

令和 5 年 6 月 19 日現在

機関番号：33111

研究種目：若手研究

研究期間：2020～2022

課題番号：20K20233

研究課題名（和文）虚血性心疾患画像診断支援のための深層畳み込みニューラルネットワークの開発

研究課題名（英文）Development of Deep Convolutional Neural Network for Computer-Aided Diagnosis of Ischemic Heart Disease

研究代表者

長谷川 晃（Hasegawa, Akira）

新潟医療福祉大学・医療技術学部・講師

研究者番号：20749999

交付決定額（研究期間全体）：（直接経費） 3,200,000円

研究成果の概要（和文）：冠動脈CTにおける陽性的中率の低下の要因となる石灰化プラークを正しく認識できるよう、深層学習で類似所見のステントとの自動分類を実施した。その結果、VGG-16から畳み込み層を6層、全結合層を1層増やしたVGG-23でのファインチューニングによる自動分類の精度が最も高く、正診率98.0%となった。また、低吸収プラークを含むプラークの自動分類では、低吸収プラークを正しく認識できなかった。そこで、領域の自動抽出が可能なU-Netを用いて低吸収プラーク領域を自動抽出したところ、Dice係数が0.91で高い精度で領域抽出できた。

研究成果の学術的意義や社会的意義

本研究の結果は、深層学習による冠動脈CTでの虚血性心疾患の診断支援の要素技術となる。特に冠動脈CTで陽性的中率が下がる原因となる石灰化プラークを深層学習が正しく認識できることが期待でき、陽性的中率の改善が期待される。また、低吸収プラークの領域も正しく抽出することができたため、今後はプラークを自動認識するだけでなく狭窄率も正確に自動分析することが期待される。冠動脈CTにおける虚血性心疾患の診断支援技術の普及により、さらに迅速かつ正確な診断が期待される。

研究成果の概要（英文）：In order to correctly recognize calcified plaques, which are the cause of low positive predictive value in coronary CT, automatic classification with stents with similar findings of calcified plaques was performed using deep learning. The results showed that VGG-23, which has 6 more convolution layers and 1 more full-connect layer than VGG-16, had the highest accuracy in automatic classification by fine tuning, resulting in an accuracy of 98.0%. In the automatic classification of plaques including low-absorption plaques, low-absorption plaques were not correctly recognized. Therefore, low absorption plaque regions were automatically extracted using U-Net, which can automatically extract regions, and the Dice coefficient was 0.91, indicating that the regions were extracted with high accuracy.

研究分野：放射線技術学

キーワード：虚血性心疾患 深層学習 冠動脈CT プラーク 自動分類 領域抽出

1. 研究開始当初の背景

心疾患は日本人の死亡原因で第2位となっており、2018年では年間20万人余りが亡くなっている1)。このうち約7万人が急性心筋梗塞や狭心症などの虚血性心疾患で死亡している。心筋梗塞は心臓の筋肉に血液を送る冠動脈が完全に塞がり血液が流れなくなった状態、狭心症は冠動脈が狭くなった状態(狭窄)である。これらの虚血性心疾患は主に動脈硬化に起因する。動脈硬化が進むと冠動脈の血管内膜にコレステロールが蓄積し、次第に脂肪分が沈着しプラーク化することで狭窄の原因となる。したがって冠動脈狭窄の予防や早期発見により、虚血性心疾患での死亡者数を減らすことができる。

虚血性心疾患の診断は侵襲性の高いカテーテル挿入による冠動脈造影が行われてきた。近年は冠動脈CT(computed tomography coronary angiography: CTCA)が普及している。これはCTの進化によって安定した冠動脈狭窄診断が可能となったためである。CTCAは冠動脈造影と比較して短時間に冠動脈狭窄の診断を行えることから、虚血性心疾患の早期発見のための手段として期待される。一方でCTCAによる虚血性心疾患の診断精度は感度76-99%、特異度94-99%、陽性的中率56-89%、陰性的中率95-100%と報告されている2)。CTCAによる虚血性心疾患の陽性的中率が低い原因として、高度石灰化によるブルーミングアーチファクトやステントによる金属アーチファクトが挙げられる。そのため、CTCAで冠動脈の狭窄が疑われた場合は、侵襲性の高い冠動脈造影で確定診断を行っている。虚血性心疾患の早期発見のためにCTCAを活用するためには、CTCAの陽性的中率を向上させるための画像診断支援技術が必要である。

一方、CTCAは1回の検査で数千枚という膨大な画像情報が提供される。発生した膨大な画像データは正確な診断がなされることで意味を持つが、医師が膨大なデータを読影するのは負担がかかる。さらに、1日あたりの画像検査件数は飛躍的に増加しており、全体の読影時間が著しく増加している。結果、読影する医師の負担が著しく増加している3)。この問題を解決するには短時間で正確な読影を支援する方法のひとつとして、コンピュータ支援診断(computer-aided diagnosis: CAD)技術の開発が期待される3)。

これらの課題を解決するべく、先行研究として人工知能技術の一つである深層畳み込みニューラルネットワーク(deep convolutional neural network: DCNN)を用いて、CTCAにおける冠動脈内の石灰化とステントの自動分類に応用することを試みた4)。しかしながら現在は20%近く誤分類があり、CADシステムとしては満足いく結果に至っていない。

2. 研究の目的

本研究の目的は、虚血性心疾患の早期発見のための画像診断支援技術として、CTCA画像から冠動脈の異常部を自動で認識するCADシステムを開発すること、特にDCNNを要素技術として確立することである。

3. 研究の方法

(1) VGG-16のファインチューニングによる石灰化とステントの自動分類の精度検証

本研究では、先行研究4)では検討されなかったVGG-16を使用し、ファインチューニングによる石灰化とステントの分類精度を検証した。石灰化群5例、ステント群5例、正常群3例の計13症例(平均年齢70.4±13.9歳、男性10例、女性3例)を使用した。CTCAのaxial画像から冠動脈の走行に垂直な640×640 pixelsの直交断面像を取得した。さらに、この直交断面像内の冠動脈を中心に256×256 pixelsでトリミングし、window widthを1200 HU、window levelを240 HUに設定し、24 bit true colorのbitmap形式で保存した。取得した画像は石灰化像1113枚、ステント像1353枚、正常像2494枚の合計4960枚であった。DCNNの学習環境はCPU: Core i9 9900X 10core/20thread 3.5 GHz、メモリ: 128 GB、GPU: NVIDIA TITAN RTX 24 GB×2枚(合計48 GB)、ソフトウェア環境はOS: Ubuntu 16.04、deep learning SDK: CuDNN、フレームワーク: CUDA 10.0、Caffe-0.17.0-py2、Python-2.7.12、Digits-6.1.1であった。

DCNNには既存で公開されている学習済みモデルのうち、AlexNet、GoogLeNet 5)、VGG-16 6)を用いた。AlexNetは2012年の一般物体認識のコンペティション(ImageNet Large Scale Visual Recognition Challenge; ILSVRC 2012)で優勝したDCNNであり、畳み込み層が5層、全結合層が3層で、プーリングを1層目と2層目、5層目の畳み込み層の後に行う。GoogLeNetはILSVRC2014で優勝したDCNNであり、Inceptionと言われる複数の畳み込み層から構成されたモジュールを積層した構造である。全結合層がなくなったことでAlexNetよりも計算負荷が減少している。VGG-16はILSVRC 2014で第2位を獲得したDCNNであり、畳み込み層13層、全結合層3層のモデルで、畳み込み層は3×3のフィルタを使用している。層が深くなっていくごとに畳み込み層から出力される特徴マップの大きさが小さくなり、フィルタ数が多くなる構造をしている。

本研究でのDCNNの学習パラメータは、エポック数を1000回、学習率を0.001とし、他はDigitsにおける設定をそのまま使用した。各DCNNによる分類精度を評価は、症例単位でleave-one-out cross validationを実施した。13症例のうち1症例を学習から取り除き、残りの12症例で学習させた後、取り除いた1症例で検証を行った。これを13症例すべてで同様に行った。

(2) VGG の畳み込み層の構造最適化による石灰化とステントの自動分類の精度検証

本研究は(1)で最適とされた VGG-16 を中心として、単純にファインチューニングを行うだけでなく、畳み込み層の構造を変更してファインチューニングを実施することでの石灰化とステントの自動分類の精度の変化を検証した。対象画像は 24 症例 (72.2±9.5 歳、男性 13 人) の CTCA 画像から再構成した冠動脈の直交断面画像 27162 枚 (石灰化群 5254 枚、ステント群 1458 枚、正常群 20450 枚) である。DCNN は公開されているもののうち GoogLeNet と VGG-16 および、既存の VGG-16 の層を深くした VGG-22、VGG-28 を用いた。VGG は VGG-16 から畳み込み層を 3 層増やした VGG-19 が一般的に知られているが、本研究では VGG-19 の開発と同じ手順で VGG-16 から畳み込み層を 6 層増やした VGG-22、12 層増やした VGG-28 を作成し、それぞれの精度を検証した。なお、予備研究により DCNN の学習パラメータは学習係数を 0.001、バッチサイズを 16 として実施した。分類精度検証は 12-fold cross validation を実施した。12-fold cross validation では、24 症例を 2 症例ずつの群に無作為に分け、その群のひとつをテストデータに使用し、残りをトレーニングデータセットとした。ひとつの群が 1 回ずつテストデータとなるように 12 回繰り返して学習とテストを行い、その結果の合算を分類精度の結果とした。

(3) VGG の全結合層の構造最適化による石灰化とステントの自動分類の精度検証

本研究は(2)で最適とされた VGG-22 を基準として、単純にファインチューニングを行うだけでなく、全結合層の構造を変更してファインチューニングを実施することでの石灰化とステントの自動分類の精度の変化を検証した。対象画像は 49 症例の CTCA 画像から再構成した冠動脈の直交断面画像 72051 枚 (石灰化群 13035 枚、ステント群 14382 枚、正常群 44634 枚) である。DCNN はニューラルネットワークモデルが一般公開されている VGG-16 から畳み込み層を 6 層増やした VGG-22 を使用した。本研究では全結合層のパラメータに注目し、全結合層の層数を 3 種類 (3 層、4 層、5 層)、全結合層における中間層のユニット数を 2 種類 (4096、16384) 設定し、合計 6 種類で比較した。なお、VGG-16 における全結合層は 3 層、中間層のユニット数は 4096 である。対象画像のうち 64846 枚 (石灰化群 11732 枚、ステント群 12944 枚、正常群 40170 枚) を学習データに、7205 枚 (石灰化群 1303 枚、ステント群 1438 枚、正常群 4464 枚) をテスト画像に使用した。DCNN の学習係数は 0.001、バッチサイズは 2 とし、ホールドアウト検証を 7 回を行い、その正診率、および各群の陽性的中率の平均値を算出し、6 種類の DCNN を比較した。

(4) ResNet 導入と構造最適化による石灰化とステントの自動分類の精度検証

本研究では(3)で最適とされた VGG-23 を基準として、更なる分類精度向上を目指して分類問題では VGG よりも高い精度である ResNet 7)での分類を試した。ResNet 以前では層を深くすると勾配消失問題によって性能が悪化する。そこで ResNet は残差ブロックと Shortcut Connection の導入によって、それ以前の層の深さを大幅に更新し、最大 1000 層以上の DCNN を実現した。本研究では 24 症例を対象とした (72.2±9.5 歳、男性 13 人)、取得した画像は石灰化群 8494 枚、ステント群 8402 枚、正常群 8945 枚の合計 25841 枚であった。症例数及び学習画像枚数を減らしたのは、49 症例ではメモリオーバーとなり、学習できなかったためである。なお、ハードウェア環境は CPU : AMD EPYC 7542 32core/64thread 2.9 GHz、メモリ : 256 GB、GPU : NVIDIA Quadro RTX 8000 48GB×4 枚 (合計 192 GB)、ソフトウェア環境は OS : Ubuntu 18.04、deep learning SDK : CuDNN、フレームワーク : CUDA 10.0、Caffe-0.17.0-py2、Python-3.7.10 であった。

DCNN には既存で公開されている学習済みモデルのうち、GoogLeNet、VGG-16、ResNet50 を使用した。そして、VGG では 3×3 フィルタの畳み込み層を 6 層、全結合層を 1 層追加し、VGG-23 を構築した。ResNet はさらに各畳み込み層のフィルタサイズを大きくすることで精度向上が期待される 8)。本研究では ResNet50 の各畳み込み層のフィルタサイズを 2 倍にした wide ResNet (WRN) 50-2、4 倍にした WRN50-4、8 倍にした WRN50-8 を構築した。さらに Residual Block の 2 層目の convolution 層、Batch Normalization 層、活性化関数の後に Dropout を導入した。本研究では Dropout の確率を 0.4、0.5、0.6、および WRN50-2 では 0.7 で検討した。さらに出力層における活性化関数に ReLU を用いた。入力値と活性化関数からの出力値が同じとなることで softmax 関数のように正規化されず、出力差が明確となることで、WRN のパラメータが増加しても勾配消失を防ぐことを期待した。各 WRN のパラメータ数は WRN50-2 が 94,212,355 parameters、WRN50-4 が 375,815,171 parameters、WRN50-8 が 1,501,221,379 parameters であった。WRN のフィルタ数を増やすとパラメータ数が非常に大きくなるため計算回数が WRN50-2 で 830 京回、WRN50-4 で 3,300 京回、WRN50-8 で 1.3 垓回と膨大になり、多くの計算時間を費やした。

DCNN の学習パラメータは、epoch 数を 1000 回、学習率を 0.001 とした。学習時の入力画像枚数を示すバッチサイズを 2、重みを更新する際の最適化手法は Adam とした。各 DCNN による分類精度を評価するために症例単位で leave-one-out cross validation を実施した。24 症例のうち 1 症例を学習から取り除き、残りの 23 症例で学習させた後、取り除いた 1 症例で検証を行った。これを 24 症例すべてで同様に行った。各 DCNN による石灰化群、ステント群、正常群の精度、再現率、F スコア、および 3 群の正診率を分類精度結果の混同行列から求めた。

(5) 低吸収プラークと石灰化プラークの自動分類

加齢や高血圧などにより動脈硬化が進み、冠動脈内の血管内膜にコレステロールが沈着してプラークを形成するが、経過によって脆弱性プラーク、線維性プラーク、石灰化プラークとなる。

これらプラークは CTCA では主に CT 値によって分類することができる。特に脆弱性プラークや線維性プラークは CT 値が低いのが特徴である（低吸収プラーク）。CTCA において低吸収プラークの検出および他のプラークとの分類も重要な課題である。そこで、まずは(1)と同様に AlexNet と GoogLeNet でプラークの性状分類を目指した。本研究では計 14 症例、スライス枚数は計 3,198 枚の冠動脈断面画像を使用した。このうち、石灰化像が 1,143 枚、正常像が 1,471 枚、低吸収プラーク像が 584 枚であった。石灰化像および正常像は(4)までの研究で取得できたが、本研究ではウィンドウ値が異なり、画像モリサイズで取得したこと、分類画像枚数に偏りがあると評価値に影響を与えることから、新たに取得した 14 症例を学習データとした。

DCNN の学習パラメータは、epoch 数を 1000 回、学習率を 0.001 とした。また、バッチサイズは 32、最適化手法は stochastic gradient descent (SGD) とした。評価方法は 2-fold cross validation である。7 症例(石灰化例 627 枚、正常例 555 枚、低吸収プラーク例 435 枚の計 1,617 枚)を学習に、テストには 7 症例(石灰化例 516 枚、正常例 916 枚、低吸収プラーク例 149 枚の計 1,581 枚)を使用した。そして、学習画像とテスト画像を入れ替えて 2 回検証した。石灰化群、正常群、低吸収プラーク群の混同行列から正診率を求め、各 DCNN の分類精度とした。

(6) 低吸収プラーク領域の自動抽出

(5)で示すように、分類で使われる DCNN ではプラークを認識できていないことが示唆された。そこで、領域抽出で用いられる DCNN である U-Net を用いて、低吸収プラーク領域の自動抽出を目指した。対象画像には CTCA 画像から取得した低吸収プラークを含む冠動脈直交断面画像 132 枚を用いた。教師画像(低吸収プラーク領域の正解ラベル画像)は診療放射線技師が作成し、放射線科医が確認・修正した [Fig. 1(a)]。入力画像には、原画像 [Fig. 1(b)]、コントラスト強調を行った画像 [Fig. 1(c)]、原画像から血管領域を手動抽出した画像 [Fig. 1(d)]、コントラスト強調画像から血管領域を手動抽出した画像 [Fig. 1(e)] の 4 種類を用いた。低吸収プラーク領域の抽出精度検証方法として 10-fold cross-validation を実施した。また、教師画像と U-Net が抽出した低吸収プラーク領域の一致度を Dice 係数で評価した。

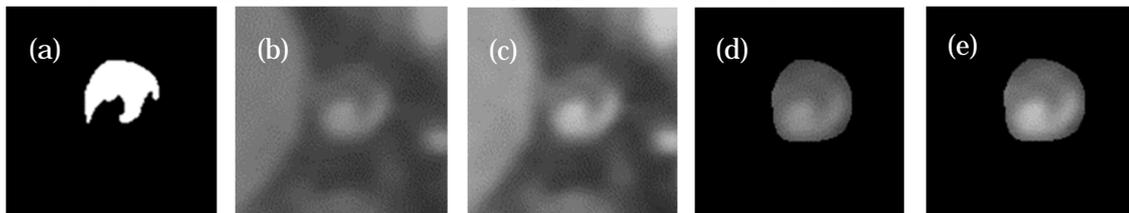


Fig. 1 U-Net の学習で使用した教師画像および入力画像。

(a) 教師画像、(b) 原画像、(c) コントラスト強調、(d) 血管のみ、(e) (c) の血管のみ

4. 研究成果

(1) VGG-16 のファインチューニングによる石灰化とステントの自動分類の精度検証

石灰化群、ステント群、正常群をまとめた正診率は VGG-16 を用いた場合が最も高くなった。AlexNet における的中率は石灰化群 73.2% (815/1113)、ステント群 73.5% (994/1353)、正常群 78.5% (1957/2494) となり、トータルの的中率(正診率)は 75.9% (3766/4960) であった。GoogLeNet における的中率は石灰化群 72.4% (806/1113)、ステント群 74.7% (1011/1353)、正常群 88.8% (2214/2494) となり、トータルの的中率(正診率)は 81.3% (4031/4960) であった。VGG-16 における的中率は石灰化群 72.8% (810/1113)、ステント群 74.1% (1003/1353)、正常群 98.4% (2454/2494) となり、トータルの的中率(正診率)は 86.0% (4267/4960) であった。特に VGG-16 では、正常群を正しく分類した割合(陰性的中率)が顕著に高くなった。

(2) VGG の畳み込み層の構造最適化による石灰化とステントの自動分類の精度検証

VGG-22 で石灰化群、正常群のそれぞれの的中率、およびトータルの的中率が最も高くなった。的中率は石灰化群 89.3% (4690/5253)、ステント群 71.0% (1035/1458)、正常群 98.4% (20127/20450) となり、トータルの的中率は 95.2% (25852/27162) であった。ただし、ステント群の的中率は VGG-28 で最も精度が高く、75.3% (1098/1458) となった。症例数(学習用の画像枚数)が増えたこと、VGG の構造が最適化されたことにより、特に石灰化群とステント群の的中率(陽性的中率)が顕著に向上した。したがって、最適な畳み込み層の層数は VGG-16 の 13 層から 6 層増やした 19 層であることがわかった。

(3) VGG のファインチューニングと構造最適化による石灰化とステントの自動分類の精度検証

正診率は、全結合層における中間層のユニット数を 4096 としたとき、3 層では 97.6%、4 層では 97.8%、5 層では 97.0% であった。中間層のユニット数を 16384 としたとき、3 層では 97.9%、4 層では 98.0%、5 層では 97.3% となった。また、石灰化群およびステント群は中間層のユニット数を 16384 とし、中間層を増やすほど陽性的中率が向上した。したがって、最適な全結合層の層数は VGG-22 の 3 層から 1 層増やし、ユニット数を 4 倍の 16384 とした VGG-23 であることがわかった。ただし、Fig.2 で示すように円周全方向に高度石灰化プラークが付着している場合や、

画像内にアーチファクトが含まれる場合は正しく認識することができなかった。

(4) ResNet 導入と構造最適化による石灰化とステントの自動分類の精度検証

GoogLeNet、VGG-23、ResNet50、および WRN での分類結果を Table 1 に示す。VGG-23 において精度、再現率、F スコア、正診率いずれも最も高くなった。正診率は VGG-23 で 95.2%であった。ResNet50 および WRN は精度、再現率、F スコア、正診率いずれも GoogLeNet および VGG-23 を下回った。なお、WRN は Dropout rate が 0.5 の場合のみ学習できた。また、ResNet にも Dropout を入れたが、学習曲線での正診率が 0.3303 でフラットとなり、学習できなかった。したがって、ResNet および WRN による石灰化とステントの分類精度向上は困難であることが示唆された。

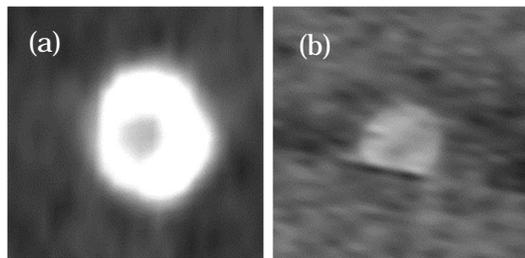


Fig. 2 VGG-23 でも分類できなかった画像例。
(a) 円周全方向に石灰化が付着している画像
(b) アーチファクトが含まれる画像

(5) 低吸収プラークと石灰化プラークの自動分類

石灰化像では GoogLeNet の的中率が高く、1,143 枚中 896 枚 (78.4%) 正しく分類することができた。正常像でも GoogLeNet の的中率が高く、1,471 枚中 994 枚 (67.6%) 正しく分類することができた。低吸収プラーク像では AlexNet の的中率が高く、584 枚中 183 枚 (31.3%) 正しく分類することができた。正診率は GoogLeNet が 3,198 枚中 2,021 枚 (63.2%) と

AlexNet よりも高かった。しかしながら、学習画像枚数が少なかったこともあるが、低吸収プラークの的中率が顕著に低く、低吸収プラークを正常と誤分類することが多かった。したがって、低吸収プラークを正しく認識できていないことが示唆された。

Table 1 GoogLeNet、VGG-23、WRN による分類結果

	DCNN					
	GoogLeNet	VGG-23	ResNet50	WRN50-2	WRN50-4	WRN50-8
Precision	92.7%	95.1%	36.0%	77.9%	38.0%	71.1%
Recall	92.6%	95.2%	46.6%	77.4%	52.1%	68.2%
F score	92.6%	95.1%	39.6%	77.2%	42.3%	67.8%
Accuracy	92.6%	95.2%	46.8%	77.4%	52.5%	68.7%

(6) 低吸収プラーク領域の自動抽出

全画像 (132 枚) に対する Dice 係数の平均値は、入力画像が原画像のとき 0.73、コントラスト強調画像のとき 0.85、原画像の血管領域抽出画像のとき 0.89、コントラスト強調画像の血管領域抽出画像のとき 0.91 となった。この結果より、血管領域抽出画像を使用し、かつ、コントラスト強調を行ったとき、低吸収プラーク領域を最も高精度に抽出可能であることが示された。今後は学習用データを増やすことでさらなる抽出精度の向上が期待される。また、血管領域の抽出を自動化することで、低吸収プラーク領域の抽出をさらに効率よく行えると考えられる。

< 引用文献 >

- 1) 厚生労働省：平成 30 年(2018)人口動態統計月報年計(概数)の概況．厚生労働省ホームページ <https://www.mhlw.go.jp/toukei/saikin/hw/jinkou/geppo/nengai18/index.html>
- 2) Schroeder S, et al: Cardiac computed tomography: indications, applications, limitations, and training requirements: report of a Writing Group deployed by the Working Group Nuclear Cardiology and Cardiac CT of the European Society of Cardiology and the European Council of Nuclear Cardiology. Eur Heart J, 29(4), 531-556, 2008.
- 3) 西谷弘:特集論文 / 3DCT の有効性と課題 - 精度の向上と膨大な情報量をどのように扱うか. Medical Imaging Technology, 25(2), 75-78, 2007.
- 4) 長谷川晃, 李鎔範, 他: 深層学習を用いた冠動脈 CT における石灰化とステントの自動分類. 日放技学誌, 74(10), 1138-1143, 2018.
- 5) Szegedy C, Liu W, Jia Y, et al.: Going deeper with convolutions. Proceedings of IEEE conference on computer vision and pattern recognition, 1-9, 2015.
- 6) Simonyan K and Zisserman A.: Very deep convolutional networks for large-scale image recognition. In International Conference on Learning Representation, 2015.
- 7) Kaiming He, et al.: Deep Residual Learning for Image Recognition; Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition; (CVPR); Las Vegas, NV, USA. 27-30, 770-778, 2016.
- 8) Zagoruyko S, et al.: Wide residual networks. CoRR. vol. abs/1605.07146, 2016.

5. 主な発表論文等

〔雑誌論文〕 計2件（うち査読付論文 2件 / うち国際共著 0件 / うちオープンアクセス 2件）

1. 著者名 長谷川晃, 吉田皓文, 児玉直樹	4. 巻 69巻834号
2. 論文標題 冠動脈CT画像における石灰化とステントの高精度な自動分類を目的とした深層学習改良の試み	5. 発行年 2022年
3. 雑誌名 日本診療放射線技師会誌	6. 最初と最後の頁 29-35
掲載論文のDOI (デジタルオブジェクト識別子) なし	査読の有無 有
オープンアクセス オープンアクセスとしている (また、その予定である)	国際共著 -

1. 著者名 長谷川晃, 吉田皓文, 二木来菜, 李鎔範	4. 巻 20巻9号
2. 論文標題 冠動脈 CT における石灰化とステントの自動分類のためのDCNN 構造最適化	5. 発行年 2020年
3. 雑誌名 新潟医療福祉学会誌	6. 最初と最後の頁 9-15
掲載論文のDOI (デジタルオブジェクト識別子) なし	査読の有無 有
オープンアクセス オープンアクセスとしている (また、その予定である)	国際共著 -

〔学会発表〕 計2件（うち招待講演 0件 / うち国際学会 1件）

1. 発表者名 Hasegawa Akira, Yoshida Akifumi
2. 発表標題 Automated Classification of Fragile Plaques and Fibrous Plaques on Coronary Computed Tomography Angiography using Deep Learning
3. 学会等名 The 23rd Asia-Australasia Conference of Radiological Technologists (国際学会)
4. 発表年 2021年

1. 発表者名 長谷川 晃, 吉田 皓文, 李 鎔範
2. 発表標題 CCTA 画像の自動分類を目的としたDCNN のwide 化による性能比較
3. 学会等名 第20回新潟医療福祉学会学術集会
4. 発表年 2020年

〔図書〕 計0件

〔産業財産権〕

〔その他〕

新潟医療福祉大学 医療技術学部 診療放射線学科 教員紹介 長谷川晃
<https://www.nuhw.ac.jp/faculty/medical/rt/teacher/hasegawa.html>

6. 研究組織

	氏名 (ローマ字氏名) (研究者番号)	所属研究機関・部局・職 (機関番号)	備考
--	---------------------------	-----------------------	----

7. 科研費を使用して開催した国際研究集会

〔国際研究集会〕 計0件

8. 本研究に関連して実施した国際共同研究の実施状況

共同研究相手国	相手方研究機関
---------	---------