

# 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

*Deep learning improvement for accurate automatic classification of calcification and stents in coronary computed tomography angiography*

長谷川 晃, 吉田 皓文, 児玉 直樹

新潟医療福祉大学医療技術学部診療放射線学科

**Key words:** deep convolutional neural network, wide residual network, rectified linear unit, dropout, coronary computed tomography angiography

## [Abstract]

The purpose of this study was to construct a deep learning algorithm to accurately classify calcification and stent from coronary computed tomography angiography (CCTA) images. 23,256 orthogonal cross-sectional images of coronary arteries from 24 CCTA images were used. Wide Residual Network (WRN) 50-2, WRN50-4, and WRN50-8 were constructed as deep learning. In addition, we added Dropout and changed the activation function of the output layer to rectified linear unit (ReLU) to compare the classification accuracy of calcification and stent. When the activation function was set to ReLU and the probability of Dropout was set to 0.6 in WRN50-2, the classification accuracy was the highest (0.7738). Therefore, it was suggested that adding Dropout and changing to ReLU to WRN50 were effective.

## [要旨]

本研究の目的は、coronary computed tomography angiography (CCTA) 画像から石灰化とステントを高精度に分類する深層学習を構築することである。深層学習にWide Residual Network (WRN) 50-2, WRN50-4, WRN50-8を構築した。さらにDropoutを追加し、出力層の活性化関数をrectified linear unit (ReLU) に変更した。WRN50-2で活性化関数をReLU, Dropout確率が0.6で正診率が0.7738となった。従ってWRN50にDropoutを追加することとReLUに変更することは有効である。

## 1. 緒言

虚血性心疾患の診断において、multi detector computed tomography (MDCT) による coronary computed tomography angiography (CCTA) を用いた冠動脈狭窄診断が普及している<sup>1), 2)</sup>。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や冠動脈ステント留置といった虚血性心疾患治療後の経過観察目的などで利用されている<sup>3)-5)</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%であり、陽性的中率が低い<sup>6)</sup>。これは、ブルーミング効果やCT装置の解像度の限界によるCCTA画像での石灰化やステントの膨張、ステントによる金属アーチファクトが原因として挙げられている<sup>6), 7)</sup>。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。CCTAで虚血性心疾患の確定診断をするためには、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。特に石灰化を伴うステント内腔の開存評価は困難となる。正確な評価を行うためには、石灰化とステントを認識し、さらにステント内腔領域を正確に認識することが必要である。

人工知能技術における画像認識には画像分類や物体認識があり、近年の画像の自動認識技術として deep convolutional neural network (DCNN) が挙げられる<sup>8)</sup>。2010年から始まった画像の自動分類の精度を競うImagenet Large Scale Visual Recognition Challenge (ILSVRC) では、近年、人間のエラー率5.3%を下回るDCNNが発表されており、DCNNは画像の自動認識技術として特に注目されている技術である<sup>8)</sup>。

そこで本研究は、CCTA画像からステント内腔の開存評価を行う画像診断支援技術の開発の一環として、石灰化とステントを正しく認識させるために、CCTA画像から石灰化と石灰化を伴うステント画像の自動分類を行うことを目的とした。特に本研究では、高い自動分類精度を有するDCNN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試みた。

HASEGAWA Akira, YOSHIDA Akifumi,  
KODAMA Naoki

Department of Radiological Technology, Faculty of Medical Technology, Niigata University of Health and Welfare

Received February 8, 2021; accepted October 16, 2021

## 2. 方法

### 2-1. CCTA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（承認番号2017-0094）、富山赤十字病院倫理委員会（承認番号：270）によって承認された。同意せず、研究をオプトアウトした症例は除外した。本研究では、冠動脈に石灰化プラークを有する症例または石灰化を伴うステント留置後の症例の24症例を対象とした（ $72.2 \pm 9.5$ 歳、男性13人）。CCTA撮影は2017年7月から2018年10月の間に、64列CT（Revolution GSI, GEヘルスケア・ジャパン株式会社）および384（ $2 \times 192$ ）スライスCT（SOMATOM Force, シーメンスヘルスケア株式会社）によって適時的に取得した。64列CTでは、管電圧を120kVp、管電流を210~245mAとして撮影した。造影剤はイオパミドール（イオパミロン370mgI/mL、バイエル薬品株式会社）を使用した。造影剤を25.8mgI/kg/sの流速で12秒間注入し、続いて30mLの生理食塩水を注入した。画像は $512 \times 512$ マトリックス、field of view (FOV)を160~180mmとし、0.312~0.35mmの面内解像度、0.625mmのスライス厚、0.312mmのスライス間隔で再構成した。384スライスCTでは、管電圧を100kVp、370quality reference mAsで撮影した。造影剤を25.9mgI/kg/sの流速で10秒間注入し、続いて30mLの生理食塩水を注入した。画像は $512 \times 512$ マトリックス、FOVを180~200mmとし、0.35~0.39mmの面内解像度、0.6mmのスライス厚、0.3mmのスライス間隔で再構成した。

ターゲット画像は、医用画像分析ワークステーション（Advantage Workstation VolumeShare 4.7, GEヘルスケア・ジャパン株式会社）で3次元画像処理した。CCTA画像から冠動脈を自動的に抽出し、冠動脈に垂直な $640 \times 640$ pixelsの直交断面像を得た。これ

らの画像を $256 \times 256$ pixelsにトリミングし、冠動脈を中心に配置した。さらにwindow widthを1,200HU、window levelを240HUに設定し、24bitのtrue color bitmap形式で保存した。これらのwindow widthとwindow levelは、特に石灰化とステントを含む画像の読影に使用される条件である。

石灰化のみの画像8,494枚、石灰化を伴うステント画像8,402枚、および石灰化やステントを伴わない画像（正常像）8,945枚、合計25,841枚の冠動脈直行断面像を取得した。対象画像の例をFig.1に示す。16年の経験を持つ診療放射線技師が分類を行い、28年の

Table 1 Wide residual network structure. The network width is determined by the coefficient  $k$ . The original architecture<sup>9)</sup> is equivalent to  $k=1$ . The convolution group is shown in parentheses. Where the numbers next to the parentheses (3, 4, 6, 3, respectively) are the numbers of blocks in the group

layer name	output size	block structure
conv1	$128 \times 128$	$7 \times 7$ , 64 stride 2
		$3 \times 3$ , max pool, stride 2
conv2	$64 \times 64$	$\left( \begin{array}{l} 1 \times 1, 64 \times k \\ 3 \times 3, 64 \times k \\ 1 \times 1, 256 \times k \end{array} \right) \times 3$
conv3	$32 \times 32$	$\left( \begin{array}{l} 1 \times 1, 128 \times k \\ 3 \times 3, 128 \times k \\ 1 \times 1, 512 \times k \end{array} \right) \times 4$
conv4	$16 \times 16$	$\left( \begin{array}{l} 1 \times 1, 256 \times k \\ 3 \times 3, 256 \times k \\ 1 \times 1, 1024 \times k \end{array} \right) \times 6$
conv5	$8 \times 8$	$\left( \begin{array}{l} 1 \times 1, 512 \times k \\ 3 \times 3, 512 \times k \\ 1 \times 1, 2048 \times k \end{array} \right) \times 3$
average pool	$1 \times 1$	
activation		softmax




Fig.1 Examples of target images

(a) Calcified image, (b) stent image with calcification, (c) normal image

経験を持つ放射線科医が正確に分類されていることを確認した。

## 2-2. Deep convolutional neural networkの構築

DCNNは50層を有するResidual Network (ResNet) 50<sup>9)</sup> から、各層のフィルター数を2倍に増やしたWide Residual Network (WRN) 50-2、4倍に増やしたWRN50-4、8倍に増やしたWRN50-8を構築した<sup>10)</sup>。WRNの構造をTable 1に示す。

またResNetにおけるResidual Blockの構造をFig.2に示す。

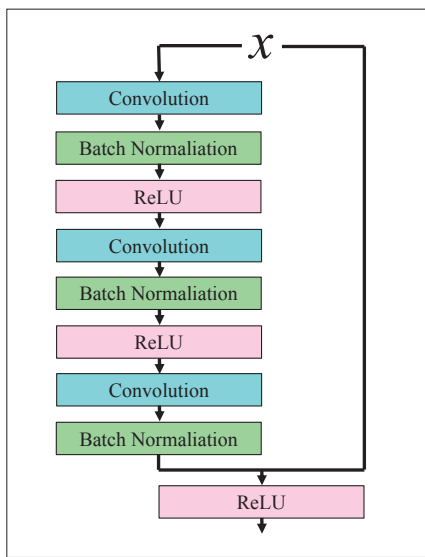


Fig.2 Structure of Residual Block. 'x' indicates the input value

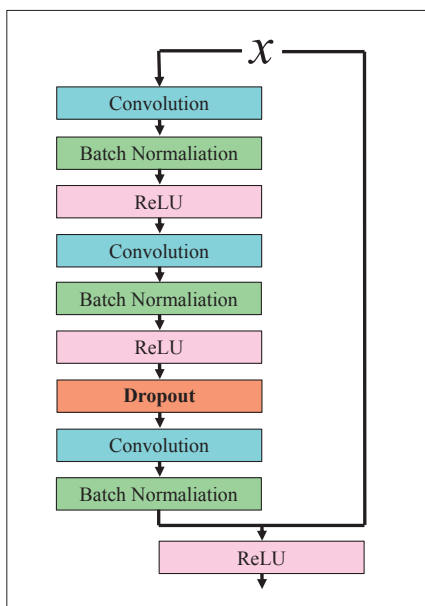


Fig.3 Structure of Residual Block with Dropout inserted

各WRNのパラメーター数はWRN50-2が94,212,355 parameters, WRN50-4が375,815,171parameters, WRN50-8が1,501,221,379parametersであった。

## 2-3. Dropoutの導入

Fig.3に示すように、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。

## 2-4. 出力層の活性化関数の変更

本研究では、出力層における活性化関数にReLUを用いることによる分類精度への影響を調査した。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のパラメーターが増加しても勾配消失を防ぐことを期待した。

## 2-5. DCNNの学習と精度評価

本研究でのDCNNの学習パラメーターは、繰り返し学習回数を示すepoch数を1,000回、1回の学習における重みパラメーターの変化率を示す学習率を0.001、学習時の入力画像枚数を示すバッチサイズを4、重みを更新する際の最適化手法はAdam<sup>11)</sup>とした。

まず、1,000epochでの学習曲線から、フィルター数を増やした場合、Dropoutを導入した場合、出力層の活性化関数をReLUにした場合での勾配消失および過学習の発生について調査した。そして学習過程での正解率と誤差率に変化がなく、学習曲線が直線になった場合は勾配消失が発生したと判断した。また学習回数が増えるごとに各epochでの学習時の正解率と学習後の検証時における正解率に乖離が生じた場合、過学習の発生と判断した。そして勾配消失および過学習が生じなかったパラメーターを正常に学習ができたパラメーターと判断し、分類精度の評価を行った。

各DCNNの分類精度を評価するために、resubstitution法で実施した<sup>12)</sup>。学習用データベースの24症例25,841枚をそのままテスト用データベースとして繰り返し用いて評価した。

DCNNの学習には、WRN50-2はDeepLearning BOX version 2 (DL-BOX v2, 株式会社ジーデップ・アドバンス)、WRN50-4はDeepLearning BOX II (DL-BOX II, 株式会社ジーデップ・アドバンス)、WRN50-8はDeepLearning BOX/alpha (DL-

Table 2 Hardware and software configuration

	detail		
	DL-BOX v2	DL-BOX II	DL-BOX/ $\alpha$
CPU	Xeon E5-1650v4 6core/12thread 3.6GHz	Intel Core i9-9900X 10core/20thread 3.5GHz	AMD EPYC 7542 32core/64thread 2.9GHz
Memory	128 GB	128 GB	256 GB
GPU	NVIDIA GeForce GTX 1080 (4 units)	NVIDIA TITAN RTX (2 units)	NVIDIA Quadro RTX 8000 (2 units)
GPU Memory	8 GB	24 GB	48 GB
OS	Ubuntu 16.04	Ubuntu 16.04	Ubuntu 18.04
Software library for DCNN	TensorFlow-GPU (ver. 1.12.0)		
Software library for NN	Keras		
Python	3.6.10		

Table 3 Training accuracy and presence or absence of vanishing gradient problem in the training process. '×' indicates that vanishing gradient problem has occurred

Full connect activation	Dropout rate	WRN50-2		WRN50-4		WRN50-8	
		Training accuracy	Vanishing gradient	Training accuracy	Vanishing gradient	Training accuracy	Vanishing gradient
Softmax	–	0.3303	×	0.2610	×	0.3652	×
	0.4	0.3303	×	0.2501	×	0.3652	×
	0.5	0.3303	×	0.2501	×	0.3652	×
ReLU	0.6	0.3303	×	0.2501	×	0.3652	×
	0.4	0.2156	×	0.3652	×	0.2501	×
	0.5	0.7672	○	0.7147	○	0.6837	○
	0.6	0.8553	○	0.2501	×	0.3846	×
	0.7	0.5322	×	–	–	–	–

BOX/ $\alpha$ , 株式会社ジーデップ・アドバンス) を使用した。各装置における実験環境の概要を Table 2 に示す。本研究では Keras を用いた DCNN の学習を行った。Keras とは、計算ライブラリの TensorFlow 上をバックエンドとして実行をするニューラルネットワークライブラリ<sup>13)</sup> であり、Graphics Processing Unit (GPU) の使用により、学習をより高速に行うことができる。

### 3. 結果

Table 3 に、各 DCNN における学習過程での正解率と勾配消失の発生の有無を示す。単純にフィルター数の幅を広げたり Dropout を導入したりしただけでは、勾配消失が発生し学習が進まなかった。一方で、

出力層の活性化関数を ReLU に変え、Dropout の確率を 0.5、WRN50-2 では 0.6 でも勾配消失の発生を抑制できた。

Table 4~7 に、勾配消失を抑制できた各 DCNN における resubstitution 法での分類結果の混同行列を示す。Table 4 は WRN50-2、Dropout の確率 0.5 における混同行列、Table 5 は WRN50-2、Dropout の確率 0.6 における混同行列、Table 6 は WRN50-4、Dropout の確率 0.5 における混同行列、Table 7 は WRN50-8、Dropout の確率 0.5 における混同行列である。縦軸は診療放射線技師が分類し、放射線科医が正しく分類されていることを確認した CCTA 画像の各分類枚数を、横軸は各 DCNN が分類した画像枚数を示している。WRN50-2、Dropout の確率が 0.5 のとき、WRN50-4、Dropout の確率が 0.5 のときで



Table 4 Confusion matrix with WRN50-2 and Dropout rate 0.5

		Predictive classification result		
		Calcification	Normal	Stent
Gold standard	Calcification	7432	1062	0
	Normal	4273	4672	0
	Stent	7354	1048	0

Table 5 Confusion matrix with WRN50-2 and Dropout rate 0.6

		Predictive classification result		
		Calcification	Normal	Stent
Gold standard	Calcification	7483	917	94
	Normal	1866	5663	1416
	Stent	1015	536	6851

は、ステントに分類された画像はなかった。WRN50-2, Dropoutの確率0.5のときにおける、正常を石灰化やステントと誤って分類した偽陽性率は0.4777, 石灰化やステントを誤って正常と分類した偽陰性率は0.1249であった。以下、WRN50-2, Dropoutの確率0.6のときにおける偽陽性率は0.3669, 偽陰性率は0.0859, WRN50-4, Dropoutの確率0.5のときにおける偽陽性率は0.3951, 偽陰性率は0.1458, WRN50-8, Dropoutの確率0.5のときにおける偽陽性率は0.0569, 偽陰性率は0.2513であった。また正解率は高い順にWRN50-2, Dropoutの確率0.6のときで0.7738, WRN50-8, Dropoutの確率0.5のときで0.6866, WRN50-4, Dropoutの確率0.5のときで0.5246, WRN50-2, Dropoutの確率0.5のときで0.4684であった。

#### 4. 考 察

CCTAでステント治療後の経過観察を行う場合、ステント素材による金属アーチファクトやブルーミング効果、CTの解像度の限界により、石灰化を伴うステント画像では石灰化とステントストラットの領域境界が不明瞭になる。石灰化とステントの領域境界が不明瞭になると、ステント内腔で再石灰化が進行しているか判断が困難となり、ステント内腔の開存状態を評価することが難しくなる。従ってCCTA画像で石灰化やステントストラットの領域を正確に認識し、ステント内腔の開存評価が正確にできるようにすることは大

Table 6 Confusion matrix with WRN50-4 and Dropout rate 0.5

		Predictive classification result		
		Calcification	Normal	Stent
Gold standard	Calcification	8145	349	0
	Normal	3534	5411	0
	Stent	6298	2104	0

Table 7 Confusion matrix with WRN50-8 and Dropout rate 0.5

		Predictive classification result		
		Calcification	Normal	Stent
Gold standard	Calcification	4149	3875	470
	Normal	501	8436	8
	Stent	2854	390	5158

切なことである。そのためにも、CCTA画像が持つ情報を詳細に分析できる診断支援システムの構築は有用である。本研究は、CCTA画像の詳細な分析をする診断支援システムが、まずは石灰化とステントを正確に認識できるようにすることを目指している。

石灰化を含むCCTA画像と石灰化を伴うステント部のCCTA画像は、非常に似通った特徴を持つことが多い。類似性の高い特徴を持つ画像を分類するには、微妙な違いを認識するために複雑な識別ができるDCNNを用意する必要がある。DCNNは層を増やすことでより複雑な認識や予測が可能となる。一方で、誤差逆伝播法による予測結果と実際の正解との誤差をフィードバックする上で、層を深くすると活性化関数の微分に掛け合わされて、伝播していく誤差が小さくなり、最終的にはフィードバックすべき誤差がなくなる勾配消失問題がある<sup>8)</sup>。これにより、単純に層数を増やすことには限界があったため、shortcut connectionにより手前の層の入力を後ろの層に直接つなげたResidual Blockを用いることで、層の入力と出力の残差を学習する手法が考案された<sup>9)</sup>。このResidual Blockを多層化することで構成されたのがResNetである。ResNetは残差ブロックを導入することで多層化の限界を押し上げることができ、2015年のILSVRCで人間のエラー率5.3%を下回る3.57%を実現した。またResNetは層を数千まで増やしても、それに合わせてパフォーマンスが向上することで知られている。これとは逆に、層の深さを浅くしてフィルター数を増やすことで、層が深く幅の狭い従来の

ResNetに比べて良いパフォーマンスを出すことができる。この各層のフィルター数を増やすことは幅を広くすると表現され、幅を広くしたResNetがWRNである<sup>10)</sup>。幅を広くすることでパラメーターが増加し、WRNではResNetより複雑な認識ができるようになる。さらにWRNのトレーニングにかかる時間がResNetに比べ半分近くになる。従ってWRNは、類似性の高い石灰化のみのCCTA画像と、石灰化を伴うステントのCCTA画像を正確に分類するには有用であると考えられる。

Resubstitution法での分類結果はWRNのフィルター数を増やすことで向上した。従ってフィルター数の増加は正確な分類には有効である。しかしながら、WRNのフィルター数を増やすとパラメーター数が非常に大きくなるため計算回数が膨大になり、WRN50-2で830京回、WRN50-4で3,300京回、WRN50-8で1.3垓回となり、多くの計算時間を費やした。加えてWRNのフィルター数を増やすことで、GPUのメモリーサイズといった対応できる環境に制限が生じた。従ってフィルター数を単純に増加させることは慎重に検討するべきである。

本研究では、出力層における活性化関数をReLUにし、Residual BlockにDropoutを導入することで勾配消失の問題を解消することができた。これは、通常用いられているsoftmax関数では出力値が0から1であるのに対し、ReLU関数は入力値が0より上の場合には出力値が入力値と同じ値となる関数であることから、入力値が大きくなるほど活性化関数の違いによる出力値の差が大きくなり、結果的にReLU関数を使った方が分類に必要な信号差が生じたものと考えられる。出力層における活性化関数は、分類問題では通常、softmax関数が用いられる<sup>8)</sup>。これは、softmax関数の出力値が0から1であり、出力値の総和が1になるため、分類確率として見なせるからである。またReLUは通常、中間層における活性化関数に用いられており、勾配消失問題の解消に有効とされている。出力層における活性化関数をReLUにし、Residual BlockにDropoutを導入することは、WRNのフィルター数を増やすことと同様に精度を向上させることができる。従って計算環境に制限があっても高い精度の分類ができるDCNNを導入することができる。

Dropoutは一定の確率でランダムにニューロンを無視して学習を進めることで、複数の独立したDCNNを学習していると見なすことができる。つまりは学習時にランダムでニューロンを消去していくこ

とで、毎回異なるDCNNを学習していることになる。先行研究では、Dropoutを導入することで分類精度を向上できることを報告している<sup>9)</sup>。Dropoutは一定の確率でランダムにニューロンを無視して学習を進める手法であり、過学習を防ぐことができる<sup>14)</sup>。過学習はパラメーターが増えることでも発生することが知られている<sup>14)</sup>。そこで本研究では、過学習の予防のためにDropoutを導入し分類精度への影響を調査した。複数のDCNNの合議制で予測をするとより良い結果が得られることが分かっているが、その分計算コストが増大する。Dropoutはただ学習時にランダムでニューロンを選択していただくだけであるため、簡単に複数のDCNNの出力結果の平均値を認識結果とすることができる。本研究では、Dropoutの確率を0.5ないし0.6としたことで程よく認識結果が分かれたものとする。

本研究には課題もある。第一に、混同行列の結果から、臨床で用いるには十分な分類精度を有すると判断することは困難である。正解率が最も高かったWRN50-2、Dropoutの確率0.6の場合であっても偽陰性率が8.6%、偽陽性率が37.0%であったことから、さらに正しい分類ができるように症例数の追加やパラメーターの調整が必要である。先行研究<sup>15)</sup>から、偽陽性が多い原因は正常画像のコントラストやアーチファクトによるものと考えられるが、DCNNが捉えている特徴をheat mapで確認した上でパラメーターを調整する必要がある。第二に、症例数が24症例と少なかったことである。DCNNは症例数が多いほど正確な認識ができるため、症例数をさらに増やすべきである。第三に、epoch数・学習率・バッチサイズ・重みを更新する際の最適化手法など、学習時のパラメーターについて検討を行っていない。DCNNの学習はこれらの学習パラメーターによっても精度が変わるため、特に勾配消失問題が解消できた条件においては、学習時のパラメーターについても検討し、より正確なDCNNの分類精度を検証するべきである。第四として、分類精度の評価方法にresubstitution法を用いていることである。Resubstitution法はDCNN開発の初期段階での学習精度の確認や、手法の将来的な可能性の判断に用いられるため、本研究における評価手法としては妥当であると考えられる。一方で、resubstitution法は学習用データベースをそのままテスト用データベースとして利用しており、DCNNが未知の症例で検証しているわけではないため、過大評価されやすい。従って交差検証やhold out検証な

ど、学習用データベースとテスト用データベースを分けた検証法でさらに調べる必要がある。

本研究では、石灰化と石灰化を伴うステントの自動分類のみを行ったが、内腔の開存について評価ができるようにするためには、石灰化を伴うステント画像から石灰化領域を正しく認識できているかについても検討する必要がある。

## 5. 結論

WRN50を用いて、CCTA画像における石灰化を伴うステント画像と石灰化のみの画像の自動分類を試みた。WRN50の出力層における活性化関数をReLUに変更し、Residual Blockのconvolution層にDropoutを挿入した結果、WRN50-2のDropout確率0.6で最も高い正解率となり、0.7738であった。epoch数・学習率・バッチサイズ・最適化手法といった学習パラメーターの調整、および症例数の追加のような検討事項はあるものの、WRN50の適用は有効であり、さらに出力層の活性化関数にReLUを適用することと、Residual Blockのconvolution層にDropoutを追加することは有効であることが示唆された。

## 6. 謝辞

本研究の一部はJSPS科研費20K20233の助成を受けたものである。

### 表の説明

Table 1	Wide residual networkの構造。ネットワークの幅は係数 $k$ によって決定される。元となる構造 <sup>9)</sup> は $k=1$ と同等である。畳み込み層のグループは括弧内に示される。括弧の横の数字（上から3, 4, 6, 3）は、グループ内のブロックの数を示す
Table 2	ハードウェアとソフトウェアの構成
Table 3	トレーニング時における分類精度と勾配消失問題の有無。「×」は勾配消失問題が発生したことを示す
Table 4	WRN50-2, Dropout率0.5における混同行列
Table 5	WRN50-2, Dropout率0.6における混同行列
Table 6	WRN50-4, Dropout率0.5における混同行列
Table 7	WRN50-8, Dropout率0.5における混同行列

### 図の説明

Fig.1	対象画像例 (a) 石灰化画像, (b) 石灰化を伴うステント画像, (c) 正常画像
Fig.2	Residual Blockの構造。「 $x_i$ 」は入力値を示す
Fig.3	Dropoutを入れたResidual Blockの構造

### 参考文献

- Pontone G, 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): 155-164, 2012.
- Schuetz GM, et al.: Meta-analysis: Noninvasive coronary angiography using computed tomography versus magnetic resonance imaging. *Annals of Internal Medicine*, 152(3): 167-177, 2010.
- 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.
- Budoff MJ, 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, Council on Clinical Cardiology. *Circulation*, 114(16): 1761-1791, 2006.
- Leipsic J, 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): 342-358, 2014.
- 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.
- Husmann L, 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.
- 藤田一弥, 他: 実装ディープラーニング. オーム社, 2016.
- 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, June 2016, 770-778.
- Zagoruyko S, et al.: Wide residual networks. *CoRR*, vol. abs/1605.07146, 2016.
- Diederik P. Kingma, et al.: Adam: A Method for Stochastic Optimization. *international conference on learning representations (ICLR)*: 2015.
- 藤田広志, 他: 新医用放射線科学講座 医用画像情報工学. 医歯薬出版株式会社, 2018.
- Keras Documentation: Keras: The Python Deep Learning library. <https://keras.io/> (Accessed 10 Jan. 2021)
- N. Srivastava, et al.: Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(1): 1929-1958, 2014.
- 長谷川 晃, 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.