

テクニカルレポート

# 医用画像 AI 開発支援ソフトウェアを用いた 歯科用 CBCT 画像における下顎管のセグメンテーション

鳥井 浩平<sup>1</sup>, 西村 良太<sup>2</sup>, 誉田 栄一<sup>3,4</sup>

## Segmentation of Mandibular Canal on Dental Cone Beam CT Images with AI Development Support Software for Medical Images

Kohei Torii<sup>1</sup>, Ryota Nishimura<sup>2</sup> and Eiichi Honda<sup>3,4</sup>

The primary barrier to the development of artificial intelligence (AI) in medical imaging is data collection. Medical professionals generate training data for the development of medical imaging AI; however, this process is time-consuming and labor-intensive. Consequently, insufficient data collection frequently results in the premature discontinuation of AI model development. To address this challenge, we developed a software tool named 'Aidia' to support the research and development of medical imaging AI. Aidia offers functionalities such as a medical image viewer, data annotation, model training for various tasks, model evaluation, and automated annotation using trained models. For data annotation, Aidia allows users to annotate images by generating polygons, rectangles, polylines, lines, and points. Aidia supports Digital Imaging and Communications in Medicine images as well as general image formats, and we optimized it for annotating medical images. Moreover, Aidia utilizes open-source Python and PyQt5 libraries to build a cross-platform graphical user interface. Thus, Aidia provides a platform where medical professionals can develop, evaluate, and create training data for AI models at no cost. In this study, we developed a segmentation model based on U-Net to predict mandibular canals in cross-sectional jawbone images using Aidia. We collected 8,287 images annotated by a radiologist and trained the segmentation model using these data. The trained model achieved a precision of 0.805, recall of 0.752, F1 score of 0.777, and average precision of 0.869 on test data, accurately generating training data for the test images. Aidia is a promising solution for AI development and image annotation in the medical field.

*Dental Radiology 2024; 64(1): 11-19*

**Key words:** Medical Images, Artificial Intelligence (AI), Segmentation, Cone Beam CT (CBCT), Mandibular Canal / 医用画像, 人工知能, セグメンテーション, CBCT, 下顎管

### 1. 緒言

近年では医用画像に対する人工知能 (Artificial Intelligence, AI) 技術の有効性が多くの研究で示されたことにより, 画像診断の効率化や負担軽減を目的とした画像診断支援システムの研究開発が世界中で行われている。その中にはすでに製品として販売された画像診断支援システムもあり, 社会への普及も進んでいる。たとえば, SYNAPSE

SAI viewer (富士フイルム株式会社, 日本, 東京) は AI を用いた臓器のセグメンテーション (画像を画素単位で意味のあるグループに分割すること) や肺結核の検出などが可能な医用画像ビューアであり, Computed Tomography (CT) 画像や Magnetic Resonance Imaging (MRI) 画像の読影補助として有用なサービスの一つである。医用画像 AI に関する研究開発は一般的に医学研究者と情報工学研究者が共同で行うことが多く, 医学研究者は主に医用画像の収集と, 収集した医用画像に対するアノテーション (情報の付与) を行い, 情報工学研究者が AI 開発やシステム構築などを行う。画像のアノテーションには, 一般的にアノテーションツールと呼ばれる専用のソフトウェアを用いる。たとえば, 歯科パノラマ X 線写真から歯を検出する AI を開発する場合はアノテーションに歯の位置や形状などの情報が必要となるため, アノテーションツールを用いて歯科パノラマ X 線写真に写る各歯を多角形などの図形で囲むという作業が必要になる。日本国内の代表的なアノテーションツールの一つに FastLabel (FastLabel 株式会社, 日本, 東京) がある。FastLabel はアノテーションツールとしての機能に加えて既存の豊富なデータセットの

Received October 3, 2023, revision accepted March 29, 2024.  
 著者所属: <sup>1</sup>徳島大学デザイン型 AI 教育研究センター, <sup>2</sup>徳島大学大学院社会産業理工学研究部情報工学分野, <sup>3</sup>徳島大学大学院医歯薬学研究部歯科放射線工学分野, <sup>4</sup>こばやし歯科クリニック  
 別刷請求先: 〒 770-8503 徳島県徳島市蔵本町 3 丁目 18-15  
 徳島大学デザイン型 AI 教育研究センター 鳥井浩平  
 From <sup>1</sup> Center for Design-Oriented AI Education and Research, Tokushima University, 3-18-15, Kuramoto-cho, Tokushima-shi, Tokushima 770-8503, Japan, <sup>2</sup> Information Engineering, Tokushima University Graduate School of Technology, Industrial and Social Science, <sup>3</sup> Oral and Maxillofacial Radiology, Tokushima University Graduate School of Biomedical Sciences, <sup>4</sup> Kobayashi Dental Clinic  
 Address reprint requests to the author, Dr. K. Torii  
 版権: © 2024 日本歯科放射線学会

利用や AI を用いた自動アノテーションなどが可能な有料アノテーションツールである。収集したデータを用いて AI を開発する機能もあり、AI 開発のオールインワンソリューションとして注目を集めている。現在では 100 社以上の企業が FastLabel を導入している。また、SYNAPSE Creative Space（富士フィルム株式会社、日本、東京）は医用画像 AI 開発に特化した有料クラウドサービスであり、匿名化した医用画像データをアップロードすることで、アノテーションから AI の学習や実行まで、すべてオールインワンで行うことができる。日本国外では Amazon Web Service（Amazon Web Services, Inc., アメリカ合衆国、シアトル）や Microsoft Azure（Microsoft Corporation, アメリカ合衆国、レッドモンド）などがあり、FastLabel と同様に AI 開発を包括的に行うことができる。無料で利用できるアノテーションツールには CVAT（CVAT.ai Corporation, アメリカ合衆国、パロアルト）や labelme<sup>1</sup> などがあり、医用画像ビューアである 3D Slicer<sup>2</sup> や Open Health Imaging Foundation<sup>3</sup> などアノテーションツールとして利用することもできる。このように、数多くのアノテーションツールが存在するため、Aljabri らは医用画像のアノテーションが可能な 13 種類のアノテーションツールについて調査および検証を行い、アノテーションツールの選定に有用な知見を提供している<sup>4</sup>。

特定分野の専門知識を必要としない AI 開発ではアノテーションを外部に委託することが可能な例が多いが、専門性が高く個人情報を含む医用画像のアノテーションは外部委託が難しいため、医学研究者がローカル環境下でアノテーションを行うことが往々にしてある。また、画像の収集が比較的困難な医療分野においては画像の収集を共同研究の中で随時進めていく例も少なくなく、画像を十分に収集できていない中で有料アノテーションツールを利用すると必要以上にコストがかかる可能性があるため、簡易的な試験段階では無料アノテーションツールを利用する機会が多い。したがって、無料のアノテーションツールには一定の需要があるが、AI 開発用に製作されたアノテーションツールは、Digital Imaging and Communications in Medicine (DICOM) データの読み込みができない、明るさ・コントラストの調整ができないなど、医用画像のアノテーションツールとしては機能が不十分であることが多い。他方で、医用画像ビューア付属のアノテーション機能で作成したアノテーションデータを AI 開発に用いるためには多くの前処理を必要とするため、AI 開発に用いるアノテーションツールとしては扱いが難しい一面がある。

著者らは歯科パノラマ X 線写真を対象とした医用画像 AI 開発で無料のアノテーションツールを利用していたが、上述のような課題があったため、labelme に対して、DICOM ファイルの読み込み機能やラベルの検索機能など

を追加したアノテーションツール Anotee を開発した<sup>5</sup>。Anotee は歯科パノラマ X 線写真のアノテーション用に開発したアノテーションツールであるが、研究目的に合わせてプログラムを書き換えることで、歯科パノラマ X 線写真以外のアノテーションにも利用できるため、さまざまな医用画像 AI 開発で医用画像のアノテーションツールとして運用を続けてきた。

しかし、画像のアノテーションは大変単調な作業であるため、医学研究者がモチベーションを維持できず、AI 開発に十分な数のデータを集めることができないという問題がたびたび起こっている。その理由の一つは、アノテーションが AI にどのような影響を与えるのか、AI が実際に改善されているのかなどのフィードバックを医学研究者が享受しづらいことである。医用画像 AI の共同研究では医学研究者と AI 開発者の間で AI の開発状況を逐次共有することで AI の改善策や今後の研究計画などについて検討していくが、これには多大な時間と労力がかかることが多く、結果として共同研究が長期化し、モチベーションの低下に繋がることもある。また、単調なアノテーション作業と共同研究の長期化が相まって、データの品質を保つことが難しくなるという問題も起こっており、品質の悪いデータが増加することで AI の学習に悪影響を及ぼす可能性も懸念される。

著者らはこの現状を改善するために、Anotee に対して、汎用アノテーションツールとして利用するための改良、簡易的な AI 開発機能、開発した AI による自動アノテーション機能を加えた、医用画像 AI 開発支援ソフトウェア Aidia を開発した。Aidia のターゲットは主に大学病院などの医療関係の研究機関であり、医用画像 AI 開発を医学研究者自身が単独で行うことができる環境を提供することを目標とする。Aidia の特色は主に、①完全無料で利用できること、②ローカル環境で利用できること、③DICOM ファイルに対応していること、④物体検出とセグメンテーションの AI 開発ができること、⑤開発した AI による自動アノテーションができることである。④⑤の機能により、医学研究者が自らのアノテーションによって AI が賢くなっていく様子を直に観察することができるため、アノテーション作業に対する医学研究者のモチベーション向上が期待できる。また、画像のアノテーションから AI 開発まで、すべてマウス・キーボード操作のみで行うことができるため、プログラミングの知識や経験がない人でも気軽に AI 開発に触れることができ、AI 開発において試行錯誤で得られる知見やノウハウの習得に役立つ。結果として、Aidia は医用画像 AI に関する研究開発のさらなる活性化に貢献することが期待される。なお、Aidia は SYNAPSE Creative Space と目的や機能が似ているが、Aidia は①②の点で有用である。

本論文では、Aidia の実装と仕様について解説し、歯科用 CBCT 画像から切り出した断面画像に対する下顎管のセグメンテーション AI 開発を題材に、Aidia の実用性について述べる。

## 2. 材料と仕様

### 2.1 医用画像 AI 開発支援ソフトウェア Aidia

Aidia のメイン画面を Figure 1 に示す。Aidia は主に、画像のアノテーション、AI 開発、AI 評価、自動アノテーションの 4 つの機能で構成されている。画像のアノテーションでは、画面左側と画面右側に配置されたボタンを押して画像の読み込みやアノテーションの種類を選択などを行い、画面中央に表示された画像に対して、マウス操作でアノテーションを行う。AI 開発、AI 評価、自動アノテーションはそれぞれ「AI 開発」、「AI 評価」、「AI データ生成」ボタンに対応している。各機能の詳細は後述する。ただし、本論文では物体検出の機能については割愛する。

Aidia は Python (Python Software Foundation, アメリカ合衆国, ウィルミントン) と Python で実装されたオープンソースのライブラリを用いて開発した。画像処理は OpenCV<sup>6</sup>, AI モデルの実装は TensorFlow (Google LLC, アメリカ合衆国, マウンテンビュー), DICOM ファイルの処理は Pydicom<sup>7</sup> を用いた。アプリケーションの構築には、Windows, MacOS, Ubuntu などの Operating System (OS) に対応している PyQt5 (Riverbank Computing Limited, ドーチェスター, イングランド) を用いた。また、Aidia の表示言語は英語と日本語の 2 種類に対応させた。Aidia の実行には、Windows, MacOS, Ubuntu のいずれかの OS を搭載したコンピュータが必要であり、8 GB 以上のランダムアクセスメモリと、4 GB 以上の Graphic Processing Unit (GPU) メモリを持つ GPU を搭載しているコンピュータを推奨している。

対応している画像ファイルフォーマットは、Windows Bitmap (BMP), Portable Network Graphics (PNG), Joint Photographic Experts Group (JPEG), Tag Image File Format (TIFF), DICOM であり、拡張子がない DICOM ファイルの読み込みも可能である。DICOM ファイルの読み込みでは画像以外の情報も取得し、「DICOM 情報」ウィンドウに表示する。ただし、個人情報に関わる情報は表示しない。また、DICOM ファイルから取得した画像 (DICOM 画像) には、DICOM ファイルから読み込んだウィンドウ中心とウィンドウ幅の値を用いてウィンドウ処理を行う。

画像の明るさ・コントラストはマウスの右クリックを長押ししながらドラッグすることで調節できる。上方向にドラッグすると画像は明るくなり、下方向にドラッグすると画像は暗くなる。また、右方向にドラッグするとコントラ

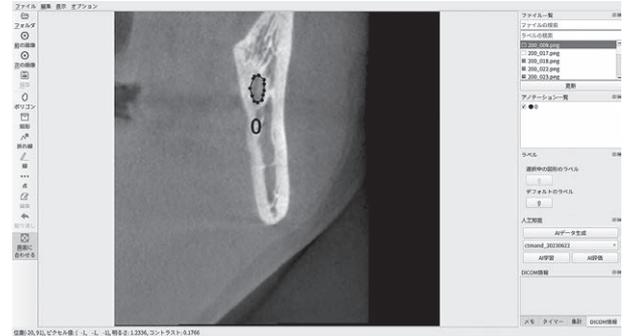


Figure 1 Aidia のメイン画面

中央の画像は左側下顎骨の歯科用 CBCT 頬舌断面像である。多角形の領域は下顎管を示している。多角形の下に “0” はラベルであり、ここでは下顎管を “0” としてラベリングしている。

ストが高くなり、左方向にドラッグするとコントラストが低くなる。DICOM 画像が表示されているときは、ウィンドウ中心の増減を垂直方向のドラッグ、ウィンドウ幅の増減を水平方向のドラッグに割り当てており、ウィンドウ中心とウィンドウ幅が変化するとき、元画像に対してウィンドウ処理を行うことで、画像の明るさ・コントラストを変化させる。ウィンドウ処理では、ウィンドウ中心を下げる (上方向にドラッグする) と画像が明るくなり、ウィンドウ幅を狭める (右方向にドラッグする) とコントラストが高くなる。DICOM 画像以外の画像が表示されているときは、式 2.1.1 にしたがって画素値の変換を行う。

$$x_{new} = \text{clip}(\alpha x + \beta) \quad (0 < \alpha < 2, -M < \beta < M) \quad (2.1.1)$$

$x$  は元画像の画素値、 $x_{new}$  は変換後の画素値、 $M$  は 8 ビット画像であれば 255、16 ビット画像であれば 65535 をとる定数である。clip 関数は  $\alpha x + \beta$  が  $M$  より大きい値であれば  $M$  に、 $\alpha x + \beta$  が 0 より小さい値であれば 0 に変換する処理を表す。 $\alpha$  がコントラスト、 $\beta$  が明るさに相当する変数であり、 $\alpha$  が増えると画像のコントラストが高くなり、 $\beta$  が増えると画像が明るくなる。なお、 $\beta$  の増減を垂直方向のドラッグ、 $\alpha$  の増減を水平方向のドラッグに割り当てている。

### 2.2 画像のアノテーション機能

Aidia では画像に対して多角形、矩形、折れ線、線、点のアノテーションを付与することができる。ラベルはオプションメニューで設定することで画面上にボタンとして配置され、作成した図形を選択してボタンを押すとラベルを付与することができる。各図形は基本的にラベルが付与されていない状態で作成されるが、デフォルトラベルを設定することで、新しい図形を作成した際にデフォルトラベルが自動的に付与される。この仕様は同じラベルの図形を大

量に作成するときには活用することで作業の効率化に寄与する。たとえば、細胞の顕微鏡画像からがん細胞を検出する AI の開発では、大量の細胞に対してそれぞれ多角形や矩形で囲み、陽性または陰性のラベルを付与する必要があるが、デフォルトラベルを陽性または陰性に設定すれば、ラベル付与の手間を最小限に抑えることができる。なお、各図形の種類と付与したラベル、図形を構成する頂点の座標などの情報は JavaScript Object Notation (JSON) フォーマットのファイルとして保存され、対応する画像の読み込み時に再度自動で読み込まれる。

### 2.3 AI 開発機能

AI 開発機能では、学習の設定、データセットの構築、AI モデルの構築・学習を行う (Figure 2)。セグメンテーションの AI 開発では、セグメンテーションの場合は U-

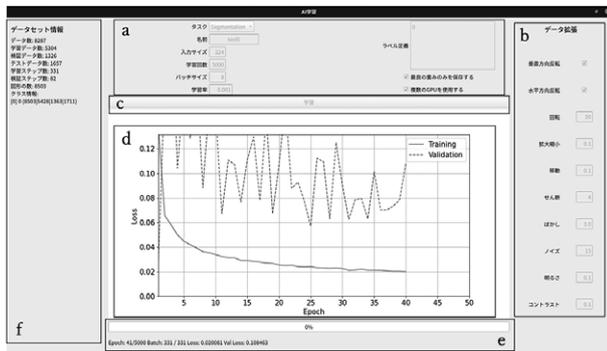


Figure 2 AI 学習ウィンドウ

学習の設定値 (a, b) を入力したあと、「学習」ボタン (c) を押すことで学習が始まる。AI の学習中は学習曲線 (d) がリアルタイムで描画され、学習の進捗 (e) が表示される。また、AI の学習に使用しているデータセットの情報も表示される (f)。

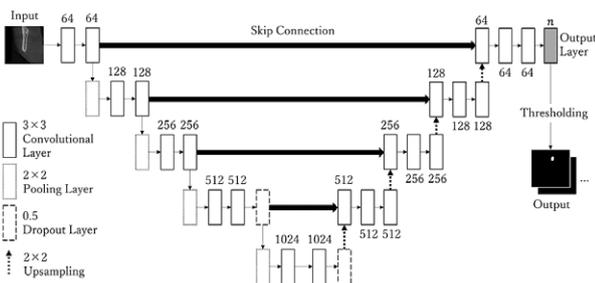


Figure 3 セグメンテーションモデルの構造

凡例における  $3 \times 3$  や  $2 \times 2$  はフィルタサイズを表し、ドロップアウト層 (Dropout Layer) の 0.5 はドロップアウトするユニットの割合 (ドロップアウト率) を表す。また、各畳み込み層 (Convolutional Layer) の上下の数字はフィルタ数を表し、 $n$  はラベルの種類数を表す。Skip Connection は接続元の特徴マップを接続先に結合する処理である。出力層 (Output Layer) で得られた各ラベルに対する確率に対してしきい値処理 (Thresholding) を行うことで、各ラベルのマスク画像を得る。

Net<sup>8</sup> に基づく AI モデル (セグメンテーションモデル) を構築する。Figure 3 にセグメンテーションモデルの構造を示す。入力画像 (Input) のサイズは可変であり、各層の入出力サイズは入力画像のサイズに合わせて自動的に調節される。ただし、入力画像のサイズは  $16 \times 16$  ピクセルから  $2048 \times 2048$  ピクセルまでの制限を設けており、畳み込み層のフィルタ数とフィルタサイズ、ドロップアウト (ランダムにユニットの一部を無効にする) 層のドロップアウト率、プーリング層とアップサンプリングのフィルタサイズ、層構造は固定である。入力画像は正方形の 8 ビット 3 チャンネル画像とし、元画像と入力画像のサイズが異なる場合は、入力画像のサイズに合わせて元画像をリサイズする。また、入力画像を入力するときには、入力画像を単精度浮動小数点数に変換し、各画素値は 255 で除算することで正規化を行う。畳み込み層の活性化関数は出力層 (Output Layer) を除いてすべて ReLU 関数であり、プーリング層 (Pooling Layer) とアップサンプリング (Upsampling) の直前の各畳み込み層には Batch Normalization<sup>9</sup> を適用している。出力層は活性化関数をシグモイド関数としたフィルタサイズ  $1 \times 1$  の畳み込み層であり、各画素が各ラベルに属する確率を出力する。出力層のチャンネル数は後述するラベルの定義に基づいて自動的に決定される。なお、ReLU 関数とシグモイド関数はそれぞれ式 2.3.1 および式 2.3.2 で表される。

$$R(z) = \max(0, z) \tag{2.3.1}$$

$$\sigma(z) = \frac{1}{1 + e^{-z}} \tag{2.3.2}$$

損失関数 (予測値と真値の誤差を表す関数) は二値交差エントロピー、最適化アルゴリズムは Adam<sup>10</sup> を採用している。二値交差エントロピーは予測値と真値が離れるほど大きな値をとる。 $L$  を損失、 $t$  を真値、 $y$  を AI の予測値とすると、二値交差エントロピーは式 2.3.3 で表される。

$$L = -t \log y - (1 - t) \log(1 - y) \tag{2.3.3}$$

Adam の学習率 (パラメータの更新割合を決める値) 以外のハイパーパラメータ (人が決定するパラメータ) は TensorFlow の既定値を用いる。

学習の設定では、AI モデルの名前、入力画像のサイズ、学習回数 (AI が学習データを繰り返し学習する回数)、バッチサイズ (1 回のパラメータ更新に用いるデータ数)、学習率、ラベルの定義、最良のパラメータ (重み) を保存するか否か、複数の GPU を使用するかどうかの設定を行う。AI モデルの名前は AI 評価や自動アノテーションを利用するとき参照される。AI が学習対象とするラベルは「ラベル定義」に記述する。セグメンテーションモデルの構築では、どのラベルにも属さない画素に “background” の

ラベルを自動的に付与し、背景の学習も行う。最良のパラメータを保存するか否かの設定では、10回の学習毎にパラメータを保存するか、検証データに対する損失が前回の学習よりも小さくなったときに限りパラメータを保存するかを選択することができる。複数GPUの使用はGPUを2枚以上搭載しているコンピュータに限り可能であり、有効にすると計算処理を並列化して高速化することができる。

データ拡張（データに対して何らかの変換を行うことで、データを水増しすること）では、垂直・水平方向反転、回転、拡大・縮小、平行移動、せん断（長方形を平行四辺形に変形する処理）、ガウシアンぼかし（正規分布を用いて画像をぼかす処理）、ガウシアンノイズ（正規分布に従うランダムノイズ）の付加、明るさ変化、コントラスト変化を適用することができる（Figure 4）。垂直・水平方向反転を有効にした場合は、垂直方向反転と水平方向反転がそれぞれ学習データ（AIの学習に用いるデータ）に50%の確率で適用される。反転以外のデータ拡張では、それぞれ設定した値の範囲内でランダムに値をサンプリングして学習データのデータ拡張を行う。回転とせん断では角度の範囲、拡大・縮小では元画像サイズに対する倍率の範囲、平行移動では上下左右の移動ピクセル量の範囲、明るさ変化では式 2.1.1 における  $\beta$  の範囲、コントラスト変化では式 2.1.1 における  $\alpha$  の範囲を設定する。たとえば、回転において設定した値が10の場合、-10から10までの範囲でランダムに値をサンプリングし、サンプリングした値を回転の角度として扱い、回転を行う。せん断において設定した値が10の場合、-10から10までの範囲でランダムに2つの値をサンプリングし、サンプリングした2つの値をそれぞれ縦方向・横方向のせん断ひずみ（角度）として扱い、せん断を行う。拡大・縮小において設定した値が0.2

の場合、0.8から1.2までの範囲でランダムに値をサンプリングし、サンプリングした値を元画像サイズに対する倍率として扱い、拡大・縮小を行う。平行移動において設定した値が20の場合、-20から20までの範囲でランダムに2つの値をサンプリングし、サンプリングした2つの値をそれぞれ上下・左右の移動量として扱い、平行移動を行う。明るさ変化とコントラスト変化はそれぞれ設定した範囲内の値からランダムにサンプリングした値をそれぞれ  $\beta$ 、 $\alpha$  とし、式 2.1.1 にしたがって画素値の変換を行う。ガウシアンぼかしとガウシアンノイズの付加では、設定した範囲内の値からランダムにサンプリングした値を標準偏差とした正規分布を用いて、それぞれ処理を行う。たとえば、ガウシアンぼかしにおいて設定値が10の場合、0から10までの範囲でランダムにサンプリングした値を標準偏差とした正規分布を用いてガウシアンぼかしを行う。ただし、ガウシアンぼかしにおけるフィルタサイズはOpenCV内のアルゴリズムによって標準偏差をもとに自動的に決定され、標準偏差が0のときはガウシアンぼかしを適用しない。また、ガウシアンノイズの付加に用いる正規分布の平均値は0とし、標準偏差が0のときはガウシアンノイズを付加しない。

データセットの構築では、対象フォルダ内のすべてのデータを学習データ、検証データ（AIの学習に用いず、AIの学習を監視するために使うデータ）、テストデータ（AIの学習に用いず、AIの評価に用いるデータ）に分割し、各データをAIの学習・検証・評価に適した形へ整形する。学習データとテストデータはデータ数の比が8:2となるように分割され、学習データの5%は検証データとして用いられる。セグメンテーションモデルの構築では、アノテーションファイルに記録された多角形の頂点座標からAIの学習・検証・評価に用いるマスク画像を生成する。マスク画像はラベルの種類の数だけチャンネルをもち、各チャンネルはラベルに該当する画素を1、それ以外を0とする二値画像である。なお、マスク画像も入力画像と同様に、リサイズや単精度浮動小数点数への変換、データ拡張が適用される。ただし、マスク画像は二値画像であるため、ガウシアンぼかし、ガウシアンノイズの付加、明るさ変化、コントラスト変化は適用されない。

データセットの構築を完了すると、「データセット情報」の記載が更新され、データの内訳などが確認できるようになる。データの内訳では、主に各ラベルにおける学習データ数、検証データ数、テストデータ数を知ることができる。学習の進捗状況は学習曲線とプログレスバーとして動的に表示される。学習曲線とは横軸に学習回数（Epoch）、縦軸に損失（Loss）をとる曲線のことであり、一般的に学習データに対する損失と検証データに対する損失の両方をプロットする。学習データに対する損失と検証データに対

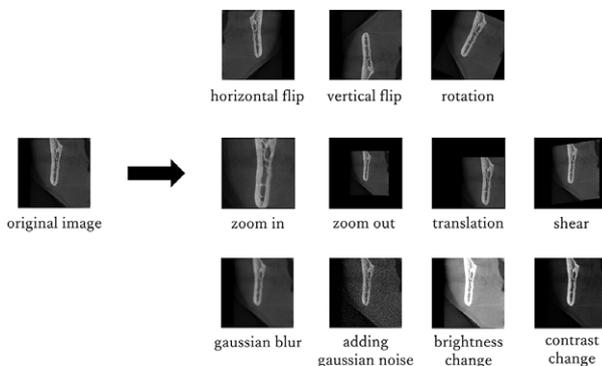


Figure 4 データ拡張の例

元画像（original image）に対して、水平反転（horizontal flip）、垂直反転（vertical flip）、回転（rotation）、拡大（zoom in）、縮小（zoom out）、平行移動（translation）、せん断（shear）、ガウシアンぼかし（gaussian blur）、ガウシアンノイズの付加（adding gaussian noise）、明るさ変化（brightness change）、コントラスト変化（contrast change）をそれぞれ適用したときの例。

する損失が両方下降していることが理想の学習状態といえる。一方で、学習データに対する損失が小さく、検証データに対する損失が大きいときは、AI モデルの未知データに対する性能が低いことが疑われる。このように、学習曲線は学習の成否の確認などに活用することができる。

### 2.4 AI 評価機能

AI 評価機能では、AI 学習機能で構築・学習した AI モデルと構築したデータセットのテストデータを用いて、さまざまな評価指標による評価を行う (Figure 5)。主な評価指標としては、適合率 (Precision)、感度 (Recall)、F 値 (F Score)、Average Precision (AP) がある。適合率は AI の予測結果のうち正しく予測できたデータの割合、感度はすべてのデータのうち AI が正しく予測できたデータの割合を意味し、F 値は適合率と感度の調和平均である。適合率、感度、F 値はそれぞれ 0 から 1 までの値をとり、1 に近いほど AI モデルの性能が高いといえる。適合率、感度、F 値はそれぞれ式 2.4.1、式 2.4.2、式 2.4.3 で表される。

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2.4.1)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2.4.2)$$

$$\text{F Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.4.3)$$

TP, TN, FP, FN はそれぞれ真陽性 (True Positive)、真陰性 (True Negative)、偽陽性 (False Positive)、偽陰性 (False Negative) を表す。TP は予測が真 (1) で正解が真 (1) であるデータ (セグメンテーションの場合は画素) の合計、TN は予測が偽 (0) で正解が偽 (0) であるデータの合計、FP は予測が真で正解が偽であるデータの合計、FN は予測が偽で正解が真であるデータの合計である。AI モデルの出力は確率であるため、しきい値処理を行うことで、二値 (1 または 0) のデータに変換した後、TP, TN, FP, FN の値を求める。Aidia では、しきい値を 0.5 としている。AP は Precision-Recall 曲線 (PR 曲線) の積分値 (曲線下の面積) であり、1 に近いほど AI モデルの性能が高いといえる。PR 曲線とは、縦軸に適合率、横軸に感度をとるグラフ上の曲線のことであり、曲線を構成する各点は AI モデルの出力に対するしきい値を変化させることで得られる複数の適合率・感度の値をプロットした点である。これらの評価値は Excel データとして出力され、混同行列や PR 曲線の図も PNG 画像として保存される。また、各ラベルに対する評価値や PR 曲線の図、テストデータに対する AI の予測結果を可視化した画像も同時に保存される。これらのデータは「データのエク

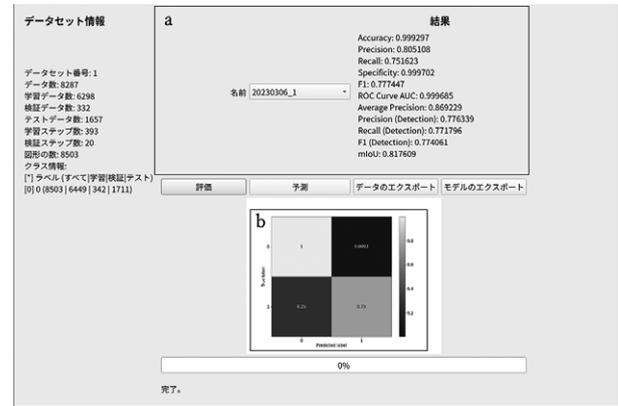


Figure 5 AI 評価ウィンドウ

「名前」で学習済み AI モデルの選択し、「評価」ボタンを押すことで評価を行うことができる。評価が終わると、評価結果 (a) と混同行列 (b) が表示される。混同行列はラベル間の関係を考察するときにより有用な評価指標の一つである。

サポート」機能を用いて任意の場所へ簡単にコピーすることができる。

### 2.5 自動アノテーション機能

AI 開発機能で構築した学習済み AI モデルが存在する場合は、メイン画面の「AI データ生成」ボタンを押すことで、学習済み AI モデルを用いた自動アノテーションを行うことができる。自動アノテーションでは、学習済み AI モデルに対して表示している画像を入力し、その出力結果をもとにアノテーションを自動生成する。セグメンテーションの場合、AI の出力結果 (マスク画像) に対して 9 × 9 のフィルタを用いた膨張処理と輪郭抽出を行い、アノテーションデータに変換する。輪郭抽出では、Suzuki らのアルゴリズムに基づく輪郭検出と、許容距離を輪郭周囲長の 0.01 倍とした Ramer-Douglas-Peucker アルゴリズムに基づく輪郭近似を行う<sup>11-13</sup>。自動アノテーションに用いる AI モデルは選択可能であり、過去に構築した AI モデルを利用することもできる。

## 3. 方法

本論文では、Aidia を用いた医用画像 AI の開発事例として、下顎骨の歯科用コーンビーム CT (CBCT) 頬舌断面画像における下顎管のセグメンテーションを行うセグメンテーションモデル (下顎管検出モデル) の開発を行った。パノーラ A1 (株式会社ヨシダ、日本、東京)、CS 9600 (Carestream Dental LLC、アメリカ合衆国、アトランタ)、PreXion3D Excelsior (プレキシオン株式会社、日本、東京) で撮影された歯科用 CBCT 画像を収集し、歯科用 CBCT 画像から下顎骨の頬舌断面を切り出して、300 × 300 ピクセルの 8 ビット PNG 画像に変換した。なお、パ

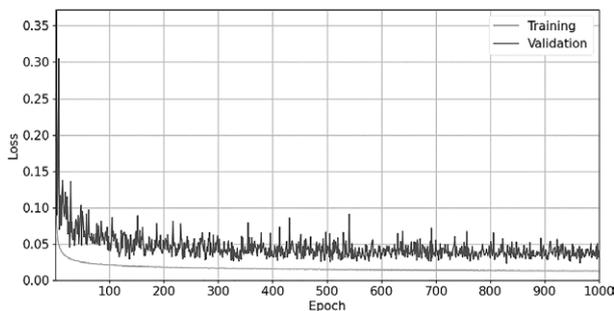
ノーラ A1 の歯科用 CBCT 画像はピクセルサイズが 0.2mm × 0.2mm, スライス厚が 0.2mm, スライス間隔が 0.2mm であり, CS 9600 と PreXion3D Excelsior はピクセルサイズが 0.3mm × 0.3mm, スライス厚が 0.3mm, スライス間隔が 0.3mm である。収集した下顎骨の頬舌断面画像は合計で 8,287 件となり, これらの画像に対して 1 名の歯科放射線科医 (日本歯科放射線学会専門医・指導医・歯科用 CBCT 認定医, 経験年数 40 年) が Aidia を用いてアノテーションを行った。アノテーションでは, 27 インチのモニター EV2750 (EIZO 株式会社, 日本, 石川) 上で断面画像の拡大および明るさ・コントラストの調節を行いながら下顎管の領域を多角形で囲み, “0” のラベルを付与した。

学習は AMD Epyc 7713p (2.0GHz, 64 コア, 128 スレッド, Advanced Micro Devices, Inc., アメリカ合衆国, サンタクララ), 128GB のランダムアクセスメモリ, NVIDIA A6000 (GPU メモリ 48GB, NVIDIA Corporation, アメリカ合衆国, サンタクララ) 2 基を搭載し, Ubuntu をインストールしたコンピュータで行った。学習の設定では, 入力画像のサイズを 256 × 256 ピクセル, 学習回数を 1,000 回, バッチサイズを 8, 学習率を 0.001 とした。データ拡張では, 垂直・水平方向反転を有効, 回転を 20, 拡大・縮小を 0.1, 水平移動を 40, せん断を 4, ガウシアンぼかしを 3, ガウシアンノイズの付加を 15, 明るさ変化を 40, コントラスト変化を 0.1 に設定した。

本研究は徳島大学大学院社会産業理工学研究部の倫理委員会から承認を得た (承認番号: 20002, 課題名: AI を用いた歯科診断システムの研究開発)。また, 本研究では株式会社プレキシオンから PreXion3D Excelsior で撮影した歯科用 CBCT 画像の提供を受けた。

#### 4. 結 果

学習曲線は Figure 6 のようになり, 学習データに対する損失と検証データに対する損失が共に下降していく様子が確認できた。1,000 回の学習を終えた下顎管検出モデルを用いてテストデータに対する評価を行った結果, 適合率



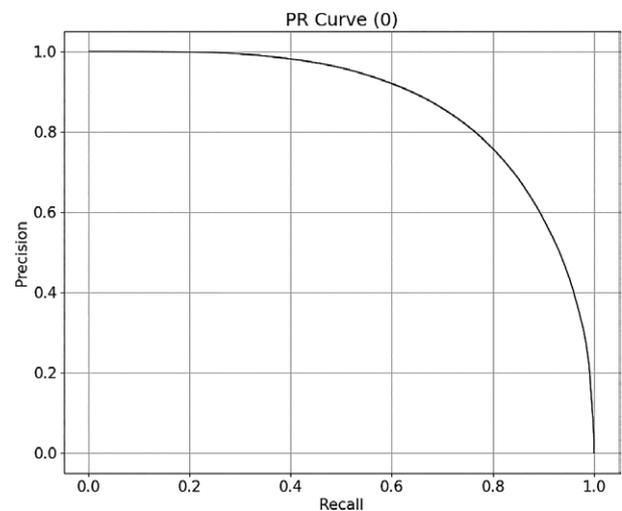
**Figure 6** 下顎管検出モデルの学習曲線  
学習データに対する損失を Training, 検証データに対する損失を Validation としてプロットした。

は 0.805, 感度は 0.752, F 値は 0.777 であった。PR 曲線は Figure 7 のようになり, AP は 0.869 であった。テストデータに含まれる 1 枚の画像を下顎管検出モデルに入力し, 下顎管検出モデルの出力結果を用いて下顎管のセグメンテーションを行った画像は Figure 8 のようになった。また, 下顎管検出モデルを用いてテストデータに対する自動アノテーションを行った結果は Figure 9 のようになった。

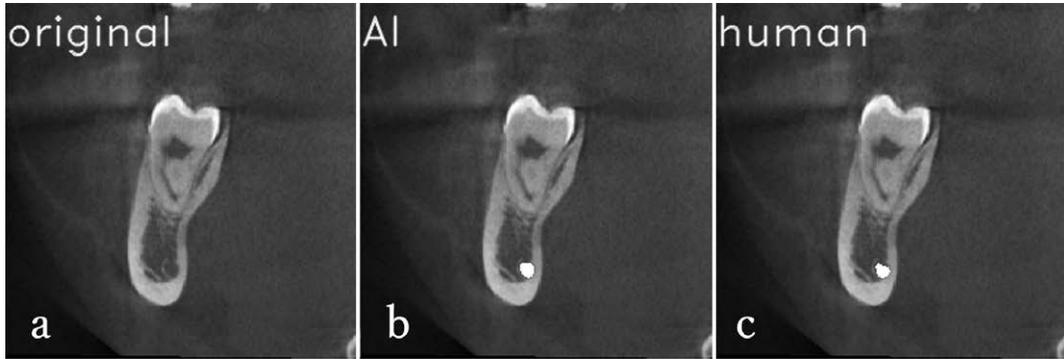
#### 5. 考 察

Aidia は実験において問題なく動作し, ノーコードでアノテーションから AI の開発および評価まで行うことができることを確認した。ただし, GPU の利用には各 OS で設定やドライバなどが必要であり, これらの設定は一般的に敷居が高いため, GPU に関するドキュメントを用意するなど, Aidia 上で GPU の設定支援を行うことを考えている。また, OS によって Aidia のレイアウトが若干崩れる現象を確認しているため, 各 OS に対するより細かなデバッグを行う必要がある。

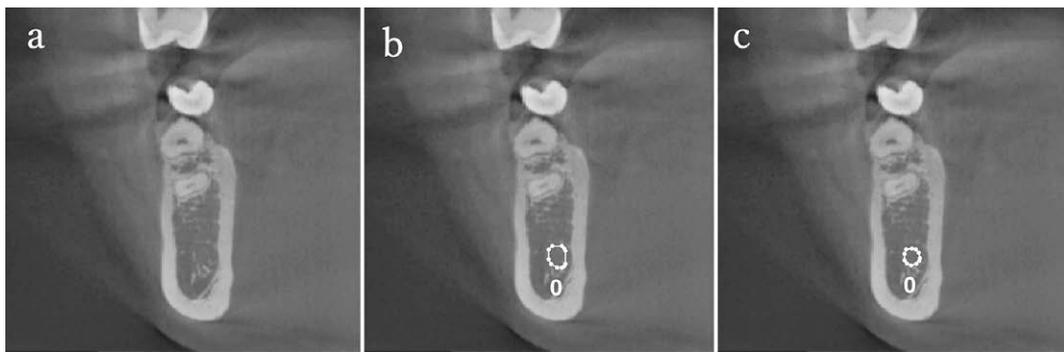
下顎管検出モデルによる自動アノテーションでは, 専門医のアノテーションと同等のアノテーションの生成を確認できた。実験では画像 1 枚に対して 1 つのアノテーションのみであったが, たとえば病理画像の細胞のセグメンテーションなどを行う場合は, 1 枚の画像に対するアノテーション数が非常に多いため, 自動アノテーションによる作業の効率化がより期待できる。また, 本論文における自動アノテーションは AI 開発機能で構築した学習済み AI モデルを用いて行った。したがって, 学習済み AI モデルが存在しない場合は自動アノテーションを行うことができないことが課題である。解決策の一つとして, 各画像に対



**Figure 7** 下顎管検出モデルの PR 曲線  
グラフタイトルの括弧内の “0” はラベルである。



**Figure 8** 下顎管検出モデルによる下顎管のセグメンテーション例  
 (a) 原画像。(b) 下顎管検出モデルによる下顎管のセグメンテーション。下顎管領域を白で描画している。  
 (c) 専門医による下顎管のセグメンテーション。



**Figure 9** 下顎管検出モデルによる自動アノテーションの例  
 (a) 原画像。(b) 自動アノテーションを行った画像。白の多角形が生成されたアノテーションであり、“0”はラベルである。(c) 専門医がアノテーションを行った画像。

して特徴点抽出を行い、アノテーション済みの画像とアノテーションが無い画像の特徴点マッチングを行うことで、同じ特徴をもつ領域に対して自動的にアノテーションを付与する手法が考えられる。Local Feature-based Transformation for 3D Reconstructions (LoFTR)<sup>14</sup> や Deep Kernelized Dense Geometric Matching (DKM)<sup>15</sup> など、近年では特徴点抽出にも AI が用いられており、特徴点マッチングの精度は飛躍的に向上している。これらの手法を応用することで、少数のアノテーション済みの画像を用いて自動アノテーションを行うことが可能になると考えられる。

実験結果より下顎管のセグメンテーションにおける F 値は 0.777 であった。収集したデータには専門医でも下顎管の領域の判断が難しい画像が含まれており、これらの画像に対しては前後の画像から連続性を考慮してアノテーションを行った。構築した AI モデルは単一の画像から推定を行うため、単一画像では下顎管の領域の判断が困難なデータが精度低下の一因となったと考えられる。これらの画像に対しては、前後の画像のセグメンテーション結果を用いた補完処理によるセグメンテーションが有効であると考えられる。また、この補完処理を自動アノテーションにも取り入れることで、より柔軟な自動アノテーションが可

能になると考えられる。

Aidia では F 値や AP などの評価指標を実装した。現状では設定したパラメータや構築した AI モデルに対する評価の比較は自身で行う必要があるため、比較した際の差分を可視化する機能を実装することで、学習に大きな影響を与えるハイパーパラメータの解析や AI モデルの改善状況の把握などに役立つことが期待できる。

今後は、著者らが関わる医用画像 AI に関する共同研究開発で Aidia を運用し、共同研究者らのフィードバックをもとに課題の洗い出しや機能の強化、デバッグなどを行う。また、Aidia のドキュメントの充実化や配布ページの整備などを行い、誰でも気軽に利用できる環境作りを進めていく。

謝 辞

歯科用 CBCT 画像の収集と本研究開発にご協力いただいた同志社大学人工知能工学研究センターの北 研二氏、こばやし歯科クリニックの小林健一郎氏、新井広幸氏、株式会社プレキシオンの今田泰豊氏、富井和仁氏、古月 昇氏に心から感謝申し上げます。

文 献

1. Wada K. Labelme: Image Polygonal Annotation with Py-

- thon [Computer software]. 2016. <https://doi.org/10.5281/zenodo.5711226>
2. Fedorov A, Beichel R, Kalpathy-Cramer J, Finet J, Fillion-Robin J, Pujol S, Bauer C, Jennings D, Fennessy F, Sonka M, Buatti J, Aylward S, Miller J, Pieper S, Kikinis R. 3D Slicer as an Image Computing Platform for the Quantitative Imaging Network. *Magnetic Resonance Imaging*. 2012 ; 30 : 1323-1341.
  3. Ziegler E, Urban T, Brown D, Petts J, Pieper S, Lewis R, Hafey C, Harris G. Open Health Imaging Foundation Viewer: An Extensible Open-Source Framework for Building Web-Based Imaging Applications to Support Cancer Research. *JCO Clinical Cancer Informatics*. 2020 ; 4 : 336-345.
  4. Aljabri M, AlAmir M, AlGhamdi M, Abdel-Mottaleb M, Collado-Mesa F. Towards a better understanding of annotation tools for medical imaging: a survey. *Multimedia Tools and Applications*. 2022 ; 81 : 25877-25911.
  5. 鳥井浩平, 誉田栄一, 北 研二. AIを用いたパノラマ X 線画像からのカルテ入力支援システムの開発. *歯科放射線*. 2022 ; 62 : 24-34.
  6. Bradski G. The opencv library. *Dr. Dobb's Journal: Software Tools for the Professional Programmer*. 2000 ; 25 (11) : 120-123.
  7. Mason DL. pydicom: An open source DICOM library [Computer software]. 2018. <https://github.com/pydicom/pydicom>
  8. Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation. *Proceedings of Medical Image Computing and Computer-Assisted Intervention*. 2015 ; 3 : 234-241.
  9. Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *International conference on machine learning*. 2015 ; 448-456.
  10. Kingma D, Ba J. Adam: A Method for Stochastic Optimization. *The International Conference on Learning Representations*. 2015.
  11. Suzuki S, Abe K. Topological structural analysis of digitized binary images by border following. *Computer Vision, Graphics, and Image Processing*. 1985 ; 30 : 32-46.
  12. Ramer U. An iterative procedure for the polygonal approximation of plane curves. *Computer Graphics and Image Processing*. 1972 ; 1(3) : 244-256.
  13. Douglas D, Peucker T. Algorithms for the reduction of the number of points required to represent a digitized line or its caricature. *The Canadian Cartographer*. 1973 ; 10 : 112-122.
  14. Sun J, Shen Z, Wang Y, Bao H, Zhou X. LoFTR: Detector-Free Local Feature Matching with Transformers. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021 ; 8922-8931.
  15. Edstedt J, Athanasiadis I, Wadenbäck M, Felsberg M. DKM: Dense Kernelized Feature Matching for Geometry Estimation. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2023 ; 1 : 17765-17775.