

学位論文の全文に代えてその内容を要約したもの

愛知学院大学

甲 第 797 号	論文提出者 西山雅子
論文題目  異なる2施設のパノラマX線画像によって構築した 関節突起骨折診断のための深層学習モデル	

## I. 緒言

パノラマ X 線画像は顎骨を総覧的に観察することに優れた撮影法であり、顎口腔領域の診断を行う上で日常的に使用される。しかし複数の組織が重複することが多いことや、断層域から外れた部位では歪みが生じ、読影が困難となることもある<sup>1,2)</sup>。顎関節領域はその様な領域の一つであり、特に経験の浅い歯科医師にとってパノラマ X 線画像のみで関節突起骨折を診断することは必ずしも容易ではない<sup>3)</sup>。下顎頭周囲の構造には関節結節や頭蓋底があり、それらの陰影が骨折線と重複し関節突起骨折の診断の妨げとなる可能性がある。また下顎枝は気道と重複して描出され、軟組織との境界が骨折線のように見える場合もある。さらにパノラマ X 線画像撮影では、X 線は下顎頭の長軸方向に対して平行に入射する。そのため縦骨折では骨折線の描出は非常に困難であり、このような場合パノラマ X 線画像のみで骨折を診断することは極めて難しい<sup>4,5)</sup>。

近年、医療分野においても畳込みニューラルネットワーク (CNN: convolutional neural network) を用いた深層学習 (DL: deep learning) の応用は高い関心を集めている。DL には画像分類や物体検出、セグメンテーション、超解像処理などの技術があるが、画像分類と物体検出は画像診断の分野で多く使用されており、これらの技術に基づく診断支援あるいは病変検出支援 (CAD: computer-aided-diagnosis/detection) システムの有用性は様々な疾患で報告されている<sup>2,6-9)</sup>。パノラマ X 線画像の診断に DL モデルを応用した研究がいくつかの疾患に関してなされているが、関節突起骨折に関する報告はこれまでにない。

製品化可能な汎用性のある画像診断のための DL モデルを開発するには、一般的に 10 万から 100 万単位の訓練用画像が必要であり、特に病態が多様な疾患の場合には訓練用画像の数が重要とされる<sup>10)</sup>。一方で、特定の疾患や集団を対象にした場合は、数百単位の訓練用画像でも一定の診断能を有した DL モデルが作成できるという報告もある<sup>11)</sup>。パノラマ X 線画像を用いて行われた多くの研究では、数百から数千枚の画像を用いて DL モデルが構築されているが<sup>10)</sup>、ほとんどの研究で訓練用画像およびテスト画像を同一施設から収集しており、高い診断能が報告されている<sup>2,6-9,12-16)</sup>。一方で訓練用画像とは異なる施設のテスト画像を使用した外部検証に関する報告は未だ十分ではない。外部検証においては“ドメインシフト”と呼ばれる現象が生じることが知られている。ドメインシフトとは、集団の特徴の違いに起因するもので、訓練用画像とテスト画像の母集団が異なる場合に引き起こされる現象である<sup>10)</sup>。多くの場合、外部データを使用した検証では診断能は低下すると考えられている。

DL モデルによる診断支援を実際の診療において行うことを想定した場合には、DL モデルの汎用化に関する外部検証の問題は重要な課題である。しかし、パノラマ X 線画像に関する外部検証の報告は我々の知る限りまだなされていない。

本研究の目的は、2 施設から得られたパノラマ X 線画像を用いて下顎骨関節突起骨折の診断のための DL システムを構築し、特に外部検証と内部検証の比較を中心に診断能を検証することとした。

## II. 対象および方法

本研究はヘルシンキ宣言に則り、愛知学院大学歯学部倫理委員会 (承認番号: 586) および大垣市民病院倫理委員会 (承認番号: 20200423-13) の承認を得て行った。

## 1. 対象

対象は愛知学院大学歯学部附属病院（病院 A）と大垣市民病院（病院 B）において、パノラマ X 線および CT 検査を行った 16 歳以上の患者とした。いずれの病院においても 2019 年 10 月から遡って、CT で関節突起骨折を認めた 100 症例の顎関節をそれぞれ連続的に抽出した。パノラマ X 線および CT 検査は受傷から 1 ヶ月以内に実施されたものを対象とした。病院 A では 78 人の 100 顎関節、病院 B では 77 人の 100 顎関節が抽出された。これらを骨折群とした。

関節突起骨折の部位に関しては Lindahl による分類<sup>17)</sup>を改変して使用した。下顎枝後縁に接線を引き、骨折線の高さにより下顎頭部、上顎部、下顎部、基底部の 4 部位に分類した<sup>18)</sup>。下顎頭部は下顎頭頂から翼突筋窩までの領域、顎部では頭側を上顎部と尾側を下顎部に分類した。下顎切痕の高さから咬筋粗面までを基底部とした。

骨折の程度については Maclennan の分類<sup>19)</sup>を改変し、5 段階に分類した。骨片の偏位がないものを亀裂、骨片の偏位はあるが関節窩内に止まっており、骨片同士が一部で接触したものを偏位、接触がないものを転位とした。さらに小骨片が関節窩から逸脱したものは脱臼とした。偏位脱臼として骨片が一部で接触しているが、小骨片が関節窩から逸脱したものの、転位脱臼として骨片同士の接触がなく、かつ関節窩から小骨片が逸脱したものを分類した。

対照として、パノラマ X 線および CT 検査を行い、関節突起骨折のない 50 人の 100 顎関節をそれぞれの病院において 2019 年 10 月から遡って連続的に抽出した。これらは骨折なし群として、顎関節に自覚症状がない症例で、CT 上で骨折がなく、下顎頭に骨変形がみられないことを確認した。骨折なし群は、智歯周囲炎、第三大臼歯の抜歯、嚢胞、良性腫瘍、上顎洞病変などの診断を目的として検査を行ったものであった。また、16 歳未満の患者は除外した。

パノラマ X 線撮影は、病院 A では主に Veraview epocs（モリタ製作所、京都）を用いて実施した（193 顎関節）。撮影条件は管電圧 75 kV、管電流 8 mA、照射時間 16.2 秒であった。残りの 7 顎関節は AUTOIII（朝日レントゲン、京都）を用いて撮影された。撮影条件は管電圧 75 kV、管電流 12 mA、照射時間 12 秒であった。病院 B では 200 例全てで AUTOIII（朝日レントゲン、京都）を用いて撮影を行った。撮影条件は管電圧 75 kV、管電流 12 mA、照射時間 12 秒であった。

## 2. 画像パッチの準備

パノラマ X 線画像はそれぞれの病院のデータベースから 900×900 ピクセルの JPEG 形式でダウンロードした。パノラマ X 線画像から顎関節部を任意の大きさの矩形領域で切り出した。切り出しには Photoshop CS6（Adobe Systems Co., Ltd., CA）を使用した。

切り出し範囲の上端は関節窩の最深部に、下端は咬合平面に設定したが、無歯顎の場合は下顎枝の 1/2 の高さに設定した。近心端は下顎切痕、遠心端は関節窩の後端に一致させて矩形領域の設定を行った。病院ごとに 200 の顎関節画像パッチを切り出した。

## 3. DL システムの構築

今回使用した DL システムは Ubuntu OS version 16.04.2 を動作システムとして、11GB の GPU（NVIDIA GeForce GTX 1080 Ti）および 128GB のメモリを有するワークステーションに構築された。学習過程は Caffe フレームワークで行った。ネットワークは DIGITS library version 5.0（NDIVIA, Santa Clara, CA; <https://developer.nvidia.com/digits>) 上に公開されている

AlexNet および VGG-16 の 2 つを用いた。AlexNet は 5 層の畳み込み層と 3 つの全結合層をもつ CNN で、比較的シンプルな構造である<sup>20)</sup>。VGG-16 は畳み込み層およびプーリング層を 13 層、フル結合層を 3 層もつ 16 層構造であり、100 万枚を超える自然画像で学習させた事前学習済みモデルとして公開されている<sup>21)</sup>。今回の研究では、この 2 つのネットワークを使用して作成した DL モデルの結果を比較した。

#### 4. DL モデルの作成と評価

5 分割交差検証の手法を応用して、DL モデルを作成し、評価した。DL モデルの作成にはそれぞれ 200 エポックの学習を実施した。

##### 1) 内部検証

病院 A の画像 200 枚を Aa、Ab、Ac、Ad、Ae の 5 グループに分割し、それぞれのグループが骨折群 20、骨折なし群 20 の計 40 画像パッチになるように無作為に割付けた。Fold 1 では Ab、Ac、Ad、Ae の 160 の画像パッチを使用して DL モデルを作成し、作成されたモデルを Model A 1 とした。160 のうち 130 を訓練用データ、30 を検証用データとして使用した。130 の訓練用画像パッチに対してデータ拡張を実施し、130 の画像パッチを 2340 パッチに増幅した。データ拡張には Irfan View (Irfan View Version 4.44; <http://www.Irfanview.com>) を使用した。作成した Model A 1 に対して、テストデータとして Aa を用いて評価を行った。Fold 2 では Aa、Ac、Ad、Ae を訓練・検証用データとして使用し、Ab をテストデータとして使用した。この過程を訓練用データとテストデータのデータセットを入れ替えながら 5 回繰り返した。病院 B の内部検証も同様の手法で行った。

##### 2) 外部検証

DL モデルには内部検証で使用した Model A 1 ~ 5、Model B 1 ~ 5 をそれぞれ使用した。テストデータとして、訓練用データとは異なる病院の画像で作成されたデータセットを使用した。具体的には、病院 A の画像で作成された Model A 1 に対して病院 B の画像で作成された Ba をテストデータとして使用した。Model B 1 に対しては病院 A の画像で作成された Aa をテストデータとして適用した。

##### 3) 2 施設の画像を使用した DL モデルの作成と評価

2 施設の訓練用画像を統合した DL モデルを作成した。ここでは作成されたモデルを Model AB としたが、このモデルの作成には合計 320 の画像パッチを用いた。テストデータには病院 A、病院 B のそれぞれの画像パッチで作成されたデータセットを使用した。

##### 4) 診断能の評価

作成された DL モデルにテストデータを適用すると 1 枚の画像ごとに ground truth (真の値: ここでは骨折の有無) に対する可能性 probability として 0~100% の値が提示される。骨折がある場合の probability は true positive fraction (感度) に相当し、骨折がない場合の probability は false-positive fraction (1-特異度) に相当する。この値を用いて、200 のテ

ストデータの結果から DL モデルごとの ROC 曲線 (Receiver Operating Characteristic Curve) を描記した。ROC 曲線下の面積 (AUC: Area Under the Curve) を算出し結果を比較した。また ROC 曲線のグラフで座標の左上に最も近い点をカットオフ値として、感度、特異度、正診率を求めた<sup>6)</sup>。

## 5. 統計解析

2 病院間および骨折群と骨折なし群の間の年齢の差の検定には t 検定を用いた。AUC、男女比および骨折の部位および程度の分布の差の検定には  $\chi^2$  検定を用いた。p<0.05 を統計学的に有意とした。

## Ⅲ. 結果

病院 A と病院 B の骨折群と骨折なし群の男女比に有意差はなかった。骨折の部位 (p=0.026) および骨折の程度の分布 (p=0.041) では病院 A と病院 B の間で有意差を認めた。病院 A では上頸部骨折が多く、病院 B では下頸部骨折が多くみられた。また、病院 A では偏位や転位といった脱臼を伴わない症例が多かったが、病院 B では過半数が脱臼を伴う骨折であった。

AlexNet では、テストデータと訓練・検証用データとが同施設の場合 (内部検証)、AUC は Model A で 0.85、Model B では 0.86 であり、高い診断能を示した。一方で異なる施設の画像をテストデータとした場合 (外部検証) では AUC は Model A、Model B とともに 0.58 であり、同施設の結果 (内部検証) と比較して有意に低い値を示した。(p<0.05) Model AB では内部検証の結果と比べ、有意差はないものの AUC はわずかに高い値を示した。

VGG-16 では、内部検証では、Model A の AUC は 0.88、Model B では 0.98 とさらに高い診断能を示した。一方、外部検証では AUC が 0.60、0.51 と内部検証と比較して有意に低い値を示した。Model AB の AUC は 0.91、0.98 であった。Model A および Model B の内部検証と比較して同等もしくはわずかに高い値を示したが有意差は認められなかった。

AlexNet と VGG-16 を比較すると、いずれのネットワークにおいても内部検証では診断能は高く、外部検証では低くなるという同様の傾向がみられた。また、VGG-16 では Model B および Model AB にテストデータとして病院 B の画像を使用すると、特に高い診断能を示した。両モデルとも AUC は 0.98、正診率は 94.5% であった。AlexNet による Model B (p < 0.001) および Model AB (p = 0.030) と比較して AUC に有意差を認めた。

外部データで作成された DL モデルで関節突起骨折を検出できなかった症例は AlexNet を使用した場合、病院 A の症例で 24 例、病院 B の症例で 25 例であった。VGG-16 では病院 A の症例で 34 例、病院 B の症例では 31 例で骨折を検出できなかった。

## Ⅳ. 考察

訓練・検証用データとテストデータが同施設から収集された場合 (内部検証) の結果を見ると、AlexNet を使用した場合には、Model A、Model B とともに AUC は 0.85 を超えていた。また VGG-16

では Model A で 0.88、Model B で 0.98 と高い AUC を示した。これらは他の疾患のパノラマ X 線画像に DL システムを応用した過去の報告<sup>2,7-9)</sup>と比較しても遜色ない結果であった。従って、内部検証から見る限り、関節突起骨折の診断において、DL システムは十分な診断能を有していると考えられた。

両病院のデータによって作成した DL モデル (Model AB) では、単独の病院のデータで作成したモデル (Model A および Model B) の内部検証に比べ、同等もしくはわずかに高い値を示したが有意差は見られなかった。これは訓練用データとして 2 施設分の画像を使用したことで学習量が増加し、わずかに診断能が向上したものと考えられる。

今回の研究においては、訓練・検証用データに他施設の画像を含めても診断能の低下は見られなかった。一般的に提供されている DL モデルや他施設で作成された DL モデル (以下、外部モデルとする) を利用する際に、自施設のデータセットを用いて再学習させるなどの調整を行うことで、診断能が向上する可能性があることを示唆している。

我々が知る限り、パノラマ X 線画像を用いた DL システムの外部検証に関する報告は本研究が初めてである。Lee ら<sup>22)</sup>は 3 つの病院から 7000 枚のパノラマ X 線画像を収集して DL モデルの構築を行ったが、本研究における外部検証に相当する評価は行っていない。

本研究では、外部の画像をテストデータとした場合の診断能は有意に低いという結果を示した。これはドメインシフトと呼ばれる現象に起因していると考えられる。外部モデルを使用する場合にはこの問題を考慮する必要がある。CT<sup>23)</sup>、MRI<sup>24)</sup>、胸部単純 X 線画像<sup>25)</sup>やウォーターズ法 X 線画像<sup>26)</sup>などを用いて外部検証を行った報告では、内部検証と比較して外部の画像をテストした場合には診断能はわずかに低下することが明らかになっている。Kim ら<sup>26)</sup>はウォーターズ法を用いた上顎洞炎の診断において 2 つのデータセットを用いた診断能を比較している。内部検証として訓練用データとは別期間に撮影された同施設のデータセットでは AUC が 0.93、外部施設のデータセットでは 0.88 の AUC を示した。この研究では、8 万枚もの訓練用画像を使用していたため、外部検証でも比較的高い診断能を保つことが可能であったと考えられる。本研究における外部検証の結果は、AlexNet を使用した場合の AUC が 0.58、VGG-16 を使用した場合では 0.51 および 0.60 といずれも低い値を示した。これは今回の研究に使用した症例の少なさが要因の一つであると考えられる。

次に使用した両ネットワークの比較をすると、AlexNet、VGG-16 どちらのネットワークも、内部検証と比較して外部検証では診断能が有意に低下し、類似した傾向が見られた。しかし VGG-16 を使用して病院 B のデータを含む訓練および検証用データで作成した Model B および Model AB では、AlexNet を使用した同様の DL モデルに比較して有意に高い AUC を示した。VGG-16 は事前学習済みのネットワークであることが診断能の向上をもたらした原因かもしれない。事前学習済みのネットワークや DL モデルを利用して独自のデータセットで再学習することを転移学習という。今回使用した VGG-16 では事前に 100 万枚を超える自然画像で学習が行なわれているため、訓練用データが少ない場合でも効率的に学習を行うことができるという利点があるとされる<sup>27)</sup>。一方で Model A の外部検証においては AlexNet と VGG-16 で同等の低い結果を示しており、必ずしも事前学習済みモデルの診断能が高いとは言えない。今回の結果では事前学習済みモデルを使用した結果にはばらつきがあることが明らかになった。そのため、事前学習済みモデルの使用に関してはさらなる検証が必要であると考えられる。

2施設の診断能を比較するにあたって、施設間のデータの特徴に違いがあることも考慮する必要がある。病院Aと病院Bの間には年齢や使用した装置など複数の違いがあった。なかでも骨折の状態の差はDLモデルの学習過程において大きく影響するものと考え、骨折の部位および程度の違いについて分析を行った。

病院Aでは上顎部骨折が多く、病院Bでは下顎部骨折が多くみられた。また骨折の程度に関しては病院Aでは脱臼を伴わない偏位や転位が多く、病院Bでは脱臼を伴う症例が半数近くで観察された。DLシステムではどのような特徴を学習して診断を行なっているか一般的には明らかにされることはない。しかしModel Aでは比較的偏位の少ない関節突起骨折を多く学習しているため、脱臼症例の診断が困難になることが予想された。一方でModel Bでは脱臼を伴わない偏位の少ない関節突起骨折の学習が比較的少なかったと言える。具体的な症例を見てみると、病院Aの画像でAlexNetを使用した場合に診断できなかった症例では関節窩内に何らかの陰影があり、あたかも関節突起のように見える画像が複数認められた。VGG-16においては小骨片と大骨片が重複し、下顎頭が二重に見える画像が複数みられた。また、病院BでAlexNetを使用した場合に診断できなかった症例では小骨片が垂直的に偏位しており、関節突起の形態を保っているように見える症例が複数あった。VGG-16では小骨片と大骨片が一部で重複し、骨棘様に見える症例があった。これらは、正しく診断できなかった症例の一部ではあるものの、関節突起骨折には様々なバリエーションがあり<sup>18)</sup>、少ない症例数で学習を行う際には注意が必要であることを示唆している。骨折の部位や状態に差が見られたのは病院の特徴の違い、つまり病院Aは大学歯学部附属の教育病院であり、病院Bは救急外来を有する総合病院である点が影響しているかもしれない。またネットワークによって診断の傾向は類似しているものの、診断に使用した特徴的な所見は異なっている可能性も考えられる。

本研究に使用した症例数は少なく、データの収集も2施設のみであることから、今回の結果を一般化することは難しい。一般的に、どの施設でも使用できるような汎用性をもつDLモデルの作成には数十万から数百万枚程度の訓練用データが必要であると言われている<sup>10)</sup>。そのため、インターネット上に公開されているデータベース<sup>10)</sup>を利用することができれば、この問題は解決できる。しかし、パノラマX線画像においてはこのようなデータベースは存在しない。複数施設から多くの症例を集めることは、個人情報保護の問題や法的な規制により、実質的に困難である。近年、このような問題を解決するためにFederated Learning<sup>10)</sup>という新しい手法が研究されている。Federated Learningシステムは2017年にGoogle社が提唱<sup>28)</sup>したもので、訓練用画像や患者情報を共有せずにそれぞれの施設内で作成されたDLモデルのみを収集して統合する手法である。ディープラーニングによる診断支援を臨床的に応用するためには、DLモデルの性能は十分に評価されなくてはならない。そのためには内部検証のみならず、他の施設から収集した画像を評価する場合の診断能が保たれていることを注意深く観察する必要がある。本研究はパノラマX線画像における外部検証を行った最初の研究であり、今後さらなる検証が求められる。

さらに、この研究では観察者との比較を行っていない。人工知能が進化して高い診断能を持ったとしても、現時点では最終的な診断の責任は医師、歯科医師にあり、CADシステムの目的は診断の補助に過ぎないとされている<sup>29)</sup>。そのため今回の結果を踏まえて、診断医との比較や診断補助としての有用性を検証する研究を行う必要がある。

## V. 結 論

パノラマ X 線画像を用いた関節突起骨折診断のための DL システムの内部検証において 0.85 を超える AUC を示したことから、DL モデルの有用性が示唆された。しかし、訓練用画像を提供した施設とは異なる施設で DL モデルを使用する場合には診断能が低下することが明らかとなった。外部の施設で作成された DL システムを用いて診断支援を行う場合には注意が必要であることが示唆された。

## 謝 辞

本稿を終えるにあたり、終始御懇篤なる御指導と御高閲を賜りました愛知学院大学歯学部歯科放射線学講座 有地榮一郎教授に謹んで深甚なる感謝の意を表すとともに、御高閲を賜りました口腔衛生学講座 嶋崎義浩教授ならびに顎顔面外科学講座 長尾徹教授に深謝致します。また、本研究の遂行に際し、御助言、御協力いただきました歯科放射線学講座 有地淑子准教授をはじめ、愛知学院大学歯学部歯科放射線学講座教室員各位、ならびに愛知学院大学歯学部附属病院放射線技術部診療放射線技師諸氏に深く感謝いたします。

## 文 献

- 1) Damante JH, Filho LI, Silva MA. Radiographic image of the hard palate and nasal fossa floor in panoramic radiography. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod*, 85(4): 479-484, 1998.
- 2) Murata M, Ariji Y, Ohashi Y, Kawai T, Fukuda M, Funakoshi T, Kise Y, Nozawa M, Katsumata A, Fujita H, Ariji E. Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. *Oral Radiol*, 35(3): 301-307, 2019.
- 3) Chacon GE, Dawson KH, Myall RW, Beirne OR. A comparative study of 2 imaging techniques for the diagnosis of condylar fractures in children. *J Oral Maxillofac Surg*, 61(6): 668-672, 2003.
- 4) Nardi C, Vignoli C, Pietragalla M, Tonelli P, Calistri L, Franchi L, Preda L, Colagrande S. Imaging of mandibular fractures: a pictorial review. *Insights Imaging*, 11(1): 30, 2020.
- 5) Yamaoka M, Furusawa K, Iguchi K, Tanaka M, Okuda D. The assessment of fracture of the mandibular condyle by use of computerized tomography. Incidence of sagittal split fracture. *Br J Oral Maxillofac Surg*, 32(2): 77-9, 1994.
- 6) Fukuda M, Ariji Y, Kise Y, Nozawa M, Kuwada C, Funakoshi T, Muramatsu C, Fujita H, Katsumata A, Ariji E. Comparison of 3 deep learning neural networks for classifying the relationship between the mandibular third molar and the mandibular canal on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol*, 130(3): 336-343, 2020.
- 7) Hiraiwa T, Ariji Y, Fukuda M, Kise Y, Nakata K, Katsumata A, Fujita H, Ariji E. A deep-learning artificial intelligence system for assessment of root morphology of



- the mandibular first molar on panoramic radiography. *Dentomaxillofac Radiol*, 48(3): 20180218, 2019.
- 8) Ekert T, Krois J, Meinhold L, Elhennawy K, Emara R, Golla T, Schwendicke F. Deep Learning for the Radiographic Detection of Apical Lesions. *J Endod*, 45(7): 917-922, 2019.
- 9) Lee JH, Kim DH, Jeong SN. Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network. *Oral Dis*, 26(1): 152-158, 2020.
- 10) Willemink MJ, Koszek WA, Hardell C, Wu J, Fleischmann D, Harvey H, Folio LR, Summers RM, Rubin DL, Lungren MP. Preparing Medical Imaging Data for Machine Learning. *Radiology*. 295(1): 4-15, 2020.
- 11) Chang K, Balachandar N, Lam C, Yi D, Brown J, Beers A, Rosen B, Rubin DL, Kalpathy-Cramer J. Distributed deep learning networks among institutions for medical imaging. *J Am Med Inform Assoc*, 25(8): 945-954, 2018.
- 12) Kuwana R, Ariji Y, Fukuda M, Kise Y, Nozawa M, Kuwada C, Muramatsu C, Katsumata A, Fujita H, Ariji E. Performance of deep learning object detection technology in the detection and diagnosis of maxillary sinus lesions on panoramic radiographs. *Dentomaxillofac Radiol*, 50(1): 20200171, 2021.
- 13) Watanabe H, Ariji Y, Fukuda M, Kuwada C, Kise Y, Nozawa M, Sugita Y, Ariji E. Deep learning object detection of maxillary cyst-like lesions on panoramic radiographs: preliminary study. *Oral Radiol*, doi: 10.1007/s11282-020-00485-4. 2020.
- 14) Ariji Y, Yanashita Y, Kutsuna S, Muramatsu C, Fukuda M, Kise Y, Nozawa M, Kuwada C, Fujita H, Katsumata A, Ariji E. Automatic detection and classification of radiolucent lesions in the mandible on panoramic radiographs using a deep learning object detection technique. *Oral Surg Oral Med Oral Pathol Oral Radiol*, 128(4): 424-430, 2019.
- 15) Fukuda M, Inamoto K, Shibata N, Ariji Y, Yanashita Y, Kutsuna S, Nakata K, Katsumata A, Fujita H, Ariji E. Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral Radiol*, 36(4): 337-343. 2020.
- 16) Kuwada C, Ariji Y, Fukuda M, Kise Y, Fujita H, Katsumata A, Ariji E. Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol*, 130(4): 464-469, 2020.
- 17) Lindahl L. Condylar fractures of the mandible. I. Classification and relation to age, occlusion, and concomitant injuries of teeth and teeth-supporting structures, and fractures of the mandibular body. *Int J Oral Surg*, 6(3): 12-21, 1977.
- 18) 菅野貴浩: 下顎頭骨折(関節突起), 公益社団法人 日本口腔外科学会/日本口腔顎顔面外傷学会編, 口腔顎顔面外傷 診療ガイドライン 2015年改訂版 第II部, 19-23, 2015.

(学位論文の内容を要約したもの)

No. 9

愛知学院大学

- 1 9) MacLennan WD. Consideration of 180 cases of typical fractures of the mandibular condylar process. *Br J Plast Surg*, 5(2): 122-128, 1952.
- 2 0) Alex K, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems 25 (NIPS 2012)*, NIPS, Lake Tahoe, UT. pp.1097-1105, 2012.
- 2 1) Karen S, Zisserman A. Very deep convolutional networks for large-scale image recognition. *Proceedings of the 2015 3rd IAPR Asian Conference on Pattern Recognition (ACPR)*, ICLR, Kuala Lumpur, Malaysia. pp.730-734, 2015.
- 2 2) Lee JH, Kim YT, Lee JB, Jeong SN. A performance comparison between automated deep learning and dental professionals in classification of dental implant systems from dental imaging: a multi-center study. *Diagnostics*, 10(11): 910, 2020.
- 2 3) Kann BH, Hicks DF, Payabvash S, Mahajan A, Du J, Gupta V, Park HS, Yu JB, Yarbrough WG, Burtness BA, Husain ZA, Aneja S. Multi-institutional validation of deep learning for pretreatment identification of extranodal extension in head and neck squamous cell carcinoma. *J Clin Oncol*, 38(12): 1304-1311, 2020.
- 2 4) Bien N, Rajpurkar P, Ball RL, Irvin J, Park A, Jones E, Bereket M, Patel BN, Yeom KW, Shpanskaya K, Halabi S, Zucker E, Fanton G, Amanatullah DF, Beaulieu CF, Riley GM, Stewart RJ, Blankenberg FG, Larson DB, Jones RH, Langlotz CP, Ng AY, Lungren MP. Deep-learning-assisted diagnosis for knee magnetic resonance imaging: Development and retrospective validation of MRNet. *PLoS Med*, 15(11): e1002699, 2018.
- 2 5) Zech JR, Badgeley MA, Liu M, Costa AB, Titano JJ, Oermann EK. Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: a cross-sectional study. *PLoS Med*, 15(11): e1002683, 2018.
- 2 6) Kim Y, Lee KJ, Sunwoo L, Choi D, Nam CM, Cho J, Kim J, Bae YJ, Yoo RE, Choi BS, Jung C, Kim JH. Deep Learning in Diagnosis of Maxillary Sinusitis Using Conventional Radiography. *Invest Radiol*, 54(1): 7-15, 2019.
- 2 7) 寺本篤司:ディープラーニング, 藤田広志編, 医用画像ディープラーニング入門 1版, 株式会社オーム社(東京), 33-34, 2019.
- 2 8) McMahan B, Ramage D. Federated learning: Collaborative machine learning without centralized training data. *Google AI Blog*, <https://ai.googleblog.com/2017/04/federated-learning-collaborative.html> Published 2017. Accessed March 2021.
- 2 9) 藤田広志:診断を支援する, 藤田広志編, 医用画像ディープラーニング入門 1版, 株式会社オーム社(東京), 118-132, 2019.