

歯科用 CT 画像における歯種分類への畳み込みネットワークの応用

村松 千左子

岐阜大学大学院医学系研究科知能イメージ情報分野 〒501-1194 岐阜市柳戸 1-1
(2017年1月6日受付, 2017年3月7日最終受付)

Tooth classification on dental cone-beam CT using deep convolutional neural network

Chisako MURAMATSU

Department of Intelligent Image Information, Graduate School of Medicine, Gifu University
1-1 Yanagido, Gifu, 501-1194, Japan
(Received on January 6, 2017. In final form on March 7, 2017)

Abstract : Forensic identification using dental records is one of the efficient methods in large-scale disasters. In order to facilitate record filing process and to alleviate mental burden of dentists who are generally not used to observing corpses, we are investigating an automated dental record filing method. This paper introduces our recent study on automated classification of tooth types using a deep convolutional neural network.

Keywords : Tooth classification, Dental cone-beam CT, Deep convolutional neural network, Forensic identification

1. はじめに

東日本大震災のような大規模災害時には、遺体の身元確認作業は困難を極める。個人識別の方法には DNA 型や指掌紋、歯科情報によるものなどがあるが、生前情報の入手が比較的容易で、遺体の損傷にも強い歯科的識別は重要な役割を果たしている。こうした中、生前の歯科情報のシステムティックな収集・管理が重要である一方、遺体の検査に不慣れな歯科医師の精神的負担も心配される。

これらの問題に対処するために、歯科 X 線画像を用いた個人識別が提案されており、これを支援する画像解析手法が検討されている。これまでに生前と死後の歯科画像を自動的に照合させる手法[1, 2]や、歯牙を分類または番号付けする手法[3, 4]が提案されている。これらの手法は、1本1本の歯のセグメンテーションを行い、その輪郭をマッチングさせることや、輪郭情報をもとに特徴量を得ることを基本としている。

一方、東北大の青木らは、データ化した生前と死後の歯科情報を利用した、歯科情報照合システムを開発した[5]。このシステムは、各歯の有無や治療状態から、生前と死後で矛盾がないことなどにより、対応ペアである可能性の高いものを検索する。

このような状況を踏まえ、我々は歯科用 CT 画像及び歯科パノラマ X 線画像より、自動的に歯牙領域を検出し、歯種分類を行い、歯牙状態の分類を行うシステムの構築を目指している。その初期検討として、歯科用 CT 画像における歯種分類を行い、畳み込みニューラルネットワーク (Deep Convolutional Neural Network : DCNN) を用いることにより、精密なセグメンテーションを行わずとも、従来法と同等の優れた分類精度が得られることを確認した[6]。

本稿では、我々が開発した DCNN を用いた歯科用 CT 画像上の歯種分類手法について簡単に解説する。

2. 歯種分類手法

2.1 手法の概要

本手法では CT スライス画像より抽出した、各歯牙を含む関心領域 (Region of Interest : ROI) を、中切歯、側切歯、犬歯、第一小臼歯、第二小臼歯、第一大臼歯、第二大臼歯の 7 種に分類する。第三大臼歯はサンプルが少数のため、初期検討では対象外とした。症例を学習サンプルとテストサンプルに分割し、学習サンプルを用いて 7 歯種に分類するよう DCNN を学習させた。

2.2 サンプルの準備

本研究では 2 つの歯科用 CT 装置 (Veraviewepocs 3D : モリタ製作所, Alphard VEGA : 朝日レントゲン工業) で撮影された 52 症例を用いた。本実験ではランダムに選択した 10 症例をテスト症例とし、残りの 42 症例を学習症例とした。歯科用 CT 画像は、一般の医療用 CT 画像と異なり、CT 値が標準化されていないことから、歯の領域が明瞭となるように、手動でウィンドウ幅とウィンドウレベルの調節を行った。初めに、CT ボリューム内に各歯を囲むバウンディングボックスを設定した。ボックスの設定は本手法では手動とした。ボックスを用いて中心部 60% のスライスから ROI を切り出し、分類の対象とした。最終的には症例単位での 3 次元データを用いた処理が好ましいが、初期検討の段階では 3 次元の処理が困難であったこと、また症例数が少数であったことから、スライス単位での実験・評価を行った。切り出した各歯種のサンプル画像とサンプル数を Table 1 に示す。学習サンプルの偏りをなくすために、最小サンプル数に揃えてランダムに選択した ROI を学習に用いた。テスト症例は全 ROI を対象とした。

2.3 DCNN の学習

DCNN のフレームワークは Caffe[7] を用い、ネットワークの構造には、Krizhevsky らにより提案された AlexNet[8] を採用した。ネットワーク構造を Fig.1 に示す。学習 ROI は、初めに 256×256 ピクセルに統一される。リサイズ方

Table 1 各歯種のサンプル画像とサンプル数

	中切歯	側切歯	犬歯	第一小白歯	第二小白歯	第一大臼歯	第二大臼歯
サンプル							
テスト ROI 数	1208	1254	1425	938	401	260	344
全学習 ROI 数	5445	5512	6503	4856	2945	1855	2313
使用学習 ROI 数	1855	1855	1855	1855	1855	1855	1855




Fig.1 応用した AlexNet の構造とパラメータ

法は、NVIDIA 社より提供されている深層学習ツール DIGITS に組み込まれている 4 つの手法より、実験で一番高い性能を得た Fill を用いた。これは、画像を拡大または縮小後余白をランダムノイズで埋める手法である。その後、ネットワークに入力される前に、過学習を抑制するためにランダムに 227×227 ピクセルの領域が切り出される。入力後に畳み込み層とプーリング層を繰り返し、後半の全結合層では、過学習を抑えるためにドロップアウトを採用している。本手法では、ドロップアウト率は 0.5 とした。最終層でソフトマックスによる出力として 7 種に分類される。

一般的に DCNN の学習には大量の学習サンプルが必要とされる。しかし、医用画像は多くの場合入手が困難であることから、データの水増しが行われる。本研究では、画像の回転と、ガンマ変換を用いたコントラスト調整によるデータ拡張を行い、分類精度を比較した。回転角度は -10 から +10 まで 5 度ずつ変化させ、ガンマ変換の γ 値は 1.5 と 0.75 を用いた。拡張後のデータ数を Table 2 に示す。

すべての条件で学習のバッチサイズは 100 とし、学習回数 (全症例を 1 回ずつ学習) は 30 とした。学習レートは 0.01 とし、学習回数 10 回ごとに 1/10 に減少させた。学習には NVIDIA 社製 GeForce GTX TITAN X GPU (Graphics Processing Unit) を使用した。

3. 評価

提案した DCNN を用いた歯種分類の有効性を確認するため、学習させたネットワークにテスト症例を適用し評価を行った。また、データ拡張ありとなしの場合で分類精度の比較を行った。分類精度を Table 2 に示す。

本研究では、初期検討として、ImageNet Large Scale Visual Recognition Challenge 2012[9]で優れた成績を収めた AlexNet を用い、ネットワークのパラメータは最終層以外では変更しなかったが、高い分類精度が得られた。ネットワークの構造やパラメータを検討することで、さらに分類精度を改善できる可能性がある。

Table 2 データ拡張後の学習 ROI 数と分類精度


拡張法	ROI 数	分類精度 (%)
拡張なし	12985	81.9
回転	64925	85.2
コントラスト調整	38955	89.1
回転及びコントラスト調整	194775	91.0

本研究で使用した学習症例は、42 症例と少数であったが、スライス画像を用いることで、各歯種約 1800 枚のサンプルを確保できた。さらに、データ拡張を行うことで、約 9% 分類精度が向上した。本研究では、コントラスト調整によるデータ拡張がより有効であったが、これらの他にも目的に合った拡張方法を模索する必要がある。しかしながら、学習症例数が十分得られている場合は、データ拡張による効果は小さくなることが示唆されている。なお、テスト症例のサンプリングの影響や、入力画像のリサイズ手法の影響については、文献[6]を参照されたい。


Fig.2 に成功例と失敗例を示す。本手法では、主に隣り合う前歯や犬歯、第一・第二小白歯、第一・第二大臼歯をそれぞれ誤って分類することが多かった。これらの対処法としては、学習症例数の追加、スライス結果の統合や隣接歯の情報などを用いた後処理、3次元データを用いた処理などが有効と考えられる。

4. まとめ


本稿では、近年医用画像処理分野で大きな注目を集めている深層学習技術を、我々が開発を目指す、歯科画像における自動歯式ファイリングシステムの一部である、歯科用 CT 画像における歯種分類に適用した例について解説した。評価結果より、DCNN を用いることにより、歯のセグメンテーションを行わなくても、従来の歯の輪郭を基にした手法と同等の高い分類精度が得られることが示唆された。我々は歯の検出や状態分類、また歯科パノラマ X 線画像においても DCNN の応用検討を行っており、期待される




正解: 犬歯
分類結果: 犬歯



正解: 第一大臼歯
分類結果: 第一大臼歯



正解: 側切歯
分類結果: 犬歯



正解: 第一大臼歯
分類結果: 第二大臼歯

Fig.2 提案手法による分類結果例

結果が得られている。今後は全自動化やネットワーク構造の最適化、後処理の検討などを行っていく予定である。

謝 辞

本研究は岐阜大学知能イメージ情報分野，朝日大学歯科放射線学分野，愛知学院大学歯科放射線学講座，メディア株式会社の共同研究で行われました。本研究の一部は，文部科学省科学研究費補助金新学術領域研究（26108005）及び基盤 B（26293402）により行われました。

参考文献

- [1] Jain AK and Chen H: Matching of dental X-ray images for human identification, *Pattern Recognit.*, 37(7), 1519-1532, 2004.
- [2] Zhou J and Abdel-Mottaleb M: A content-based system for human identification based on bitewing dental X-ray images, *Pattern Recognit.*, 38(11), 2132-2142, 2005.
- [3] Lin PI, Lai YH and Huang PW: An effective classification and numbering system for dental bitewing radiographs using teeth region and contour information, *Pattern Recognit.*, 43(4), 1380-1392, 2010.
- [4] Hosntalab M, Zoroofi RA, Tehrani-Fard AA, et al.: Classification and numbering of teeth in multi-slice CT images using wavelet-Fourier descriptor, *Int. J CARS*, 5(3), 237-249, 2010.
- [5] 青木孝文, 伊藤康一, 青山章一郎: 災害犠牲者の身元確認と ICT, *IEICE Fundamentals Review*, 9(2), 119-130, 2015.
- [6] Miki Y, Muramatsu C, Hayashi T, et al.: Classification of teeth in cone-beam CT using deep convolutional neural network, *Comput. Bio. Med.*, 80, 24-29, 2017.
- [7] Jia Y, Shelhamer E, Donahue J, et al.: Caffe: Convolution architecture for fast feature embedding, *arXiv*, 1408.5093, 2014.
- [8] Krizhevsky A, Sutskever I and Hinton GE: ImageNet classification with deep convolutional neural networks, in: *Advances in Neural Information Processing Systems*, (NIPS 2012), 25, 1106-1114, 2012.
- [9] Russakovsky O, Deng J, Su H, et al.: ImageNet large scale visual recognition challenge, *Int. J Comput. Vis.*, 115(3), 211-252, 2015.