

修士論文

畳み込みニューラルネットワークと  
解剖学的知識を用いた  
腹部造影 CT 画像からの腎動脈枝の自動抽出

小野 真理子

2018 年 3 月 15 日

奈良先端科学技術大学院大学  
情報科学研究科 情報科学専攻

本論文は奈良先端科学技術大学院大学情報科学研究科に  
修士(工学) 授与の要件として提出した修士論文である。

小野真理子

審査委員：

佐藤 嘉伸 教授	(主指導教員)
向川 康博 教授	(副指導教員)
大竹 義人 准教授	(副指導教員)
横田 太 助教	(副指導教員)

# 畳み込みニューラルネットワークと解剖学的知識を用いた

## 腹部造影 CT 画像からの腎動脈枝の自動抽出\*

小野 真理子

### 内容梗概

腹部血管は複雑な分岐構造をしているため、血管の構造情報を医師に提示することは、診断精度の向上等において重要である。そのため、3次元CT画像から血管領域を計算機で自動的に抽出し、画像診断や治療計画に用いることが望まれる。現在、線強調処理は血管の抽出及び、血管認識の前処理として広く用いられている。しかし線強調処理は、細い血管や、血管に近い画像エッジを持つ骨等の過抽出が発生し、これらの課題が後に続く動脈枝の抽出処理に悪影響を及ぼしていた。本研究では、腹部動脈の中でも特に分岐パターンの多様性が大きい、腎動脈枝の抽出を目標とする。提案手法では畳み込みニューラルネットワーク（CNN）を用いて動脈枝識別器を作成し、従来の手法では強調が容易でなかった動脈枝の強調処理の精度向上を目指す。手動セグメンテーションを行った腹部造影CT画像30症例を用いた実験を行い、AlexNetベースのネットワークで作成した動脈識別器、U-Netベースのネットワークで作成した動脈識別器と、線強調処理を比較した結果、CNNを用いた血管抽出精度の向上を確認した。

### キーワード

腎動脈, 血管自動抽出, 畳み込みニューラルネットワーク, U-Net, 造影CT画像

\*奈良先端科学技術大学院大学 情報科学研究科 情報科学専攻 修士論文,  
NAIST-ISMT1651030, 2018 年03 月15 日.

# Automated segmentation of renal arterial branches in abdominal contrast enhanced CT images using Convolutional Neural Network and knowledge of vessel anatomy \*

Mariko Ono

## Abstract

Since abdominal blood arteries have complicated branching structures, presenting the structural information of blood artery to a doctor is important for precise diagnosis. Therefore, it is valuable to automatically extract the vascular region from the 3D-CT image with a computer and use it for image diagnosis and treatment planning. In previous work, line enhancement filter has been widely used as a preprocessing for blood artery extraction and blood artery recognition. However, in the conventional processing, oversights are frequently found in thin blood vessels and false detections of image edges have also occurred. In this experiment, I aim to extract renal arterial branches. Renal arteries have various branching patterns, so it is important to understand the pattern. I construct the artery discriminator using Convolutional Neural Network (CNN). I aim to improve the processing accuracy for emphasizing arteries which are not easy to emphasize by the previous method. In my experiment, 30 contrast enhanced 3D-CT images with manual trace segmentation were used for training and validation in a leave-one-out cross-validation. I compared the accuracy of the blood vessel discriminator made with reference to AlexNet, made with reference to U-Net and made with line enhancement filter. As a result, I discovered that the method using CNN gave better results than previous one.

## Keywords:

Renal artery, automated segmentation of arteries, Convolution Neural Network, U-Net, contrast enhanced CT images

---

\*Master's Thesis, Department of Information Science, Nara Institute of Science and Technology, NAIST-IS-MT1651030, March 15, 2018.

# 目次

第1章	はじめに	1
第2章	方法	3
2.1	方法概要	3
2.1.1	従来研究	3
2.1.2	提案手法	3
2.2	動脈識別器の作成（学習フェーズ）	4
2.2.1	AlexNet ベースの動脈強調器	5
2.2.2	U-Net ベースの動脈強調器	6
2.3	腎動脈の自動抽出（認識フェーズ）	7
2.3.1	動脈尤度画像の作成	7
2.3.2	腎動脈流入アトラスの適用	7
2.3.3	最適経路探索	8
第3章	実験	9
3.1	実験条件	9
3.1.1	使用するデータセット	9
3.1.2	学習データの作成	9
3.1.3	臓器セグメンテーション	10
3.1.4	評価方法	11
3.1.5	血管の太さの計算	11
3.2	実験内容	13
3.3	実験結果	13
第4章	考察	16
第5章	総括	21
	謝辞	22
	参考文献	23
	発表リスト	25

## 図目次

図 1 腎臓, 腎動脈の構造.....	2
図 2 腎動脈の分岐パターンの例.....	2
図 3 提案手法の概要.....	4
図 4 AlexNet ベースのネットワークの構成.....	5
図 5 U-Net ベースのネットワークの構成.....	6
図 6 腎臓と腎動脈バウンディングボックス内の動脈と腎臓, 大動脈マスク画像.....	10
図 7 腎動脈の太さ.....	12
図 8 各手法の精度比較.....	14
図 9 各手法で作成した動脈尤度画像の MIP 表示.....	14
図 10 細い血管が大動脈から分岐している例の腎動脈抽出結果.....	17
図 11 右腎臓流入領域の抽出結果.....	18
図 12 腎動脈の抽出に失敗した例.....	19
図 13 失敗例の CT 画像 MIP 表示.....	20

## 表目次

表 1 使用する 3 次元腹部造影 CT 画像について .....	9
表 2 提案手法の入力, 出力パッチサイズ .....	13
表 3 腎動脈の自動抽出例数結果.....	15
表 4 細い腎動脈領域の Recall.....	15

## 第 1 章 はじめに

人体内を巡る血管は複雑な分岐構造をしているため、血管の構造情報を医師に提示することは、診断精度の向上等において重要である。特に、肝臓や脾臓、腎臓といった多くの消化器を持つ腹部の血管は、分岐構造や本数といった、血管パターンの多様性が非常に大きい [1] ため、構造の理解は、低侵襲治療において鍵となる問題である。これまでは検査においてカテーテル血管造影法を行っていたが、近年、X 線 CT (Computed Tomography) や MRI (Magnetic Resonance Imaging) などの医用画像撮影装置の発展・普及により、より低侵襲で高解像度な医用画像データの取得が容易になった。そして現在、この医用画像データを用いた画像解析を行うことで画像中の特定領域の抽出する研究が盛んである [2, 3]。本研究では、腹部の血管の中でも、特に血管パターンの多様性が大きい腎動脈の抽出を目標とし、3 次元 CT 画像からの腎動脈枝の自動認識を行う手法を提案する。

本研究の対象である腎動脈は、図 1 のように大動脈から左右の腎臓へ流れる動脈である。医学の解剖学についての書籍 [1, 4] に示されているような典型的な腎動脈の構造は、大動脈から左右それぞれ 1 本ずつ、太い動脈が分岐し、腎門と呼ばれる領域に入ると 5~7 本の分岐に分かれて腎臓内部の皮質へ通じている (図 2(a))。しかし、このような典型的な構造は全体の 60% ほどしか存在しておらず [1]、腎門より大動脈に近い段階で分岐するもの (早期分岐) (図 2(b)) や、そもそも 2~4 本の複数本の動脈が大動脈から分岐して腎臓へ通じる例 (図 2(c)) もある。腎動脈の構造パターンを事前に認識することは、腎移植や腎外傷、血管形成術などの検査及び治療において、非常に重要であるとされている [1, 5]。術前に腎動脈の構造や本数を把握しておくことは必須であるが、腎動脈を含む、腹部血管領域は体内の他の領域と比較しても個人差が大きく、体内を複雑に走行しており、CT 画像から直接目視で把握することが容易でないため、計算機による支援が有用である。

上で述べたように、腹部血管の抽出は医療応用上有用であるため、これまでも多くの研究が報告されている [6, 7]。なかでも、血管が線状の形をしていることに着目して、線強調処理 [8] を血管の抽出及び、血管認識の前処理として用いているものが多く報告されている [9, 10]。しかし、線強調処理後の血管候補領域では、細い血管や、血管の分岐部での見落とし、画像エッジの過抽出が発生し、それらが後に続く処理に悪影響を及ぼしていた。

近年、画像認識及び機械学習の分野では、Deep Neural Network を用いた手法が盛んに開発され、多くの問題において成功を収めている。2012 年、Alex らの ImageNet での優勝 [11] から着目されるようになった CNN は、近年、画像処理の分野で広く活用され、医用画像の分野にも幅広く使用されている。本研究では畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) を血管候補領域抽出の際の前処理に使用することを提案する。従来の手法では強調が容易でなかった血管強調処理の精度向上を目指す。



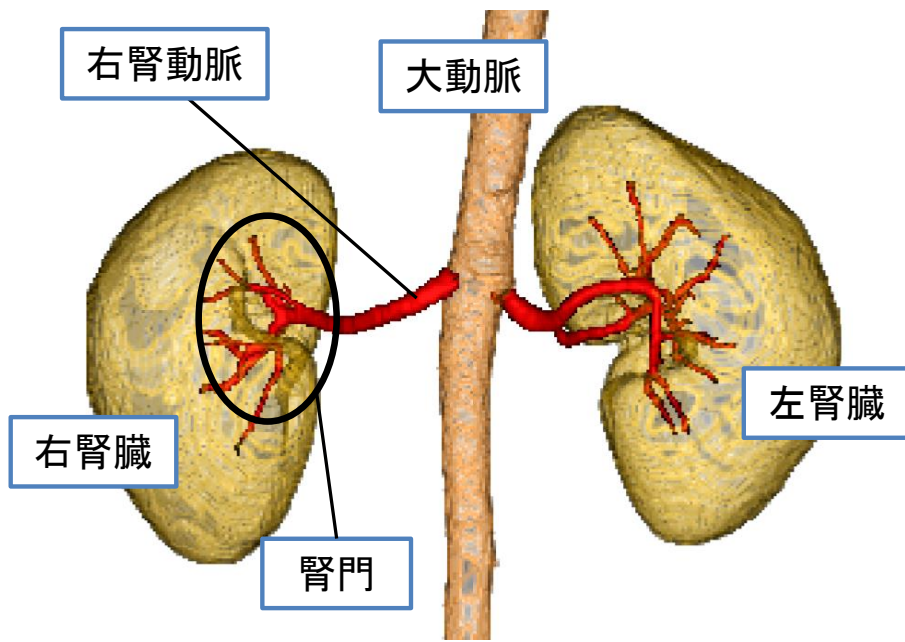



図 1 腎臓, 腎動脈の構造



2(a) 典型的な腎動脈の構造

2(b) 早期分岐している腎動脈

2(c) 複数本の腎動脈が大動脈から分岐している

図 2 腎動脈の分岐パターン例

## 第2章 方法

### 2.1 方法概要

#### 2.1.1 従来研究

第1章で述べた通り，腹部血管の抽出では，前処理に線強調処理を施したものが多く報告されている．先行研究 [9]では，血管が管状構造の集合であるという解剖学的特徴を利用し，3次元 CT 画像に線強調処理を施すことで，腹部動脈領域候補を強調している．腹部造影 CT 画像の中でも，動脈が明るく造影される動脈早期相を利用し，CT 値の閾値処理を行った画像と，線強調処理の閾値処理後の画像の論理積集合を抽出することで動脈候補領域を抽出する．そして腎動脈は大動脈から分岐し，腎臓へ通じる動脈であることを利用し，大動脈領域と腎臓領域を用いて経路探索を行うことで，腎動脈を認識する．

しかし，この手法では直径 1~2 ボクセル程度の細い動脈を見落とししてしまうことがある．細い動脈は動脈早期相を使用しても他の動脈ほど強く造影されないことが大きな原因として挙げられる．さらに，動脈に近い画像エッジを持つ骨等の過抽出が発生し，経路探索の際に悪影響を及ぼしていた．

#### 2.1.2 提案手法

提案手法の概要を図 3 に示す．本研究では，動脈候補領域抽出の前処理として，畳み込みニューラルネットワーク (Convolutional Neural Network, 以下 CNN) を使用することを提案する．CNN は畳み込み層やプーリング層を複数重ね合わせて計算するニューラルネットワークのひとつで，位置情報の変化に頑健なネットワークである．本研究では，以下のステップで処理を行なっている．認識フェーズにおいて，動脈候補領域の抽出から先のステップは，先行研究 [9]の手法を使用する．この手法は，左右の腎臓領域，大動脈領域が抽出済みであることを前提とする．

1. 学習フェーズ
  - a. CNN を用いた動脈識別器の作成
2. 認識フェーズ
  - a. 動脈候補領域の抽出
  - b. 最適経路探索

提案手法では学習フェーズとして，3次元腹部造影 CT 画像と，その画像に含まれる腎動脈領域を手動抽出したラベル画像を使用し，CNN で動脈識別器を作成する．認識フェーズと

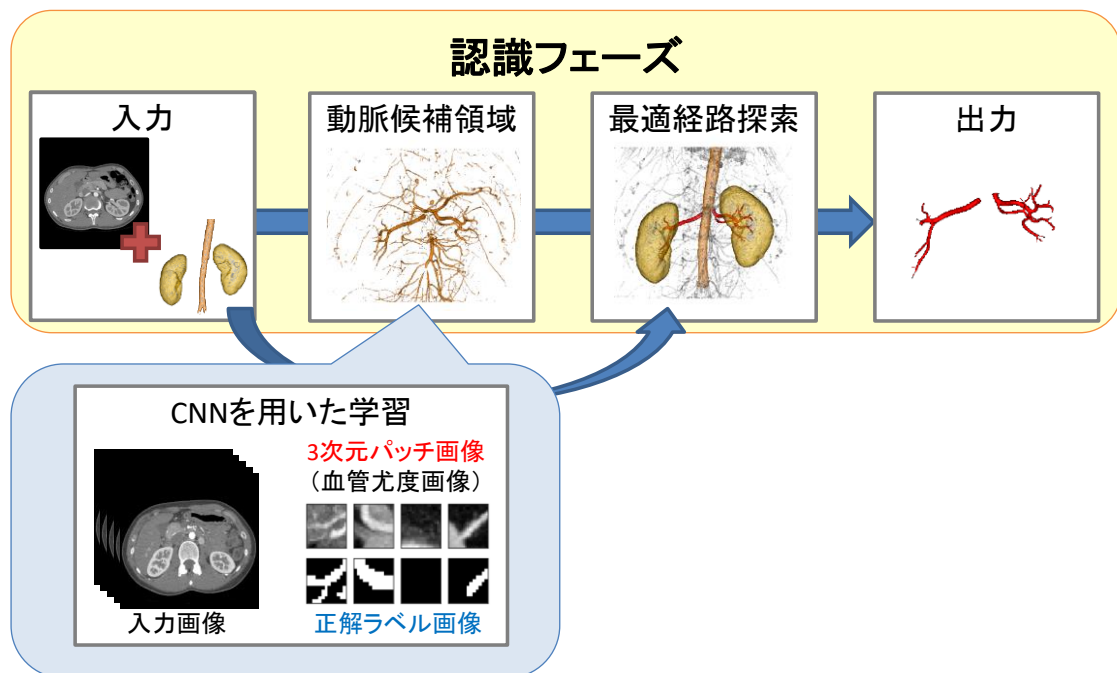


図 3 提案手法の概要

して新しいテスト画像が入力されたとき，その動脈識別器を使用することで動脈尤度画像を得ることができる．次に得られた動脈尤度画像から動脈候補画像を作成し，腎臓領域画像と大動脈領域画像を用いて経路探索を行うことで，腎動脈を抽出することができる．

## 2.2 動脈識別器の作成 (学習フェーズ)

本研究では，3次元腹部造影 CT 画像を直接識別器に与えず，腎臓と腎動脈全体を含む境界線 (バウンディングボックス) 内の領域内から，複数の 3次元パッチ画像を取得する．腹部 CT 画像の中で腎動脈領域は，実験データ内では平均して全体の 0.015%ほどであるため，画像全体を学習データとして用いると腎動脈以外の領域のデータが圧倒的に多くなる．そこで本手法では以下の 2種類の 3次元パッチを，それぞれ CT 画像と，血管のラベル付けされた画像からセットで取得し，学習データとして使用する．ここで使用する動脈中心線は Lee らの手法 [12]を使用した．

- 腎動脈中心線を中心に，取得したパッチ ( $p_w \times p_h \times p_d \times N$ )
- 腎臓と腎動脈全体を含む境界線 (バウンディングボックス) 内からランダムに取得した，上記パッチと同数のパッチ ( $p_w \times p_h \times p_d \times N$ )

ここで， $N$ は腎動脈中心線のボクセル数である．

### 2.2.1 AlexNet ベースの動脈強調器

畳み込みニューラルネットワーク (CNN) は深層学習モデルのひとつで、近年、物体認識等で多くの研究成果が報告されている [13, 14, 15]. 提案手法では CNN を用いて、各ボクセルが動脈であるかどうかを識別させる. 入力画像は 3 次元パッチ画像で、提案手法では、AlexNet [11] をベースにしてネットワークを構築し、主に 3 次元畳み込み層、3D Max Pooling, Batch normalization を用いる. 提案手法のネットワークの構成を図 4 に示す. 活性化関数として正規化線形関数 (ReLU 関数) と、シグモイド関数を使用し、ネットワークの構造には標準的な順伝搬型を採用した. 目的関数には交差エントロピーを使用し、学習の最適化アルゴリズムとして Adaptive Momentum Estimation (Adam) を用いた.




図 4 AlexNet ベースのネットワークの構成

## 2.2.2 U-Net ベースの動脈強調器

CNN で行われる画像のクラス分類（画像認識）では，畳み込み層が物体の局所的な特徴を抽出する役割を担い，プーリング層が物体の位置情報をぼかすことで位置ずれを許容する役割を担っている．そこで近年，医用画像からの特定の領域抽出では，物体の局所の特徴と全体的特徴の両方を統合して学習させることができる U-Net [16]を用いた研究が報告されている [17]．そこで，本研究では AlexNet ベースのネットワークとの比較として，U-Net をベースとして作成した動脈強調器を導入する．本研究にて使用する U-Net のネットワーク構成を図 5 に示す．主に 3 次元畳み込み層，3D Max Pooling, Batch normalization を，活性化関数として ReLU 関数とシグモイド関数を使用する．目的関数には交差エントロピーを使用し，学習の最適化アルゴリズムには Adam を使用した．

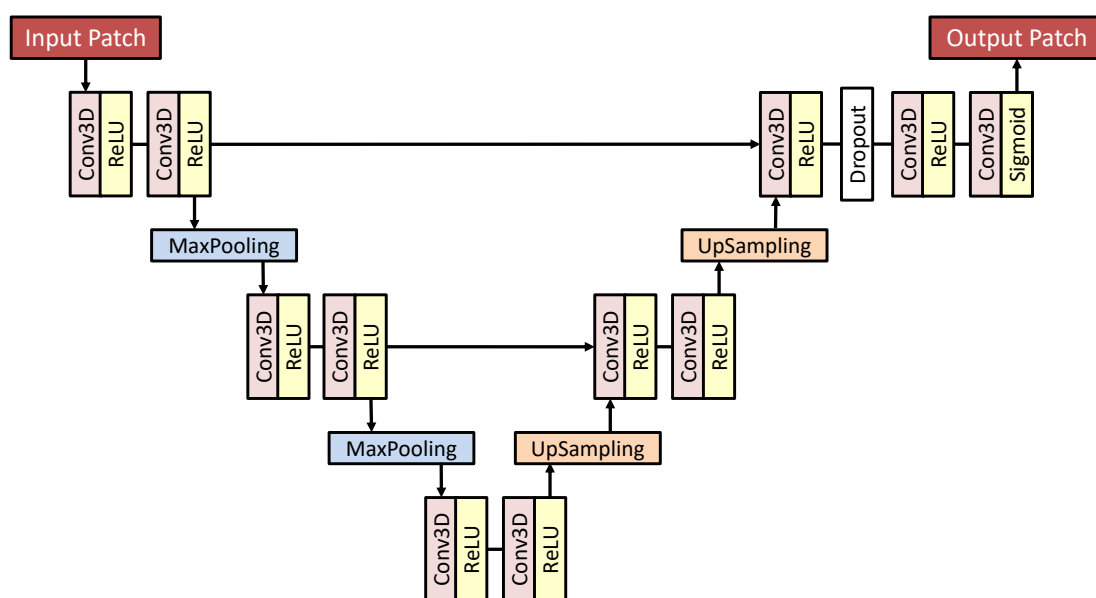


図 5 U-Net ベースのネットワークの構成

## 2.3 腎動脈の自動抽出（認識フェーズ）

### 2.3.1 動脈尤度画像の作成

動脈強調の対象となる画像は、学習フェーズのときと同様に、一定の間隔ごとに  $p_w \times p_h \times p_d$  の 3次元パッチに分割し、CNN で作成した識別器に入力することで動脈尤度パッチを得る。得られたパッチを分割前の位置に戻し、画像全体の動脈尤度を得ることができる。

### 2.3.2 腎動脈流入アトラスの適用

先行研究 [9]では、腎動脈が腎門領域から腎臓内部に通じるという解剖学的特徴を利用して流入点アトラスを事前に作成し、適用させる。腎動脈候補が腎臓に流入する領域を制限することで、抽出の見落としを増やすことなく、誤抽出の数が削減可能となる。本研究でも、この手法を適用する。制限する範囲は、学習データから得られる事前情報を用いて設定する。学習データには腹部 CT 画像から手動で抽出された腎動脈枝と腎臓の二値画像を用いる。流入点を動脈中心線と腎臓表面の交点として定義し、学習データから自動的に抽出する。流入点アトラスは次の手順で作成される。

1. 腎動脈領域を細線化 [12]し、腎臓表面との交点を抽出することで全学習データから流入点を取り出す
2. 腎臓の平均形状を作成し、各学習データの腎臓形状と平均形状の頂点を対応付ける
3. 全学習データの流入点に対応する平均形状の頂点を流入点アトラスとする。

そして、作成された腎動脈流入点アトラスを抽出対象の症例に適用する。

### 2.3.3 最適経路探索

CNN で得られた動脈尤度画像から，腎動脈候補領域の抽出を行う．まず，動脈尤度画像に対して閾値 $t$ で閾値処理を行い，腎動脈候補領域を抽出する．続いて，得られた動脈候補領域から，先行研究の手法を用いて経路探索を行う [18]．腎動脈は，大動脈から分岐し，腎臓へ通じる動脈である，という解剖学的特徴を使用して，動脈候補領域と腎臓の交点を始点，大動脈との交点を終点として，もっともコストの小さい経路を探索する．抽出された動脈候補領域は，CT 画像のノイズや部分容積効果などの影響により，途切れてしまう場合がある．対応として，動脈候補領域の膨張を用いる．まず，動脈候補領域を距離画像 $d(x)$ に変換する．この $d(x)$ は，候補領域の内部に負の値，外部に正の値を持つ画像である．距離画像をもとに，探索時のコストを持つ，コスト画像  $x, f_{cost}(x)$  を以下の式から作成する．

$$f_{cost}(x) = \begin{cases} d(x) - d_{min} & d(x) \leq 0 \\ k(d(x) - d_{min}) & 0 < d(x) \leq n \\ \infty & otherwise \end{cases}$$

ここで， $k$ は候補領域の途切れを埋めるためにかかる追加のコスト， $n$ は途切れを埋めることができる距離， $d_{min}$ は距離画像 $d(x)$ の最小値である． $d_{min}$ はコスト画像を非負にするために用いられる． $x_i$ と $x_{i+1}$ を 26 近傍で隣接するボクセル，経路を $x_1, x_2, \dots, x_N$ としたとき，その経路に対するコストを次の式で定義する．

$$\sum_{i=1}^{N-1} D(x_i, x_{i+1}) f_{cost}(x_i)$$

ここで， $D(a, b)$ は $a, b$ 間のユークリッド距離である．最適経路探索のアルゴリズムにはダイクストラ法を用いる．

## 第3章 実験

### 3.1 実験条件

#### 3.1.1 使用するデータセット

腹部造影 CT 画像 50 例を用いた実験により，提案手法の精度調査を行なった．本研究で使用する 3 次元 CT 画像は，大阪大学医学部附属病院から提供いただいた 50 例であり，そのうち 30 名は肝臓ドナー候補者，20 名は腎臓ドナー候補者の腹部を撮影した画像である．このうち，肝臓ドナー画像 30 例を精度評価用，腎臓ドナー画像 20 例を学習用として使用した．実験に使用した CT 画像の仕様を表 1 に示す．本手法では，多時相撮影された腹部造影 CT 画像の中でも，最も動脈が強調される，動脈早期相と呼ばれる時相を使用する．

表 1 使用する 3 次元腹部造影 CT 画像について

提供機関	大阪大学医学部附属病院
被験者	肝ドナー候補 30 名，腎ドナー候補 20 名
腎臓総数	100 例
画像サイズ	512×512 [画素]
枚数	281～473 [枚]
ボクセルサイズ	0.674×0.674×0.625 [mm]
時相	動脈早期相

#### 3.1.2 学習データの作成

細い動脈の抽出精度向上のため，使用する学習データ 50 例のうち，40 例の腎臓と腎動脈のバウンディングボックス内の動脈すべて（腎動脈，副腎動脈，脾動脈，胃十二指腸動脈，上腸間膜動脈，肋間動脈，横隔動脈など）を手動セグメンテーションする．これは動脈強調器を作成する際，腎臓と腎動脈バウンディングボックス内からランダムに抽出される，3 次元パッチ画像に周辺の動脈が含まれたときの対策である．また，周辺の動脈を学習データに追加することで，細い血管のデータを増やす効果も期待できる．腎動脈周辺の動脈を図 6(b) に示す．



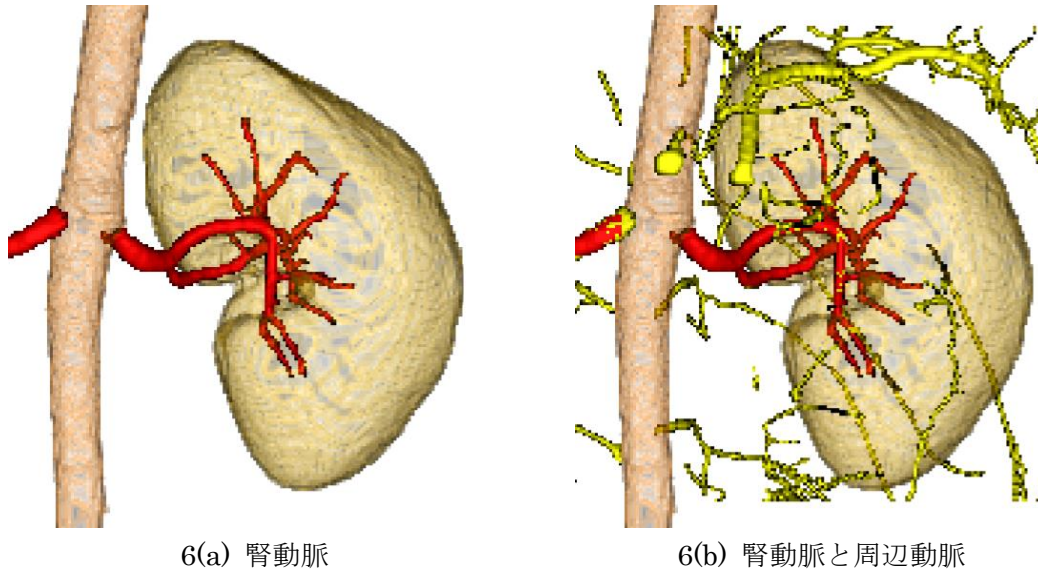


図 6 腎臓と腎動脈バウンディングボックス内の動脈と腎臓，大動脈マスク画像  
 図 6(b) の赤色領域が腎動脈，黄色領域が腎動脈周辺の動脈領域である．

### 3.1.3 臓器セグメンテーション

本研究では経路探索の際，血管候補領域と腎臓，大動脈領域を使用することで，腎動脈を抽出するため，腎臓，大動脈が抽出済みであることが前提条件である．臓器の自動セグメンテーションにおいては，U-Net を用いた臓器セグメンテーションを使用する．学習データとして，手動で抽出された腎臓，大動脈マスクを使用する．臓器自動抽出精度を，30 症例を対象に実験したところ，Jaccard 指数は大動脈が 0.937，腎臓は 0.958 であった．この値は，本研究の腎動脈認識に使用するにあたって十分な数値であるため，提案手法では U-Net を用いて作成した腎臓領域と大動脈領域を使用する．A, B をそれぞれ正解領域，抽出領域とすると，Jaccard 指数は以下の式により計算される．

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|}$$

### 3.1.4 評価方法

本研究では、50 例の 3 次元腹部造影 CT 画像を使用し、Leave-one-out 交差検証を行う。動脈抽出成功の判定方法は、血管中心線の抽出方法 [19] の評価で用いられているものを参考に決定する。手動で抽出した動脈を細線化した領域を  $M$ 、抽出された経路を  $A$  としたとき、 $M$  の近傍 2 ボクセルの領域  $M'$  に存在している抽出された経路を *True Positive* とした。評価は、*Recall* (再現率)、*Precision* (適合率)、*Fmeasure* を基準とした。評価に用いる各値は以下の式により計算される。

$$TruePositive = |\{v | v \in M' \cap A\}|$$

$$Recall = \frac{TruePositive}{|M|}$$

$$Precision = \frac{TruePositive}{|A|}$$

$$Fmeasure = \frac{2 \times Recall \times Precision}{Recall + Precision}$$

ここで、 $|X|$  は集合  $X$  の要素数を表すものとする。



### 3.1.5 血管の太さの計算

従来の手法では抽出が容易ではなかった細い血管の抽出精度を比較するために、動脈を細線化した領域  $M$  の各ボクセルに対し、そのボクセルから非動脈領域への距離を太さとして付与する。動脈二値画像からの太さの計算は、以下の手順で行う。

1. 腎動脈画像を細線化し、中心線画像を取得
2. 中心線画像の各ボクセルから非腎動脈領域への最小マンハッタン距離を計算し、太さとする


腎動脈の太さを可視化した画像の例を図 7 に示す。細い血管の精度評価には、図 7(b) で示す太さ 1 の領域のみを使用する。

太さと色の対応関係


						
1	2	3	4	5	6	7



7(a) 太さ画像



7(b) 太さ1のみ



7(c) 手動抽出した正解画像

### 図 7 腎動脈の太さ

図 7(a) に太さ画像の例を示す。太さは細い方から、1: 赤, 2: 橙, 3: 黄, 4: 黄緑, 5: 水, 6: 青, 7: 紫。図 7(c) の大動脈から分岐して、左腎臓上極部へ通じる 1 本の細い左腎動脈は、図 7(a) から、最も細い太さ 1 であることがわかる。

## 3.2 実験内容

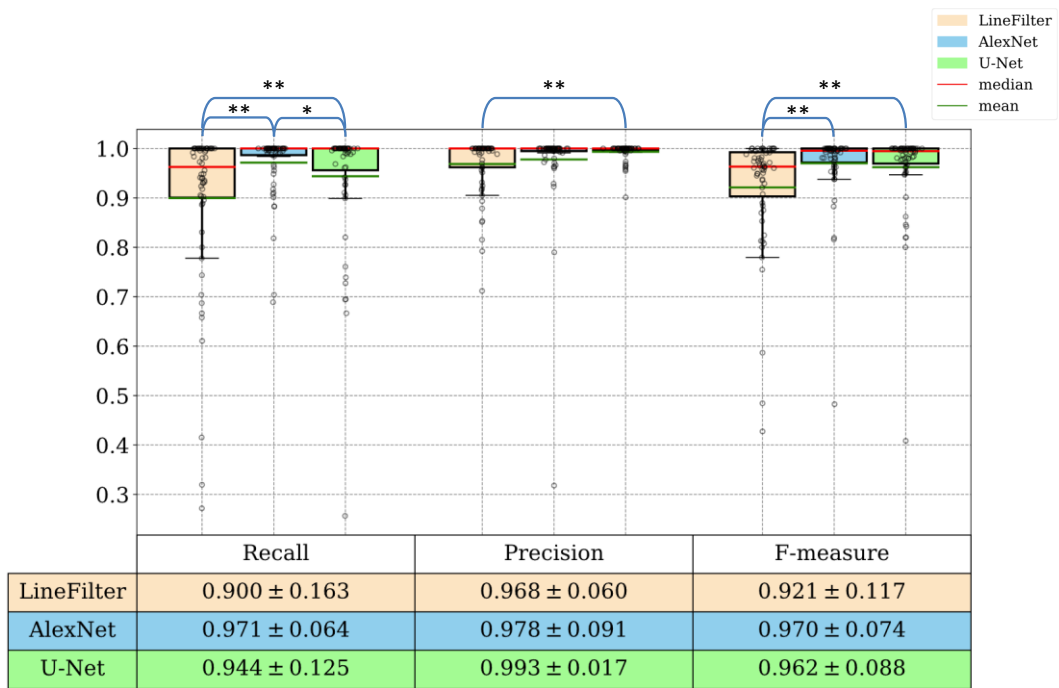
提案手法の有効性を確認するために、AlexNet をベースにして作成した動脈強調器を用いた場合、U-Net をベースにして作成した動脈強調器を用いた場合、そして従来の線強調処理を用いた場合 [9]の結果を比較する。提案手法の学習に使用する、3次元パッチ画像のサイズを以下の表 2 に示す。学習と評価には Leave-one-out 交差検定を行った。また、動脈尤度画像から腎動脈候補領域を抽出する際の閾値 $t$ は、AlexNet を用いた手法では $t = 0.5$ 、経路探索の際に使用する $n$ は $n = 2$ 、U-Net では $t = 0.4$ 、 $n = 2$ とした。一方、従来手法である線強調処理のパラメータは $\sigma = \{\sqrt{2}^{-2}, \sqrt{2}^{-1}, \sqrt{2}^0, \sqrt{2}^1, \sqrt{2}^2\}$ 、 $n = 1$ とした。

表 2 提案手法の入力、出力パッチサイズ

	入力パッチサイズ	出力パッチサイズ
AlexNet	$21 \times 21 \times 21$	$13 \times 13 \times 13$
U-Net	$38 \times 38 \times 38$	$18 \times 18 \times 18$


## 3.3 実験結果

提案手法の AlexNet を用いた場合、U-Net を用いた場合と、従来手法の線強調処理を用いた場合の腎動脈抽出結果を示す。テスト画像 30 例の、各手法での *Recall*、*Precision*、*Fmeasure* の結果を箱ひげ図で表し、図 8 に示した。従来手法である線強調処理では *Fmeasure* が平均 0.921 であったが、AlexNet は 0.970、U-Net では 0.962 と、従来手法より有意に抽出精度が向上した。U-Net を用いた際、*Precision* は平均 0.993 であり、誤抽出の数が大幅に削減されていることが数値から分かる。図 9 に原画像と、各手法を用いた動脈尤度画像の一例を、最大値投影法 (Maximum Intensity Projection, 以下 MIP) で表示したものを示す。この画像から、従来手法では腎動脈だけでなく、背骨や肋骨の辺縁部等の多くの骨領域を強調していることが分かる。一方 CNN を用いた際は、いずれも腹部の動脈を強調している。AlexNet を用いた手法では肺動脈を含む、画像全体の動脈領域を、また U-Net を用いた手法では学習に使用した腎臓や腎動脈周辺の動脈を主に強調しており、肺動脈や腸の動脈などは強調されていないことが画像から確認できる。続いて、表 3 に腎動脈の抽出の成功数を示す。図 2(c) のような、複数の腎動脈が大動脈から分岐している際、1 本でも見落としがある場合は、その例すべてが見落としと数える。左右腎臓の数が合計で 60 例あるうち、AlexNet の手法で自動抽出に成功した例は 55 例、U-Net で 55 例、線強調処理では 53 例であった。この結果からも、提案手法の精度が最も高いことが確認できる。




※ウィルコクソンの符号付順位検定  
\*: p<0.05, \*\*: p<0.01


図 8 各手法の精度比較




9(a) 原画像



9(b) 線強調処理



9(c) AlexNet



9(d) U-Net

図 9 各手法で作成した動脈尤度画像の MIP 表示

原画像は表示のため、骨領域が映らないように処理を施している

表 3 腎動脈の自動抽出例数結果

	過抽出例数	抽出不足例数	成功例数
AlexNet	2 例	3 例	55 例
U-Net	0 例	5 例	55 例
線強調処理	1 例	6 例	53 例

表 4 細い腎動脈領域の Recall

	太さ 1 の腎動脈 の Recall
AlexNet	0.924
U-Net	0.909
線強調処理	0.709

次に、細い動脈のみに限定した、各手法の抽出精度を比較する。3.1.5で計算した腎動脈中心線の太さ画像のうち、最も細い太さ1の領域のみの、*Recall*を計算したものを表4に示す。この結果から、CNNを用いた手法では細い動脈を、高い精度で抽出できていることが確認できる。

## 第4章 考察

CNN を用いた提案手法は，図 8 から従来手法の線強調処理を用いた手法より有意に抽出精度が向上した．図 10 に，細い動脈を持つ例の腎動脈抽出結果を示す．図 10(d)の手動抽出で作成した正解画像から読み取れるように，この例の右腎動脈は途中で腎臓上極領域に分岐しており，左腎動脈は大動脈から 2 本の動脈が分岐している．線強調処理の抽出結果では左右ともに，細い腎動脈を見落としている．しかし，提案手法である AlexNet ベースの手法を用いた結果と U-Net を用いた結果では，左右ともに抽出できていることが図 10 から確認できる．さらに，腎臓内部へ流入している，腎動脈枝の葉の部分に着目した結果が図 11 である．CNN を用いた提案手法は，腎臓内部へ流入後も，線強調処理より詳細に抽出できていることが分かる．

一方，提案手法で見落としてしまった例の抽出結果を図 12 に示す．図 12 (d)のように，この右腎臓は 2 本の腎動脈を持つが，本実験で使用した全ての手法で，腎臓下極に流入する腎動脈の抽出に失敗した．この例の右腎臓領域を MIP で表示したものを，図 13 に示す．矢印で指している，明るく示されている領域が，この例の右腎動脈である．図 13 の赤色矢印で指されている領域は全ての手法で抽出することができた太い腎動脈である．この腎動脈は，腎門領域で数本の枝に分岐し，腎臓内部へ通じていることが MIP 画像から確認できる．一方で，図 13 の青色の矢印で指されている領域は抽出に失敗した腎動脈である．3次元 CT 画像を用いて前後のスライスの画像情報を取り入れると，この腎動脈が腎臓に到達していることが確認できるが，図 13 からは腎臓内部に通じていることを目視で確認し難い．このような，血管造影 CT 画像で，腎臓内部まで強く強調がされていない腎動脈領域は，提案手法の際も抽出に失敗した．その他にも，平均的な腎動脈よりも太い例においても，U-Net の動脈識別器で抽出に失敗した．これは，大動脈と誤って認識したと考えられる．このような腎動脈の例は本実験で用いたものでも 2~3 例と多くないため，今後データを増強することで，精度の向上が期待できる．

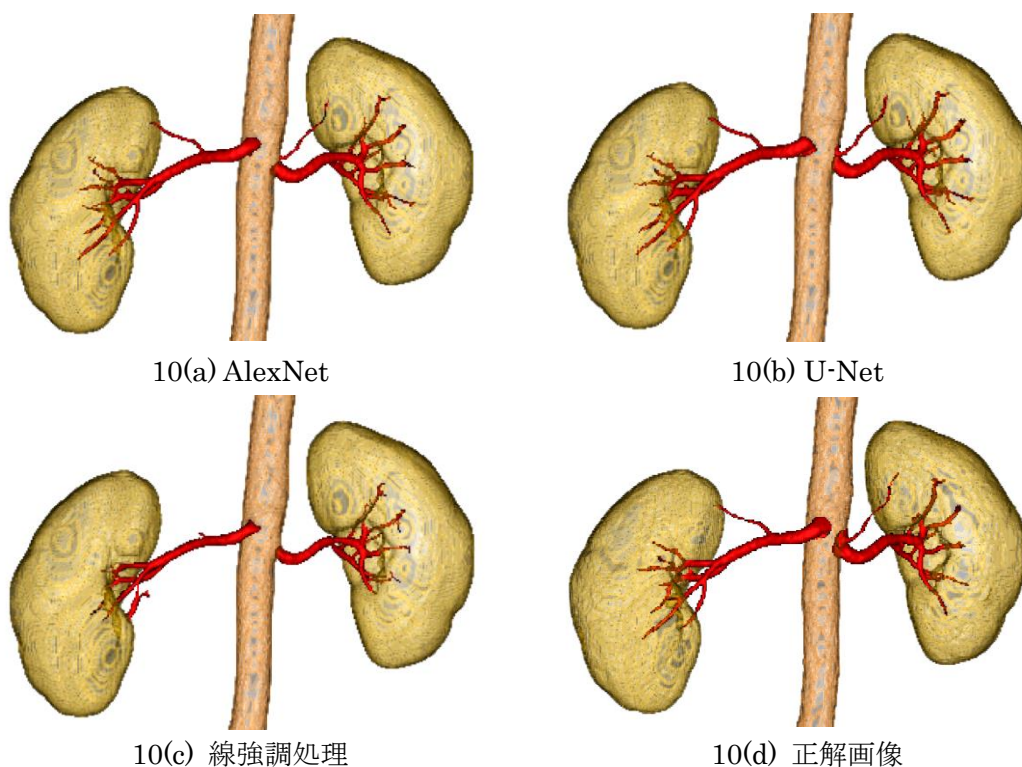
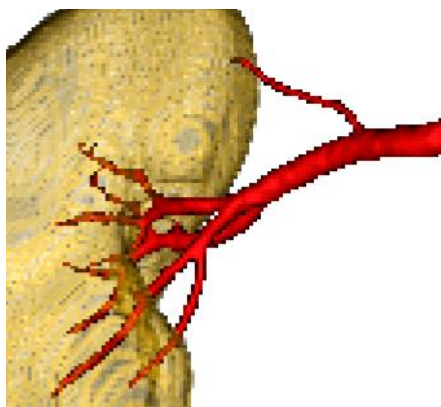



図 10 細い血管が大動脈から分岐している例の腎動脈抽出結果

ここまで、評価に使用した項目すべてにおいて、提案手法である CNN で作成した動脈識別器を用いた際の結果が、従来手法である線強調処理を用いた際の結果を大きく上回った。大きな理由としては、表 4 から読み取れるように、提案手法の細い動脈の抽出精度が、線強調処理と比較して高かったためであると考察する。前述したように、直径 1~2 ボクセル程度の動脈は、腹部造影 CT 画像においても、強く強調されないため、線強調処理では見落としてしまうことが多い。しかし提案手法では、CNN を用いて腎動脈以外の動脈も学習データとして追加したことで、細い動脈を複数学習させたためであると考察する。腎動脈以外の動脈を学習データに入れない場合、太さが 1 である領域の、学習データの腎動脈全体に占めるボクセル数の割合は 10.4%であるが、腎動脈以外の動脈を学習データに入れた場合は 27.5%と、細い動脈のデータ数の占める割合が 2.65 倍になる。

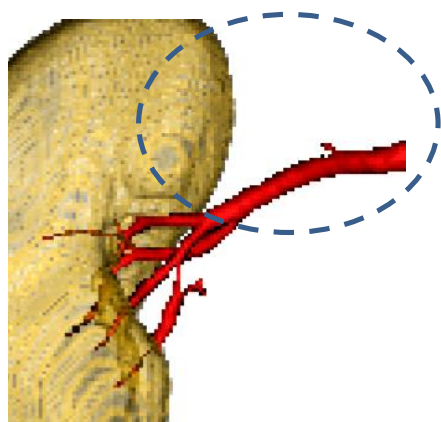




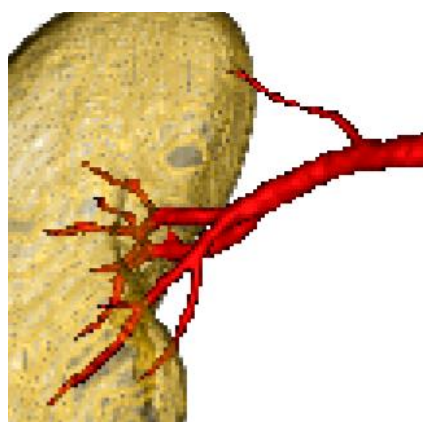
11(a) AlexNet



11(b) U-Net



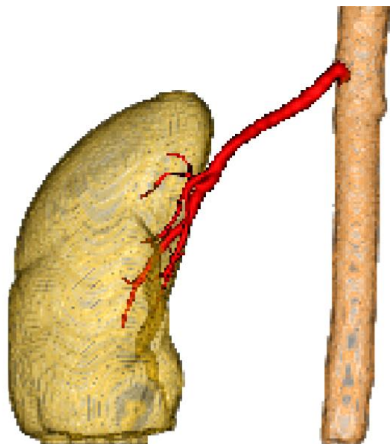
11(c) 線強調処理




11(d) 正解画像

図 11 右腎臓流入領域の抽出結果


線強調処理は腎臓内部へ流入後の腎動脈をあまり抽出できていないのに対し、CNN は腎動脈を細部まで抽出している



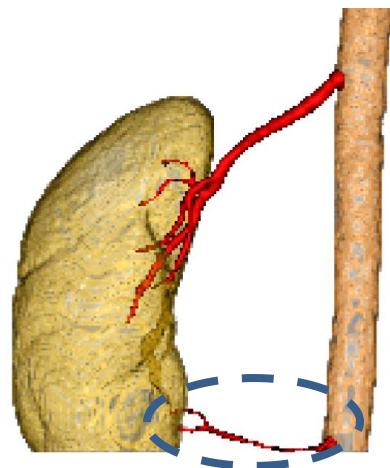
12(a) AlexNet



12(b) U-Net



12(c) 線強調処理



12(d) 正解画像

図 12 腎動脈の抽出に失敗した例




図 13 失敗例の CT 画像 MIP 表示

## 第5章 総括

本稿では、3次元腹部造影 CT 画像からの腎動脈枝の自動抽出の手法を提案した。従来の動脈候補領域抽出処理を改善する方法として、畳み込みニューラルネットワーク (CNN) を使用した。実験の結果は、線強調処理を用いた血管抽出結果の  $Fmeasure$  が 0.921 であったのに対して、AlexNet ベースのネットワークを用いた識別器の利用で 0.970、U-Net ベースのネットワークの利用で 0.962 と、精度の向上が確認できた。また、テスト画像に使用する左右腎臓の数が合計で 60 例あるうち、AlexNet を用いた手法で自動抽出に成功した例は 55 例、U-Net で 55 例、線強調処理では 53 例であった。細い動脈のみを対象として計算した  $Recall$  が、線強調処理を用いた場合に 0.709 であったのに対して、AlexNet を用いた際に 0.924、U-Net の利用で 0.909 と、細い動脈の抽出精度の向上が、腎動脈自動抽出の精度向上に寄与したと考察する。また、抽出した腎動脈の本数も提案手法の方が従来手法より多く、提案手法の有用性を確認した。提案手法は、多様な学習データの増強で、精度のさらなる向上が期待できる。

## 謝辞

本研究を進めるにあたり、日ごろより有益な助言と丁寧なご指導ご鞭撻を賜りました、奈良先端科学技術大学院大学 情報科学研究科 生体医用画像研究室 佐藤嘉伸教授に深く感謝申し上げます。また、研究発表の際、貴重なご助言を賜りました、奈良先端科学技術大学院大学 情報科学研究科 光メディアインタフェース研究室 向川康博教授に厚く御礼申し上げます。本研究を遂行するにあたり、日頃より多くの有益な御助言と丁寧な御指導を頂きました奈良先端科学技術大学院大学 情報科学研究科 生体医用画像研究室 大竹義人准教授、横田太助教、また有益な御助言を頂きました、筑波大学大学院 システム情報工学研究科 コンピュータサイエンス専攻 イメージサイエンス研究室 岡田俊之助教に深く感謝申し上げます。

本研究を進めるにあたり、CT 画像の御提供ならびに多くの有益な御助言を賜りました大阪大学大学院 医学系研究科 放射線統合医学講座 堀雅敏助教、富山憲幸教授をはじめ、諸先生方に厚く御礼申し上げます。

本研究を遂行するにあたり、日頃より丁寧な御指導を頂きました鈴木裕紀氏、日朝祐太氏、福田紀生氏、平山俊太氏に心より感謝致します。大学院生活全般にわたり様々な面で支えて頂きました田川郁代秘書をはじめ、奈良先端科学技術大学院大学 情報科学研究科 生体医用画像研究室の皆様にご心からの感謝を申し上げます。最後に、大学院修了まで多大な支援を頂いた家族に深く感謝し、ここに謝辞とさせていただきます。

## 参考文献

- [1] Herbert Lippert, Reinhard Pabst[著], 中村仁信, 沢田敏[訳], “臨床医に必要な動脈分岐様式：破格とその頻度”, 癌と化学療法社, 1988
- [2] N. Khalili, P. Moeskops, N.H.P. Claessens, et.al, "Automatic segmentation of the intracranial volume in fetal MR images", *Fetal, Infant and Ophthalmic Medical Image Analysis*, pp.42-45, 2017
- [3] T Okada, M G Linguraru, M Hori, et.al, "Abdominal multi-organ segmentation from CT images using conditional shape–location and unsupervised intensity priors", *Medical Image Analysis*, vol.26, issue 1, pp.1-18, 2015
- [4] 松村讓兒, "イラスト解剖学", 中外医学社, 2012
- [5] Sampaio FJ, Passos MA, “Renal arteries : anatomic study for surgical and radiological practice”, *Surgical and Radiologic Anatomy*, 1992
- [6] Karen López-Linares, Luis Kabongo, Nerea Lete, et.al, "CNN-Based Automatic Segmentation and Quantification of Aortic Thrombus Volume: Influence of the Training Approach", *Intravascular Imaging and Computer Assisted Stenting, and Large-Scale Annotation of Biomedical Data and Expert Label Synthesis*, pp.29-38
- [7] E Kerrien, A Yureidini, J Dequidt, et.al, "Blood vessel modeling for interactive simulation of interventional neuroradiology procedures", *Medical Image Analysis*, January 2017, vol.35, pp.685-698
- [8] Y Sato, S Nakajima, N Shiraga. Et.al, “Three-dimensional multi-scale line filter for segmentation and visualization of curvilinear structures in medical images”, *Medical Image Analysis*, vol. 2, issue 2, pp.143-168, 1998
- [9] 鈴木裕紀, “血管解剖の知識を用いた腹部 CT 画像からの動脈枝の自動認識”, 大阪大学大学院 情報科学研究科 コンピュータサイエンス専攻 修士論文 (未公刊) , 2014
- [10] Ha Manh Luu, Camiel Klink, Adriaan Moelker, et.al, "Quantitative evaluation of noise reduction and vesselness filters for liver vessel segmentation on abdominal CTA images", *Physics in Medicine & Biology*, Vol 60, Number 10, pp.3905-3926, 2015
- [11] Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks", *Advances in Neural Information Processing Systems 25 (NIPS 2012)*
- [12] Lee T.C. Kashyap, R.L. Chu C.N, "Building Skeleton Models via 3-D Medial Surface Axis Thinning Algorithms", *CVGIP: Graphical Models and Image Processing*, Vol 56, Issue 6, November 1994, pp.462-478
- [13] Karen Simonyan, Andrew Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition", *ICLR: International Conference on Learning Representations 2015*
- [14] Holger R. Roth, Hirohisa Oda, Yuichiro Hayashi, et.al, "Hierarchical 3D fully convolutional networks for multi-organ segmentation", *Computer Vision and Pattern Recognition*, 2017
- [15] Mohammad Havaei, Axel Davy, David Warde-Farley, et.al, "Brain tumor segmentation with Deep Neural Networks", *Medical Image Analysis*, Vol 35, pp.18-31
- [16] Olaf Ronneberger, Philipp Fischer, Thomas Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation", *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, pp.234-241
- [17] Özgün Çiçek, Ahmed Abdulkadir, Soeren S. Lienkamp, Thomas Brox, Olaf Ronneberger, "3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation", *MICCAI 2016: Medical Image Computing and Computer-Assisted Intervention - MICCAI 2016* pp.424-432
- [18] Michal Sofka, and Charles V. Stewart, "Retinal Vessel Centerline Extraction Using Multiscale Matched Filters, Confidence and Edge Measures," *IEEE Transactions on Medical Imaging*, Vol. 25, no. 12, pp. 1531-1546, 2006

- [19] Michal Sofka, and Charles V. Stewart, "Retinal Vessel Centerline Extraction Using Multiscale Matched Filters, Confidence and Edge Measures," *IEEE Transactions on Medical Imaging*, vol. 25, no. 12, pp. 1531-1546, 2006.

## 発表リスト

- [1] 小野真理子, 鈴木裕紀, 日朝祐太, 堀雅敏, 大竹義人, 富山憲幸, 佐藤嘉伸, “畳み込みニューラルネットワークを用いた腹部造影 CT 画像からの腎動脈枝の強調”, 第 26 回日本コンピュータ外科学会大会, 2017.10