

[原著論文]

## 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

長谷川 晃<sup>1)</sup>, 吉田 皓文<sup>1), 2)</sup>, 二木 来菜<sup>2)</sup>, 李 鎔範<sup>2)</sup>

キーワード：深層学習，構造調整，冠動脈 CT，石灰化，ステント

Structure optimization of deep convolutional neural network for  
automatic classification of calcifications and stents in  
coronary computed tomography angiography

Akira Hasegawa<sup>1)</sup>, Akifumi Yoshida<sup>1), 2)</sup>, Raina Futatsugi<sup>2)</sup>, Yongbum Lee<sup>2)</sup>

### Abstract

**Purpose** : The purpose of this study was to classify coronary arteries with calcifications or stents and normal coronary arteries with high accuracy as a computer-aided diagnosis system in coronary computed tomography angiography (CCTA).

**Methods** : Altogether, 49 CCTA scans were taken retrospectively. We obtained 72,051 cross-sectional images of coronary arteries (13,035 calcified images, 14,382 stent images, and 44,634 normal images) among CCTA images. For the deep convolutional neural network (DCNN), we used VGG-22 with six additional convolutional layers from the publicly available VGG-16. From VGG-22, the number of intermediate layers in the fully connected layers were increased from three to five. On the target images, 64,846 images were used as training data, and 7,205 images were used as test images. We performed hold-out validation at seven times, calculated accuracy and positive predictive value of each group, and compared the three DCNNs.

**Results** : The positive predictive value of the calcified group was 95.3% for 3 fully connected layers, 95.6% for 4 layers, and 95.9% for 5 layers. The positive predictive value of the stent group was 99.2% for 3 layers, 98.9% for 4 layers, and 99.3% for 5 layers.

**Conclusion** : The accuracy of automatic classification with calcifications and stents using CCTA can be improved by increasing the fully connected layer of DCNN. The results show that DCNN is effective for triage of coronary artery disease using CCTA.

---

1) 新潟医療福祉大学 医療技術学部 診療放射線学科  
2) 新潟大学大学院 保健学研究科

[責任著者および連絡先] 長谷川 晃  
新潟医療福祉大学 医療技術学部 診療放射線学科  
〒950-3198 新潟県新潟市北区島見町 1398 番地  
E-mail : akira-hasegawa@nuhw.ac.jp

投稿受付日：2020年4月7日  
掲載許可日：2020年6月29日

Keywords : deep learning, structure adjustment, coronary computed tomography angiography (CCTA), calcification, stent

## 要旨

【目的】本研究の目的は coronary computed tomography angiography (CCTA) におけるコンピュータ支援診断システムの要素技術として、石灰化またはステントを有する冠動脈と通常の冠動脈の断面像を高精度に自動分類することである。

【方法】49 症例の CCTA 画像から再構成した冠動脈の直交断面画像 72,051 枚（石灰化群 13,035 枚、ステント群 14,382 枚、正常群 44,634 枚）を用いた。Deep convolutional neural network (DCNN) には一般に公開されている VGG-16 から畳み込み層を 6 層増やした VGG-22 を使用した。この VGG-22 から全結合層の中間層数を 3 層から 5 層と増やした。対象画像のうち 64,846 枚を学習データに、7,205 枚をテスト画像に使用した。Hold-out 検証を 7 回行い、各群の的中率を算出し、3 種類の DCNN を比較した。

【結果】石灰化群の的中率は 3 層では 95.3%、4 層では 95.6%、5 層では 95.9% であった。また、ステント群の的中率は 3 層では 99.2%、4 層では 98.9%、5 層では 99.3% であった。

【結論】DCNN の全結合層を増やすことにより、CCTA を用いた石灰化とステントの自動分類精度を向上させることができる。本研究結果は、CCTA による冠動脈疾患のトリアージに有効である。

## I はじめに

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<sup>1)</sup>。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において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が、近年は coronary computed tomography coronary angiography (CCTA) が普及している<sup>2),3)</sup>。これは multi detector computed tomography (MDCT) 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。CCTA 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<sup>4)-6)</sup>。一方で CCTA 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<sup>7)</sup>。CCTA 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<sup>8)</sup> (図 1)。そのため、CCTA 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 CCTA を活用するためには、CCTA 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、CCTA は 1 回の検査で数千枚程度の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




図 1 虚血性心疾患の陽性的中率が低くなる原因となる CCTA 画像例

- (a) 高度石灰化付着例
- (b) ステント挿入後例

が著しく増加している<sup>9)</sup>。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。

この課題を解決するべく、我々は石灰化、線維性、脂質性といった冠動脈プラークの解析を自動で行い、さらに治療が必要な有意狭窄であるかを自動判定するシステムを開発している。これにより、治療が必要な患者の早期発見、および CCTA を解析する医師の負担軽減を目指している。先行研究では、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 CCTA 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<sup>10)</sup>。しかしながら正診率は 81.3% であり、CAD システムとしては満足いく結果に至っていない。

そこで本研究の目的は、CCTA から虚血性心疾患を早期発見するための CAD システム技術として、石灰化とステントの自動分類精度を向上させるために DCNN を検証することである。本研究ではネットワークモデルが公開されている DCNN を利用し、ネットワークの構造を調整することで自動分類の精度を向上させる手法を提案した。

## II 方法

図 2 に提案手法のフローチャートを示す。提案手法では深層学習のうち DCNN<sup>11)-13)</sup> を用いた。はじめに

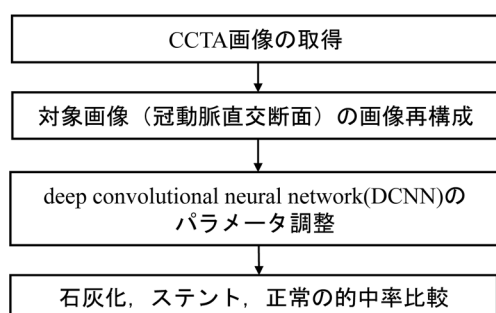


図 2 提案手法のフローチャート

CCTA 画像から対象とする冠動脈に対して直交断面となる画像を取得し、冠動脈に合わせて画像のトリミングをした。これらの画像に対して DCNN を用いて学習・分類を行った。DCNN は VGG-16 から畳み込み層を 6 層増やした VGG-22 を基準とし、全結合層を増やすことで分類精度を検証した。分類精度の評価は hold out 検証を実施した。

### 1 画像の取得

本研究は新潟医療福祉大学倫理委員会 (承認番号: 18190-190625)、新潟大学倫理委員会、富山赤十字病院倫理委員会の承認を得た。対象症例は 49 症例 (72.2±9.5 歳、男性 30 人) とし、2017 年 7 月から 2018 年 10 月までに Revolution GSI (GE Healthcare)、SOMATOM Force (Siemens Healthineers) で撮影された CCTA 画像を使用した。撮影条件は、Revolution GSI では管電圧 120 kVp、管電流 210-245 mAs、スライス厚 0.625 mm、SOMATOM Force では管電圧 100 kVp、管電流 370 Quality reference mAs、スライス厚 0.6 mm であった。

対象画像の取得作業は医用画像解析ワークステーション (Advantage Workstation VolumeShare 4.7, GE Healthcare) で行った。CCTA の axial 画像から冠動脈を自動抽出し、冠動脈に垂直な 640×640 pixels の直交断面画像を取得した。本研究では、これらの画像に対して冠動脈を中心とした 256×256 pixels にトリミングした。また、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。この window width および window level は、臨床において特に石灰化やステントを有する画像所見の場合に用いられる設定である。また、bitmap 形式で保存した画像は観察者が適切と判断したコントラストの画像となる。

対象画像となる冠動脈直交断面像の内訳は、石灰化像 13,035 枚、ステント像 14,382 枚、正常像 44,634 枚の合計 72,051 枚である。なお、本研究においてソフトプラークの存在を疑われる症例は除外した。対象画像例を図 3 に示す。これらの画像の分類は経験年数 15 年の診療放




図 3 DCNN の学習に使用した CCTA 画像例

- (a) 石灰化が付着した冠動脈 (石灰化像)
- (b) ステント挿入後の冠動脈 (ステント像)
- (c) 異常の指摘されなかった冠動脈 (正常像)

放射線技師が行い、経験年数27年の放射線科医が正しく分類されていることを確認した。

## 2 Deep convolutional neural network (DCNN)

提案手法では、これらの対象画像を深層学習の一つであるDCNNにより自動分類した。深層学習は機械学習の一手法であり、画像認識の分野ではDCNNがよく用いられている<sup>11)-13)</sup>。DCNNでは画素値を入力データとして学習・分類が行われる。本研究ではDCNN用ツールとしてDIGIT 6.0 (NVIDIA corporation)を用いた。ハードウェア環境はCPU: Xeon E5-1650v4 6core/12thread 3.60 GHz、メモリ: 128 GB、GPU: GeForce GTX1080 8 GB×4枚 (合計32 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 8.0、Caffe、Pythonであった。

表1 本研究で構築したDCNNの概要

FC3	FC4	FC5
input (224 × 224 RGB image)		
conv3×3,64 conv3×3,64	conv3×3,64 conv3×3,64	conv3×3,64 conv3×3,64
max pooling		
conv3×3,128 conv3×3,128	conv3×3,128 conv3×3,128	conv3×3,128 conv3×3,128
max pooling		
conv3×3,256 conv3×3,256 conv3×3,256 conv3×3,256	conv3×3,256 conv3×3,256 conv3×3,256 conv3×3,256	conv3×3,256 conv3×3,256 conv3×3,256 conv3×3,256
max pooling		
conv3×3,512 conv3×3,512 conv3×3,512 conv3×3,512 conv3×3,512	conv3×3,512 conv3×3,512 conv3×3,512 conv3×3,512 conv3×3,512	conv3×3,512 conv3×3,512 conv3×3,512 conv3×3,512 conv3×3,512
max pooling		
conv3×3,512 conv3×3,512 conv3×3,512 conv3×3,512 conv3×3,512	conv3×3,512 conv3×3,512 conv3×3,512 conv3×3,512 conv3×3,512	conv3×3,512 conv3×3,512 conv3×3,512 conv3×3,512 conv3×3,512
max pooling		
FC (4096)	FC (4096)	FC (4096)
FC (4096)	FC (4096)	FC (4096)
<b>FC (1000)</b>	FC (4096)	FC (4096)
	<b>FC (1000)</b>	FC (4096)
		<b>FC (1000)</b>
soft-max		

Convは畳み込み層を示し、3×3はフィルタのサイズ、64、128、256、512はフィルタ数を示す

FCは全結合層を示し、()内の数字はユニット数を示す

Max poolingは最大値プーリングを示し、soft-maxはソフトマックス関数による出力を示す

DCNNは公開されているもののうちVGG-16<sup>14)</sup>を使用した。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層の構造で、畳み込み層は3×3のフィルタを使用している。VGGは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。VGGは他にも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。本研究ではVGG-19の開発と同じ手順を用いて、VGG-16から畳み込み層を6層増やしたVGG-22を用いた<sup>15)</sup>。本研究は全結合層に着目し、VGG-22における3層の全結合層を4層、および5層とした。なお、各層のユニット数はVGG-22と同じ4096のままとした。本研究で構築したDCNNの構成の概要を表1に示す。パラメータ数は全結合層3層が139,978,624 parameters、4層が168,552,320 parameters、5層が185,329,536 parametersであった。VGGはパラメータ数が多いDCNNであるが、構造がシンプルであり容易に調整できることから、本研究ではVGGをベースにDCNNを構築した。

## 3 DCNNの分類精度検証

本研究でのDCNNの学習パラメータは、エポック数を1000回、学習係数は予備検討で最適と判断した0.001 ( $10^{-3}$ )、solver typeは確率的勾配降下法 stochastic gradient descent、バッチサイズは2とした。これらのパラメータを各DCNNに適用し、hold-out検証を実施した。精度検証結果として石灰化群、ステント群、正常群の的中率を求めた。DCNNは学習データが多いほど精度が向上するため、対象画像72,051枚のうち9割にあたる64,846枚(石灰化群11,732枚、ステント群12,944枚、正常群40,170枚)を学習データに、残りの1割にあたる7,205枚(石灰化群1,303枚、ステント群1,438枚、正常群4,464枚)をテストデータに、画像単位で無作為に分けた。その後、学習とテストを7回繰り返し、その結果の合算を分類精度の結果とした。学習とテストを繰り返す毎に画像単位で学習データとテストデータを分けることで、学習で使用した画像データがテストで使われることのないようにした。

## III 結果

表2に全結合層が3層における分類の結果、表3に全結合層が4層における分類の結果、表4に全結合層が5層における分類の結果を示す。数値はDCNNがテストデータを各群に分類した7回の合計値を示す。また、表5に全結合層3層、4層、5層それぞれにおける石灰化群、ステント群、正常群の的中率を示す。石灰化群、およびステント群は全結合層が増えるほどの中率が向上した。正常群は全結合層が3層の場合での中率が最

表 2 全結合層 3 層における分類結果

入力	出力		
	石灰化	正常	ステント
石灰化	8696	322	103
正常	656	30550	42
ステント	65	12	9989

数字は DCNN が分類した 7 回の合計画像枚数を示す

表 3 全結合層 4 層における分類結果

入力	出力		
	石灰化	正常	ステント
石灰化	8722	322	77
正常	557	30665	26
ステント	86	21	9959

表 4 全結合層 5 層における分類結果

入力	出力		
	石灰化	正常	ステント
石灰化	8743	271	107
正常	996	30168	84
ステント	61	5	10000

表 5 全結合層 3 層、4 層、5 層における CCTA 画像の石灰化、正常、ステントの的中率結果

	3層	4層	5層
石灰化	95.3 (8696/9121)	95.6 (8722/9121)	95.9 (8743/9121)
正常	97.8 (30550/31248)	98.1 (30665/31248)	96.5 (30168/31248)
ステント	99.2 (9989/10066)	98.9 (9959/10066)	99.3 (10000/10066)

上段は的中率 (%) を示し、下段は (正しく分類した画像枚数/各群の全画像枚数) を示す  
画像枚数は 7 回の合計値を示す

も高くなった。全結合層が 5 層における的中率は石灰化群 95.9 % (8,743/9,121)、ステント群 99.3 % (10,000/10,067)、正常群 96.5 % (30,168/31,248) となった。

#### IV 考察

本研究では、DCNN における全結合層の構造を調整することで分類精度を向上させることが可能であることを示した。医療画像を正確に解析することは質の高い医療を提供するためには重要である。既存の DCNN をそのまま転移学習に利用するだけでなく、ネットワークやパラメータを適切にチューニングすることで、正確に

分類できるようにするべきである。

我々は先行研究で畳み込み層を見直すことにより、24 症例、27,162 枚の CCTA 画像を用いて石灰化とステントの自動分類精度向上を試みた。その結果、VGG-16 から畳み込み層を 6 層増やした VGG-22 が最も高い分類精度を示し、石灰化群の的中率は 89.3%、ステント群では 71.0%、正常群では 98.4% となった。本研究では先行研究から 25 症例、44,889 枚増やし、全結合層の層数を増やすことで更なる分類精度向上を目指した。本研究における全結合層 3 層は先行研究における VGG-22 と同じ DCNN の構造である。VGG-22 と全結合層 3 層の結果を比較しても的中率は石灰化群で 6.0%、ステント群で 28.2% 向上していることから、DCNN の学習用画像の枚数を増やすことは精度向上に有効であることが示唆される。また、石灰化群およびステント群といった陽性的中率は全結合層を増やすことでさらに向上したことから、全結合層を増やすことは DCNN が異常部を正確に認識するためには有効である。一方で、全結合層を増やすほど偽陽性数が増え、偽陰性数は減少する傾向にあった。このことから、全結合層を増やすほど見逃しが減るが、CAD システムの要素技術として採用するためには、偽陽性を減らすことに対しても考慮すべきである。

本研究の結果、全結合層を 5 層にすることで石灰化群およびステント群の陽性的中率を向上させることができた。正常の検出数に対する陽性的中数の割合でも、3 層で 0.61 (18,685/30,550)、4 層でも 0.61 (18,681/30,665)、5 層で 0.62 (18,743/30,168) となった。陽性数、陽性的中率、正常の検出数に対する陽性的中数の割合いずれにおいても 5 層が最も高くなったことから、全結合層は 5 層に増やしたほうが良いと考える。読影医による CCTA の診断において感度は 76~99%、特異度は 94~99% であるが、本研究ではこれとほぼ同等の結果が得られている。ただし、先行研究と比較して症例数が少ないこと、また検証方法が異なるため、医師による診断との比較は更なる検討が必要である。また、5 層では基準となる 3 層よりも偽陽性数が増えたため、今後偽陽性率の低下が求められる。

本研究では石灰化群やステント群は正常群と比較して画像枚数が少なかったため、自動分類精度の評価指標である、全ての画像に対して正常、異常それぞれを正しく的中させた割合を示す正診率を求めなかった。正確な分類精度評価を行うためには、画像枚数の偏りは解消するべきである。また、本研究は高い CT 値を有する石灰化群およびステント群と異常が指摘されなかった正常群を分類したが、プラークには脂質性や線維性といった低い CT 値を有するプラークも存在するため、これらの画像を DCNN に学習させることが必要である。




図4 DCNNが異常と誤認識した正常画像例

- (a) 石灰化ありと誤認識した画像例  
冠動脈下部に banding アーチファクトが含まれている
- (b) ステンツありと誤認識した画像例  
冠動脈内の造影効果が不均一である

石灰化群やステント群は全結合層を増やすことでの中率を向上させることができたが、その一方で正常群は全結合層が増えるとの中率が低下し、偽陽性数が増えた。その理由として、正常群でも冠動脈内の造影効果が不均一であったり、画像ノイズやアーチファクトが含まれたりした画像では、これらに起因する正常冠動脈内の淡いCT値変化を石灰化やステントとして誤認識したためと考えられる。実際に誤認識された正常画像例を図4に示す。全結合層を増やすことにより、ニューラルネットワークは複雑な関数を表現できるようになるため、非常に似通った特徴であっても分類できるようになる<sup>16)</sup>。これにより、似通った特徴を持つ石灰化とステントの分類が高精度に分類できるようになる。一方、正常な冠動脈内であっても血液と造影剤は均一に混合しないため、画像上非常に微弱な濃淡差が生じる。この濃淡差を全結合層が増えることで石灰化やステントとして誤認識されたと考えられる。画像ノイズはCCTA撮影時にX線量子数や検出器の感度、電気系ノイズ等で生じるものであり、アーチファクトも心拍動の変化や体動等で生じるもので、冠動脈異常ではないが、ノイズやアーチファクトが原因で正常な冠動脈内に淡いCT値変化が生じる。この石灰化やステントとして誤認識したと考えられる。正常群の的中率を向上させるためには、画像ノイズやアーチファクトの除去といった画像処理や、DCNNの更なる構造の見直し、誤認識した画像の再学習が必要である。また、本研究ではメモリ容量の関係から全結合層を5層以上に増やすことは検討できなかった。全結合層を5層以上に増やすことによる的中率の変化をさらに検討する必要がある。

本研究では画像単位によるhold out検証により精度検証を行った。Hold out検証は学習データとテストデータが完全に独立していることから、未知の画像に対してもほぼ同程度の精度を示すと考えられる。一方で、画像単位で学習データとテストデータを分類したため、同一

症例の画像が学習データとテストデータに分かれた可能性もある。そのため、類似した画像がDCNNの学習と検証に含まれている可能性があることから、検証の結果は未知の画像に対する分類精度よりも高く出る可能性がある。今後、より臨床的な精度検証を行うためには、症例単位でのhold out検証を実施した後、未知の画像による精度検証が必要となる。

## V 結論

本研究では、CCTAにおいて石灰化またはステントを有する冠動脈と正常な冠動脈の血管断面像を自動分類するシステムの精度向上を目的とし、DCNNにおける全結合層の構造を調整した。DCNNにはVGG-22を使用し、全結合層を3層から5層に増加させた。49症例における冠動脈の石灰化群、ステント群、正常群の自動分類を行った結果、全結合層5層のとき石灰化群とステント群の的中率が最も高くなった。したがって、CCTA画像を高精度に分類するためには、全結合層を深くするといったDCNNの構造の調整が有効であることが示唆された。また本研究により調整されたDCNNは、CCTA画像による冠動脈疾患のトリアージ補助の要素技術として有効である。

## 謝辞

本研究におけるCCTA画像取得にご協力いただいた新潟大学医歯学総合病院診療支援部放射線部門の皆様、富山赤十字病院医療技術部放射線技術課の皆様にご心より御礼申し上げます。

なお、本研究は新潟医療福祉大学研究奨励金の助成を受けた。

## 利益相反

本研究において利益相反に該当する事項はない。

## 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, <https://www.mhlw.go.jp/toukei/saikin/hw/jinkou/geppo/nengai18/index.html>, 2020 年 3 月 16 日.
- 2) Pontone G, Andreini D, Bartorelli AL, et al: Radiation dose and diagnostic accuracy of multidetector computed tomography for the detection of significant coronary artery stenoses: A meta-analysis, *International Journal of Cardiology*, 160(3): 155-64, 2012.
- 3) Schuetz GM, Zacharopoulou NM, Schlattmann P, et al: Meta-analysis: Noninvasive coronary angiography using computed tomography versus magnetic resonance imaging, *Annals of Internal Medicine*, 152(3): 167-77, 2010.
- 4) Task Force Members.: 2013 ESC guidelines on the management of stable coronary artery disease: The task force on the management of stable coronary artery disease of the European Society of Cardiology, *European Heart Journal*, 34(38): 2949-3003, 2013.
- 5) Budoff MJ, Achenbach S, Blumenthal RS, et al: Assessment of coronary artery disease by cardiac computed tomography: A scientific statement from the American Heart Association Committee on Cardiovascular Imaging and Intervention, Council on Cardiovascular Radiology and Intervention, and Committee on Cardiac Imaging, *Circulation*, 114(16): 1761-91, 2006.
- 6) Leipsic J, Abbara S, Achenbach S, et al: SCCT guidelines for the interpretation and reporting of coronary CT angiography: A report of the Society of Cardiovascular Computed Tomography Guidelines Committee, *Journal of Cardiovascular Computed Tomography*, 8(5): 342-58, 2014.
- 7) Schroeder S, Achenbach S, Bengel F, 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.
- 8) Husmann L, Gaemperli O, Schepis T, et al: Accuracy of quantitative coronary angiography with computed tomography and its dependency on plaque composition: Plaque composition and accuracy of cardiac CT, *The International Journal of Cardiovascular Imaging*, 24(8): 895-904, 2008.
- 9) Hiroyuki T, Koichi S, Iwao I, et al: Current status and future prospects of cardiac computed tomography for diagnosis of coronary artery disease, *J Jpn Coron Assoc*, 23: 55-61, 2017.
- 10) 長谷川晃, 李鎔範, 竹内悠ら: 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.
- 11) Krizhevsky A, Sutskever I, Hinton GE: ImageNet classification with deep convolutional neural networks, *Proc of 26th Annual Conference on Neural Information Processing Systems (NIPS)*, 1106-1114, 2012.
- 12) Simard PY, Steinkraus D, Platt JC: Best practices for convolutional neural networks applied to visual document analysis, *Proc of the Seventh International Conference on Document Analysis and Recognition (ICDAR)*, 2: 958-963, 2003.
- 13) McFee B, Humphrey E, Bello JP: A software framework for musical data augmentation, *Proc of 16th International Society for Music Information Retrieval Conference (ISMIR)*, 248-254, 2015.
- 14) Simonyan K, Zisserman A: Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*, 2014.
- 15) 二木来菜, 李鎔範, 長谷川晃ら: 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最適な深層学習モデルとパラメータの検証, *日本放射線技術学会東北支部雑誌* (in press)
- 16) 山下隆義: *イラストで学ぶ ディープラーニング*, 講談社, 第 1 版, 15-28, 東京, 2016.