの際の亀裂判定には、観察者の判断による不確実性が含まれる。教師データに含まれる不確実性が高いほど、それに基づいて学習した結果にも不確実性が反映されると考えられる。

図7に、学習に用いなかった2つの断面(断面番号20および125)について、学習モデルを用いて亀裂抽出を行った結果を示す。同図から、X線CT画像から主要な亀裂を抽出できていることが分かる。すなわち、学習したモデルが、新た

な画像の亀裂抽出にも適用できる性能、すなわち「汎化性能」を有していることが分かる。

図 7 には、比較のために、各画像から、パブリックドメインの画像解析ツール ImageJ (<https://imagej.nih.gov/ij/docs/index.html>) を用いて亀裂抽出を試みた結果を示す。通常の画像処理（同図では、明るさ/コントラスト調整、バンドパスフィルター、二値化を実施）では、ノイズの除去には限界があることが分かる、

図 8 に、Focal Loss を用いたケースについて、学習の途中過程における亀裂抽出結果を示す。図 7 に示したように、通常の画像処理では、ノイズの多い画像から亀裂のみを取り出すことが困難であるが、CNN を用いることで、学習の進展とともに、ノイズがほぼ取り除かれ、最終的に亀裂のみが抽出されていることが分かる。

以上の結果から、機械学習を用いることにより、従来の画像処理では困難な、ノイズの大きい CT 画像からの亀裂の自動抽出が可能であることが示された。

7. まとめ

本研究では、CNN モデルを用いた多クラスセマンティックセグメンテーションにより、X 線 CT 画像からの亀裂抽出を試みた。その結果、下記のことが明らかになった。

- 1) U-Net をベースにした CNN（畳み込みニューラルネットワーク）を用いた多クラスセグメンテーションにより、X 線 CT 画像から開口幅の異なる亀裂を自動抽出できることを示した。
- 2) 亀裂抽出は、典型的なデータ不均衡な学習問題であるが、損失関数に Focal Loss を用いることで、クラス間の予測

精度差が少ない亀裂抽出が可能であることを示した。

- 3) データ拡張を用いることで、少ない学習データ（今回は、2 断面の画像に対する亀裂データ）から、新たな画像についても亀裂抽出が行える汎化性のあるモデルが得られることが分かった。
- 4) 学習モデルを用いることで、多数の画像から、一定の基準で効率的に亀裂抽出が行える可能性がある。
- 5) 亀裂抽出結果の解釈に当たっては、観察者の主観や基準の不統一など、亀裂抽出に含まれる不確実性の影響に留意が必要である。

以上の知見を踏まえ、今後は、機械学習分野における新たな知見を取り入れ、さらなる予測精度の向上を図るとともに、岩盤露頭写真、衛星写

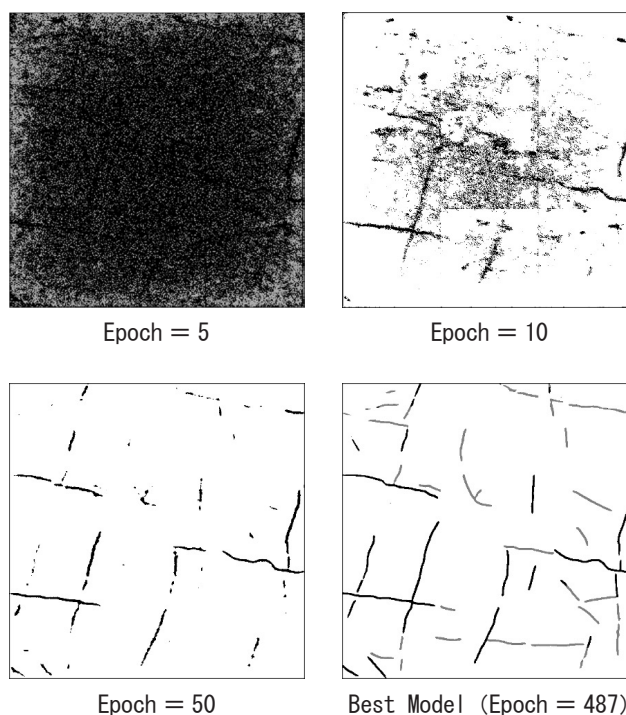


図 8 学習過程における亀裂抽出結果（断面番号 75 の例、学習が進むにつれノイズが取り除かれ、亀裂のみが抽出されることが分かる）。

真, ボーリング孔壁画像などからの断層や亀裂の抽出など, 本技術の他分野における活用方法についても検討していきたい。

文献

- Buslaev, A., Iglovikov, V. I., Khvedchenya, E. Parinov, A., Druzhinin, M. and Kalinin, A. A. (2020): Albumentations: Fast and Flexible Image Augmentations. *Information*, **11**, 125.
- Cnudde, V. and Boone, M. N. (2013): High-resolution X-ray computed tomography in geosciences: a review of the current technology and applications, *Earth-Science Reviews*, **123**, 1–17.
- Guo, Y., Liu, Y., Georgiou, T. and Lew, M. S. (2018): A review of semantic segmentation using deep neural networks, *International Journal of Multimedia Information Retrieval*, **7**, 87–93.
- Krizhevsky, A., Sutskever, I. and Hinton, G. E. (2012): ImageNet classification with deep convolutional neural networks. *Proceedings of the 25th International Conference on Neural Information Processing Systems*, 1097–1105.
- LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P. (1998): Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, **86**(11), 2218–2324.
- Lin, T. Y., Goyal, P., Girshick, R., He, K. and Dollár, P. (2017): Focal Loss for Dense Object Detection. *2017 IEEE International Conference on Computer Vision*, 2980–2988.
- Long, J., Shelhamer, E., Darrell, T. (2015): Fully convolutional networks for semantic segmentation. *Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition*, 3431–3440.
- National Research Council (1996) : *Rock fractures and fluid flow: Contemporary understanding and applications*, National Academy Press, Washington D. C., 551p.
- Ronneberger, O., Fischer, P. and Brox, T. (2015): U-Net: convolutional networks for biomedical image segmentation, *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 234–241.
- Sarraf, A., Azhdari, M. and Sarraf, S. (2021): A Comprehensive Review of Deep Learning Architectures for Computer Vision Applications, *American Scientific Research Journal for Engineering, Technology, and Sciences*, **77**(1), 1–29.
- 下茂道人 (1995) : 不連続性岩盤内の透水性の不均一性と流れの局所化について, *材料*, **44** (502), 869–873.
- Tan, M. and Le, Q. V. (2019): EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the 36th International Conference on Machine Learning*, 6105–6114.
- 額賀 淳, 上村 博, 高木寛之 (2008) : 産業用高エネルギー X線 CT装置への CdTe 化合物半導体センサの適用, *非破壊検査*, **57** (10) 号, 484–487.
- https://github.com/qubvel/segmentation_models.pytorch (2023年8月31日参照).
- <https://imagej.nih.gov/ij/docs/index.html> (2023年8月31日参照).