

千葉大学工学部
卒業論文

複数タスク融合と 2.5 次元学習に
よる経皮的冠動脈形成術の
合併症予測

2025 年 2 月提出

指導教員 中口 俊哉 教授

総合工学科医工学コース

学生証番号 21T0811C

金子 慧士

目次

第 1 章 序論	1
1.1 はじめに	1
1.2 本論文の構成	2
第 2 章 関連研究	3
2.1 はじめに	3
2.2 血管構造と IVUS 画像解析	3
2.2.1 ヒトの血管構造	3
2.2.2 IVUS 画像解析	4
2.2.3 深層学習を用いた IVUS 画像解析	5
2.3 IVUS 画像と合併症の関連	6
2.3.1 減衰プラーク	6
2.3.2 IVUS 画像と合併症の関連	7
2.3.3 減衰プラークの量を用いた合併症の予測手法	7
第 3 章 合併症の予測手法と評価手法	9
3.1 はじめに	9
3.2 本研究で使用した深層学習モデル	9
3.2.1 Convolutional Neural Network(CNN)	9
3.2.2 Residual Neural Network(ResNet)	9
3.2.3 Deeplabv3	11
3.3 学習手法	11
3.3.1 逐次学習	11
3.3.2 マルチタスク学習	12
3.4 Receiver Operating Characteristics(ROC)解析	12
第 4 章 単体フレームを入力とした合併症予測	14
4.1 はじめに	14
4.2 実験概要	14
4.2.1 データセット	14
4.2.2 実験内容	14
4.2.3 学習条件	16
4.2.4 評価手法	18
4.3 実験結果	18
4.4 考察	19

4.4.1	プラーク病変部の 3 次元特性の活用	20
4.4.2	減衰プラークの情報の活用	20
第 5 章	複数フレームを入力とした合併症予測	22
5.1	はじめに	22
5.2	実験概要	23
5.2.1	2.5D モデルへの入力	23
5.2.2	評価手法	24
5.3	実験結果	24
5.4	考察	24
第 6 章	結論	26
謝辞		27
参考文献		28

第1章

序論

1.1 はじめに

心筋梗塞や狭心症といった虚血性疾患[1]は，冠動脈の狭窄や閉塞により心筋への血流が阻害され，胸痛や心筋障害を引き起こす重大な疾患群である．こうした狭窄の原因として，動脈硬化に伴い血管壁に形成されるプラークが大きく関わっている．動脈硬化とは，悪玉コレステロールなどの脂質や炎症細胞が血管壁に蓄積することで進行し，やがてプラークと呼ばれる病変を形成する病態を指す．プラークが肥大化すると冠動脈内の血液が流れる領域である内腔が狭くなり，心筋への血液供給量が低下するため，心筋梗塞や狭心症などの虚血性疾患を発症しやすくなる．これらの患者に対しては，冠動脈バイパス術や経皮的冠動脈形成術(Percutaneous Coronary Intervention, PCI)[2]などの治療が行われている．その中でも PCI は，カテーテルを用いて狭窄部位を拡張する低侵襲的な治療手段として広く普及している．

しかし，PCI 手技中には合併症を生じることがあり，その代表例として No reflow 現象および Slow flow 現象が挙げられる．No reflow とは，冠動脈内の狭窄自体が解消されているにもかかわらず，狭窄部位の拡張の過程で流出したプラーク内容物や血栓などが微小血管を詰まらせることで末梢血流が完全に遮断された状態を指す．一方，Slow flow は血流が完全に遮断されるわけではないものの，末梢血流が著しく遅延する状態を指す．No reflow または Slow flow は PCI 後の患者において約 10-20%の割合で発症することが報告されている[3]．また，両現象とも血流の大幅な低下を引き起こし，追加の処置や薬剤投与が必要となるため，手術時間の延長や患者の予後不良につながる可能性がある．本論文では，

PCI 手技中の合併症の中でも特に No reflow および Slow flow に焦点を当て、これらを主要な対象として扱う。

こうした合併症を未然に予測し、適切な対策を講じることは PCI の安全性と効率を高める上で極めて重要である。従来、No reflow や Slow flow の予測は冠動脈造影画像や術者の経験的判断に依存しており、その正確性や再現性には限界があった。そこで近年、血管壁やプラークの状態を詳細に可視化できる血管内超音波(Intravascular Ultrasound, IVUS)[4]を用いる研究が注目を集めている。IVUS は超音波振動子を搭載した IVUS カテーテルを冠動脈内に挿入し、血管壁の断面画像をリアルタイムで取得することが可能な検査法である。IVUS によって得られる高解像度な冠動脈内の血管断面画像から、術前に No reflow や Slow flow の発生を予測できれば、術者が最適な術式を選択し、術中・術後の合併症リスクを低減できると期待されている。

これらの背景から本研究では、PCI 実施前の IVUS 画像から No reflow および Slow flow の合併症を予測することを目的とし、本論文では深層学習を用いた合併症の予測精度を検証した。

1.2 本論文の構成

本論文の構成を以下に示す。

第1章では研究背景と目的について述べた。

第2章では関連研究について述べる。

第3章では本研究で用いた合併症の予測手法と評価手法について述べる。

第4章では単体フレームを入力として合併症予測を行う実験について述べる。

第5章では複数フレームを入力として合併症予測を行う実験について述べる。

第6章では本論文の結論を述べる。

第2章 関連研究

2.1 はじめに

本章では、2.2 節において血管構造と IVUS 画像解析について述べる。2.3 節では IVUS 画像と合併症の関連研究について述べる。

2.2 血管構造と IVUS 画像解析

2.2.1 節ではヒトの血管構造を説明し、2.2.2 節ではそれぞれの構造が IVUS 画像上でどのように観察されるのかを示す。2.2.3 節では IVUS 画像解析に関する関連研究について述べる。

2.2.1 ヒトの血管構造

ヒトの動脈壁は図 2.1 に示すように、主に内膜、中膜、外膜の3層構造から成り立っている。最も内側の内膜には内皮細胞が並び、血液との界面を形成する。中膜は平滑筋細胞などから構成され、血管径の調整に寄与する。外膜は結合組織によって血管を外側から支持する役割を担っている。動脈硬化に伴って形成されるプラークは脂質や炎症細胞などが内膜側に蓄積して形成される病変である。プラークが肥大化することと血管内腔が狭くなり、虚血性疾患の発症や進行の要因となる。




図 2.1 ヒトの動脈壁

2.2.2 IVUS 画像解析

IVUS 画像例とその解析例[5]を図 2.2 に示す. IVUS 画像上では, 主に 3 つの主要項目である内腔とプラーク, 血管壁について解説する.

(1) 内腔

内腔は血液が流れる領域であり, IVUS 画像上では, IVUS カテーテルを中心として最も黒く映る領域である. 内腔の広さや形状は, 血管狭窄やプラーク形成の有無を評価する上で重要な指標になる.

(2) プラーク

プラークは内膜の内側に形成される病変であり, IVUS 画像上では血管壁の盛り上がりやエコー特性の変化として観察される. 脂質を多く含むプラークはエコー減衰特性を示し, 石灰化を含む場合は強いエコー反射が得られるなど, 組織特性によって見え方が異なる. プラークのサイズや形状, 組成の評価は PCI における合併症リスクを判断する際に重要な情報となる.

(3) 血管壁

内膜から中膜にかけてやや高輝度帯として映ることが多く，外膜との境界はエコー強度の変化によって白黒のコントラストとして識別される．この内膜から中膜にかけての領域を血管壁領域とし，プラークの付着部位や血管壁の厚みを定量的かつ定性的に解析することが可能である．





図 2.2 IVUS 画像内の各領域

2.2.3 深層学習を用いた IVUS 画像解析

西らの研究では，深層学習を用いた IVUS 画像のセグメンテーション手法 [6]が開発された．この研究では PCI 後のステント留置部を含む IVUS 画像を対象に，内腔，プラークと血管壁およびステント領域の 3 つの領域を自動的に抽出することを目的としている．使用した深層学習モデルは，Deeplabv3[7]であり，Dice 係数で 0.83 と高い精度を示した．モデルの出力例を図 2.3 に示す．図 2.3 の画像例からも西らの手法の精度の高さを確認することができる．



(a) IVUS 画像

(b) セグメンテーション結果

図 2.3 PCI 後の IVUS 画像内の各領域


2.3 IVUS 画像と合併症の関連

本節では、関連研究で示されている IVUS 画像と合併症の関連[8]について述べる．2.3.1 節では合併症の発症に関連していると報告されている減衰プラークについて述べる．2.3.2 節では、関連研究で提案されている IVUS 画像上の減衰プラーク量から合併症を予測する手法[8]について述べる．

2.3.1 減衰プラーク

減衰プラークは脂質を多く含むプラークの一形態であり、通常のプラークに比べてエコー反射が減少するため、IVUS 画像上では暗い領域として映る．図 2.4 に示すように、減衰プラークを含む IVUS 画像では、血管壁と背景との境界を明確に識別することは難しいが、減衰プラークそのものの存在は確認できる．減衰プラークの存在は、動脈硬化の進行度やプラークの不安定性と関連しており、特に PCI における合併症リスクの指標として注目されている．減衰プラークを有するプラーク病変では、プラークの破裂や血栓形成が起こりやすく、これにより

微小血管が閉塞しやすくなることが報告されている[8]。従って、減衰プラークの詳細な評価は PCI 術前評価において重要な役割を果たすと考えられる。



(a) IVUS 画像

(b) IVUS 内の減衰プラークの方向

図 2.4 IVUS 画像内の減衰プラークのアノテーション例

2.3.2 IVUS 画像と合併症の関連

IVUS 画像上に観察される減衰プラークの量について、合併症を発症した患者群と発症しなかった患者群の間で有意差が認められるとする研究報告[8]がある。これは減衰プラークの量が多いほど血栓形成や微小血管の閉塞が起こりやすく、合併症のリスクが高まる可能性を示唆している。

2.3.3 減衰プラークの量を用いた合併症の予測手法

IVUS 画像における減衰プラークの量を指標として合併症の発症を予測する手法も提案されている。具体的には、1 症例あたりに含まれる複数の IVUS 画像それぞれにおいて減衰プラークの角度を算出し、それらを平均化することで減衰プラーク量として定量評価を行う。この減衰プラーク量をもとに一定の閾値を設定し、合併症の発症有無を予測する手法が提案されている。しかし、この手

法では全ての症例データを用いて最も精度が高くなる閾値を算出しているため、未知のデータに対しては必ずしも適切に評価することができない可能性がある。したがって、提案手法は IVUS 画像内の減衰プラーク量が合併症の予測において重要な指標となる可能性を示唆している一方で、閾値の算出方法が適切でない可能性や IVUS 画像から得られる減衰プラーク以外の情報も合併症の予測に必要となる可能性があり、汎化性能に関して課題がある。

第3章

合併症の予測手法と評価手法

3.1 はじめに

本章では、本研究で用いた合併症の予測手法と評価手法について述べる。3.2 節では深層学習モデルについて説明する。3.3 節ではモデルの学習手法について述べる。3.4 節では Receiver Operating Characteristic(ROC)解析について述べる。

3.2 本研究で使用した深層学習モデル

本節では、深層学習モデルに関して説明する。まず、基本的な Convolutional Neural Network(CNN)について説明し、残差接続を活用したモデルである Residual Neural Network(ResNet)、セグメンテーションモデルである Deeplabv3 を説明する。

3.2.1 Convolutional Neural Network(CNN)

CNN は、畳み込み層やプーリング層、全結合層などから構成されるニューラルネットワークであり、主に画像認識の分野において広く利用される。畳み込み層では、フィルタを利用した畳み込み演算により入力から特徴を抽出する。プーリング層では入力を各領域に分割し、その領域における最大値や平均値など代表的な値を取り出すことで圧縮を行う。これにより、抽出した特徴にロバスト性を高める役割を果たす。全結合層では、畳み込み層とプーリング層により抽出された特徴を用いて最終的な分類や回帰を行う。

3.2.2 Residual Neural Network(ResNet)

ResNet は、He らによって 2015 年に発表された CNN を基盤とする残差接続を活用した深層学習モデル[9]である。CNN は多層化によって性能の向上が図られていった。しかし、層数を深くすると、勾配消失問題により重みがほとんど更

新されず、学習が進まないという課題があった。勾配消失問題とは、出力層から入力層に向けて勾配を計算していく誤差逆伝播を用いたモデルの更新時に、勾配がほとんど 0 に近い非常に小さい値になり、モデルの更新がうまく行えないことである。このような課題の解決を図るために、ResNet では畳み込み層およびスキップ接続を基本構造(図 3.1(g))として持つ残差ブロックを積み重ねてモデルを構築している。スキップ接続では、畳み込み層を跨いで直前の層の出力を後続の層の出力に加えている。この残差ブロックにより、勾配消失問題の影響を受けずに多層化が実現可能となった。ResNet は層数に応じて ResNet-18, ResNet-34, ResNet-50, ResNet-101, ResNet-152 がある。ResNet-50 より大きいモデルではボトルネック構造を持った残差ブロック(図 3.1(h))を積み重ねてモデルを構築している。ボトルネック構造は、3つの畳み込み層で構成され、 1×1 の畳み込み層で次元と小さくしてから最後の 1×1 の層で次元と復元することで計算量を削減している。




図 3.1 残差ブロック

3.2.3 Deeplabv3

Deeplabv3 は, Chen らによって 2017 年に発表された画像セグメンテーションを目的とした深層学習モデル[7]である. 主な特徴として, 空間ピラミッドプーリングの仕組みを活用し, 異なるスケールの特徴を同時に学習可能な点が挙げられる. Deeplabv3 では, 畳み込み層に膨張率を導入し, 複数の膨張率で畳み込み演算を並列に行う Atrous Spatial Pyramid Pooling(ASPP)(図 3.2)を実装することで, 画像内の物体や領域を複数のスケールで捉えられるようになる. 膨張畳み込みは畳み込みフィルタの受容野を大きくするため, フィルタ要素間に空隙を挿入しつつパラメータ数を抑える工夫がなされている.




図 3.2 ASPP の概要

3.3 学習手法

本節では, IVUS 画像内の合併症の関心領域を活用した学習手法を述べる.

3.3.1 逐次学習

逐次学習は, 目的とするタスクと関連度の高いタスクを事前に学習し, その後目的タスクを学習する手法である. このプロセスにより, 事前学習で得られた

知識を目的タスクに効果的に転移させることが期待される。具体的には、目的タスクが分類タスクである場合、事前学習として関心領域の抽出タスクを実施する。関心領域の抽出タスクにより、対象領域の特徴を学習したパラメータを初期値として利用することができるため、目的タスクの学習が効率化され、より迅速に高精度なモデルを構築することが期待される。

3.3.2 マルチタスク学習

マルチタスク学習[10]とは複数の関連するタスクから共通の特徴を抽出することでそれぞれのタスクの精度向上を図る学習手法である。この手法では、異なるタスク間で共通の特徴表現を共有し、全てのタスクの精度を向上させることを目的とする。マルチタスク学習のアーキテクチャは各タスク間の共通の特徴表現を抽出する共有エンコーダとタスクごとのアップサンプリングや全結合層などを組み合わせる。

また、データセットを効率的に使用できることも利点として挙げられる。各タスク間が異なるデータセットを持つ場合でも、データの相互利用が可能となり、データ不足の問題を緩和することができる。

3.4 Receiver Operating Characteristics(ROC)解析

深層学習の分類タスクにおける性能評価に ROC 解析が用いられる。ROC 解析では、深層学習モデルの出力値の閾値（カットオフポイント）を変化させたときの真陽性率（true positive rate, TPR）を縦軸に、偽陽性率（false positive rate, FPR）を横軸にプロットした ROC 曲線（図 3.3）を用いて分類モデルの性能を評価する。TPR とは、分類モデルが陽性のデータに対して正しく陽性と分類できた割合であり、FPR とは、分類モデルが陰性のデータに対して誤って陽性と分類した割合である。また、ROC 曲線の下側領域の面積は Area Under the Curve(AUC)とよばれる。AUC は 0 から 1 の値を取り、値が 1 に近いほど分類モデルの性能

が優れているといえる。ランダムな分類を行った場合、ROC 曲線は図 3.3 の点線を描き、AUC は 0.5 となる。

本論文では、ROC 曲線における最適なカットオフポイントを Youden's index[11]を用いて決定した。Youden's index とは、（再現率＋特異度－1）を計算し、最大値となる時のカットオフポイントである。このカットオフポイントにおける正解率、適合率、再現率、F1 スコア、AUC を評価指標として用いた。各指標の算出方法は(3.1), (3.2), (3.3), (3.4), (3.5)のとおりである。




図 3.3 ROC 曲線の例

$$\text{正解率} = \frac{TP + TN}{TP + FN + TN + FP} \quad (3.1)$$

$$\text{適合率} = \frac{TP}{TP + FP} \quad (3.2)$$

$$\text{再現率} = \frac{TP}{TP + FN} \quad (3.3)$$

$$\text{特異度} = \frac{TN}{TN + FP} \quad (3.4)$$

$$\text{F1 スコア} = 2 \times \frac{\text{適合率} \times \text{再現率}}{\text{適合率} + \text{再現率}} \quad (3.5)$$

第4章

単体フレームを入力とした合併症予測

4.1 はじめに

本章では、単体の IVUS 画像を入力として合併症の発症を予測する手法について述べる。4.2 節では合併症予測実験の概要を説明する。4.3 節では実験結果を示す。4.4 節では考察について述べる。

4.2 実験概要

本節では、実験概要について述べる。

4.2.1 データセット

本研究で使用する IVUS データは、千葉大学医学部附属病院で取得された IVUS 動画からプラーク病変部の中心フレームを基準に前後 5 フレーム、計 11 フレームを切り出したものである。症例数は 313 症例、そのうち合併症を発症した症例数が 74 症例、発症していない症例数は 239 症例である。また、IVUS 画像内のプラークと血管壁および内腔の領域は医師によるアノテーションが実施された。

4.2.2 実験内容

本実験は、以下の 3 つに大別される。

(1) 異なる層数を持つ ResNet を使用した実験


層数の異なる ResNet は、一般にネットワークが深くなるほど高い表現力が期待できるが、タスクやデータセットの特性により必ずしも深いモデルが最適とは限らない。本実験では、合併症の予測に対して最適な層の深さが異なる可能性を検証するため、ResNet-34, ResNet-50, ResNet-101 を用いて合併症の予測精度を比較した。

(2) 逐次学習

本実験では、事前学習として IVUS 画像内の内腔と血管壁をセグメンテーションするタスクを通して、合併症の関心領域を学習した。(図 4.1)その学習済みモデルのパラメータを初期値として合併症の予測のための学習を行い、精度を検証した。(図 4.1)

また、本実験の事前学習は、西らによって学習された Deeplabv3[6]を初期値として用いた。そして、合併症を予測するモデルは、関心領域を学習したエンコーダに全結合層を付け加えたモデルを使用した。

1. 合併症の関心領域抽出モデルの学習



2. 合併症の発症有無を予測するための再学習




図 4.1 逐次学習の概要

(3) マルチタスク学習

本実験では合併症の予測精度向上のため、3つのタスクを同時に学習した。(図 4.2)具体的には、モデルの汎化性の向上のための画像再構成タスクと IVUS 画像内の内腔およびプラークと血管壁領域を抽出する関心領域抽出タスク、合併症の予測タスクの3つを同時に学習した。画像再構成タスクを追加した理由は

Amine らの研究において、マルチタスク学習に画像再構成タスクを組み込むことで、精度の向上が報告されているためである。また、IVUS 画像内の内腔と血管壁は合併症の主要な関心領域であるため、これらの情報を適切に学習することで合併症の予測精度の向上が期待される。

また、損失関数には、画像再構成タスクで最小二乗誤差、関心領域抽出タスクとクラス分類でクロスエントロピー誤差を用いた。

本実験で使用したモデルの初期値は、西らによって学習された Deeplabv3[6]に画像再構成のためのデコーダと合併症予測のための全結合層を追加したモデルを使用した。




図 4.2 マルチタスク学習の概要

4.2.3 学習条件

本研究では、ランダムサーチを用いてハイパーパラメータ探索を行った。ランダムサーチとは、ハイパーパラメータの最適化手法の一つであり、指定した範囲内でランダムに値を選び、それらを用いてモデルを評価しながら最適なパラメータを探索する手法である。探索するパラメータは学習率とバッチサイズ、

Adam の β_1 とし、探索範囲を表 4.1 に示す．同様に、ハイパーパラメータ探索を行っていない固定のハイパーパラメータを表 4.2 に示す．

4.2.1 節で述べたように合併症を発症した症例(陽性クラス)は、発症していない症例(陰性クラス)と比べて症例数が少なく、各クラスのデータ数に偏りがある．不均衡データを用いるとモデルが多数派である陰性クラスに偏った予測を行う可能性が高まる．この問題への対策として、クラスの重みづけを行う．2 クラス分類におけるクラスの重み w_i は、全症例数 N と各クラスの症例数 N_i を用いて式(4.1)で計算される．そして、式(4.2)のように重みを損失関数に適用することで、不均衡データの影響を緩和し、少数派クラスの重要度を強調する手法である．

また、データ拡張として $256 \times 256 \text{pixel}$ へのリサイズとランダムな回転、水平反転を用いた．

表 4.1 パラメータ探索範囲

学習率	$10^{-L}, L = [4, 7]$
バッチサイズ	$2 \times M, M = [4, 64]$
β_1 (Adam)	$1.0 - 10^{-N}, N = [1, 2]$

表 4.2 学習条件

エポック数	200
Early Stopping Patience	20
最適化手法	Adam
損失関数	クロスエントロピー誤差
不均衡データへの対策	クラスの重みづけ

$$w_i = \frac{N}{N_i \times 2} \quad (4.1)$$

$$\text{Loss} = - \sum_{i=1}^N w_i \times y_i \log(\hat{y}_i) \quad (4.2)$$

4.2.4 評価手法

モデルの評価には 5-fold 交差検証を用いた。5-fold 交差検証は、合併症を発症した症例と発症しなかった症例をそれぞれ 5 つの fold に分割し、3 つの fold を学習用データ、1 つの fold を検証用データ、残り 1 つの fold をテスト用データとして学習と評価を行う手法である。それぞれの fold においてランダムサーチを 20 回実施してモデルを評価した。

合併症の予測評価は 1 症例あたり 11 枚の IVUS 画像をそれぞれモデルに入力し、出力された予測ラベルを多数決により統合して症例としての最終的な合併症の発症有無の予測を行った。また、評価指標は、合併症の予測タスクでは、正解率と適合率、再現率、F1 スコア、AUC を用いた。逐次学習とマルチタスク学習では、合併症予測の評価指標に加えて、関心領域抽出タスクの評価指標として、Dice 係数を用いた。それぞれの指標は式(3.1), (3.2), (3.3), (3.5), (4.2)に示す。これらの指標から合併症の予測性能と関心領域の抽出精度を定量的に評価した。そして、2.3.3 節で述べた IVUS 画像内の減衰プラーク量から合併症の発症有無を予測する手法と比較した。

$$\text{Dice 係数} = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (4.3)$$

4.3 実験結果

表 4.3 は、先行研究の手法と異なる層数を持つ ResNet, 逐次学習, マルチタスク学習を用いた際の合併症の関心領域抽出精度と予測精度をまとめたものである。この結果から、ResNet-101 の精度が最も正解率が高いことが分かった。

表 4.3 合併症の関心領域抽出精度と予測精度

手法	モデル	関心領域 の抽出	合併症の予測				
		Dice 係数	正解率	適合率	再現率	F1 スコア	AUC
Wu ら[8]	-	-	0.62	0.67	0.65	0.65	0.64
単一学習	ResNet-34	-	0.59	0.65	0.43	0.49	0.61
	ResNet-50	-	0.62	0.68	0.55	0.57	0.60
	ResNet-101	-	0.64	0.66	0.63	0.63	0.60
逐次学習	Deeplabv3 +全結合層	0.79	0.56	0.56	0.65	0.58	0.60
マルチタスク 学習	Deeplabv3 +デコーダ +全結合層	0.69	0.55	0.56	0.66	0.58	0.58

4.4 考察

本研究では、1枚のIVUS画像を入力として合併症の発症有無の予測精度に関して、先行研究による手法[8]との比較を行った。表4.3に示す通り、層数が異なるResNetの3種類を用いた比較実験の結果、ResNet-101を用いた場合が最も良好な正解率0.64を示した。先行研究と比較して、合併症の予測精度が向上していることから、深層学習を用いたIVUS画像解析による合併症の予測が有効であることが示唆された。

一方で、逐次学習とマルチタスク学習では、精度が向上していないことから合併症の関心領域を十分に抽出できていないことが考えられる。マルチタスク学習で予測に失敗した画像例を図4.3に示す。図4.3のIVUS画像では、画像上で右下が黒く映っており、減衰プラークが存在することが確認できる。減衰プラーク

クを含む IVUS 画像の予測を誤っていることから、モデルが合併症と減衰プラークの関係性を学習できていないことが考えられる。

本研究で得られた精度では正解率 0.64 が最良値であったが、臨床応用のためには正解率 0.80 程度まで精度を向上させる必要がある。4.4.1 節と 4.4.2 節では精度向上のために有効であると期待される内容について述べる。




図 4.3 予測に失敗した IVUS 画像例

4.4.1 プラーク病変部の 3 次元特性の活用

本研究では単体フレームの IVUS 画像をモデルの入力として合併症を予測しているため、プラーク病変部の 3 次元特性を活用することができていない。実際の臨床現場では、医師は複数フレームの IVUS 画像から得られる空間的な連続性を総合的に評価し、3 次元的にプラークの状態を把握しながら合併症のリスクを判断している。そのため、フレーム間の関連性を考慮した 3 次元的な特徴抽出により精度向上の可能性が期待される。

4.4.2 減衰プラークの情報の活用

本研究で用いた IVUS 画像では、医師によるアノテーションとしてプラークと血管壁および内腔の領域が示されている。しかし、IVUS 画像上で減衰プラーク

は黒く映されるため、一部の画像では減衰プラークを含むプラークと血管壁の領域を明確にアノテーションすることができていない。減衰プラークは2.3節で述べたように合併症との関連が示されている重要な所見である。関心領域抽出タスクにおいて減衰プラークを含む正確な領域抽出が求められる一方、減衰プラークの領域をアノテーションすることは困難であるという課題がある。そのため、IVUS 画像で確認可能である減衰プラークの角度情報を活用した合併症予測を行うことで精度向上が期待される。

第5章

複数フレームを入力とした合併症予測

5.1 はじめに

本章では、4.4.1 節で述べたプラーク病変部の 3 次元特性を用いるために、複数の IVUS 画像を入力として PCI の合併症を予測する手法について述べる。第 4 章では IVUS 画像 1 枚を入力とする合併症の発症有無の予測する手法を検討した。しかし、単体フレームの入力ではモデルがプラーク病変部の 3 次元特性を十分にとらえられない可能性がある。そこで、本章では連続する複数の IVUS 画像を同時にモデルへ入力することで、プラーク病変部の 3 次元特性をより適切に捉えて合併症の発症を高精度に予測することを試みる。

モデルが 3 次元特性を学習するための手法として、3D モデルを用いる方法が考えられる。しかし、臨床現場へのリアルタイム性を考慮すると、計算コストの大きい 3D モデルは必ずしも適切ではない。そこで、本研究では、複数の 2 次元画像を入力として 2D モデルを使用する 2.5D モデルを採用する。そうすることで、モデルの軽量性と 3 次元特性の一部を学習する利点を両立させることを目指す。

2.5D モデルでは、単体フレームを 1 つのチャンネルとして扱い、2 次元畳み込み演算を適用することで、通常の 2D モデルを拡張した形で複数フレームにわたる情報をまとめて処理可能となる。

5.2 節では、2.5D モデルを使用した実験概要について述べる。5.3 節では実験結果について述べる。5.4 節では考察を述べる。

5.2 実験概要

本節では、複数フレームを入力とする 2.5D モデルを用いた合併症予測の実験概要について述べる。データセットと学習条件、ハイパーパラメータの探索範囲と固定のハイパーパラメータは第 4 章の実験条件と同様である。また、使用したモデルは表 4.3 で示された最も精度が高かった ResNet-101 を採用した。一方、モデルへの入力サイズと評価手法は第 4 章の実験条件と異なる。5.2.1 節ではモデルへの入力について述べる。5.2.2 節では評価手法について述べる。

5.2.1 2.5D モデルへの入力

本研究で使用したデータセットは、第 4 章で用いたものと同様であり、IVUS 動画からプラーク病変部を中心に IVUS 動画からプラーク病変部の中心フレームを基準に前後 5 フレーム、計 11 フレームを切り出している。1 症例当たり 11 枚のフレームからモデルへの入力として、以下の 2 種類の実験を比較した。ただし、IVUS 画像は超音波画像であるためチャンネル $C = 1$ である。

(1) 2.5D モデルへの入力サイズ[$C \times 11, H, W$]

1 症例当たり 11 枚の IVUS 画像をすべてチャンネル方向に重ねてモデルへの入力とする。しかし、モデルへの入力を症例単位で行うことで、第 4 章と比較して学習に使用可能なデータ数が大幅に減少する点が懸念される。そこで、次に述べるデータ拡張を行うことで、学習に使用するデータ数が減少する問題を解決する。

(2) モデルへの入力サイズ[$C \times 3, H, W$]

学習時は 1 症例 11 枚のフレームを 1 から 11 とすると、(1-3), (2-4), (3-5), ... のようにオーバーラップさせながら 1 症例あたり 9 つの学習データセットを作成した。これにより、学習に使用するデータ数を増やし、合併症の予測精度の向

上を図る．ただし，検証およびテストでは，11枚のうち中心から前後1フレームを抽出して入力とするため， $[C \times 3, H, W]$ の形状を一貫して用いた．

5.2.2 評価手法

第4章では単体フレーム11枚をそれぞれ入力し，予測ラベルを多数決で統合することで症例ごとの合併症の発症を評価した．しかし，本章では複数フレームをまとめて入力しているため，フレーム間の多数決は行わずに，モデルが出力する症例単位の予測結果から各評価指標を算出する．

5.3 実験結果

表5.1は，5.2.1節で述べた2種類のモデルへの入力を用いた際の合併症の予測精度をまとめた結果である．

表 5.1 2.5D モデルを用いた合併症の予測精度

	正解率	適合率	再現率	F1 スコア	AUC
Wu ら[8]	0.62	0.67	0.65	0.65	0.64
入力サイズ [11, H, W]	0.56	0.58	0.61	0.56	0.57
入力サイズ [3, H, W]	0.54	0.53	0.51	0.56	0.56

5.4 考察

本研究では，第4章で述べた単体フレームの入力を比較対象として， $[C \times 11, H, W]$ および $[C \times 3, H, W]$ の2種類の入力サイズで2.5Dを用いた合併症の予測精度を検証した．しかし，表5.1で示した結果から，いずれの手法も第4章で行った実験より予測精度を上回ることができなかった．この原因として，各フレーム間で関心領域の位置がずれていることが考えられる．図5.1に示すのは

連続する IVUS 画像例であり、画像上の中心に映る IVUS カテーテルの血管内における位置がフレームごとに変化することが確認できる。そのため、プラーク病変部の位置もフレームごとに変化している考えられる。

IVUS 動画は血管内に挿入した IVUS カテーテルが血管内部で回転しながら連続的に断面画像を取得するため、同一症例内のフレーム間においてもフレームごとにプラーク病変部の位置が異なる。本研究では連続フレームをチャンネル方向に重ねて 2 次元畳み込みを適用したが、フレーム間で関心領域が統一されていないため、モデルがプラーク病変部を一貫した領域として認識することが困難であった可能性がある。したがって第 4 章の実験と比較して精度が低下してしまったと考えられる。

この課題を解決するための手法として、フレーム間の位置のズレを補正する前処理を行う必要があると考える。具体的には、連続するフレーム間の類似度を算出し、各フレームを回転させることで関心領域が同じ位置になるように補正する。このようなフレーム補正のアルゴリズムを導入することで合併症の予測精度の向上が期待される。




図 5.1 連続する IVUS 画像例

第 6 章

結論

本研究では、PCI 中に発症する合併症である No reflow および Slow flow の発症を術前に取得される IVUS 画像から予測することを目的として、深層学習モデルを用いた手法の検証を行った。第 4 章では、単体フレームの IVUS 画像をモデルへの入力とし、層の数が異なる ResNet を用いた実験および合併症の関心領域抽出タスクを活用した学習手法を用いて合併症の予測精度を検証した。その結果、単体フレームを入力とする ResNet-101 を用いた場合に最良の正解率を得た。これは深層学習モデルが画像中のプラーク領域や血管系などの特徴を学習することで、従来の減衰プラーク量のみから合併症予測する手法を上回ることができたと考えられる。

一方で、関心領域抽出タスクを用いた逐次学習とマルチタスク学習では精度の向上は見られなかった。この原因は IVUS 画像中に含まれている減衰プラークを十分にアノテーションできていないことが考えられる。そのため、IVUS 画像内の減衰プラークが存在する方向の情報をモデルに学習させることで精度の向上が期待される。

また、第 5 章ではプラーク病変部の 3 次元特性を捉えるため、2.5D モデルを用いた複数フレーム入力手法を検討した。しかし、フレーム間でプラークの位置にズレが生じる問題があり、単体フレームの入力に比べて精度の向上は得られなかった。フレームの回転処理を前処理に加えることの導入により 3 次元特性を正確に捉えられるように工夫することで精度の向上が期待される。

謝辞

本研究を遂行し、本論文を執筆するにあたり、多大なご指導を頂きました千葉大学フロンティア医工学センター 教授 中口俊哉先生に心より感謝し、御礼申し上げます。

また、同センター准教授 野村行弘先生、千葉大学医学部附属病院循環器内科 西 毅先生には多くの助言、激励を賜りました。深く感謝いたします。

そして、本研究を遂行するにあたり活発な議論や貴重なご意見など多岐にわたるご支援を頂きました同研究室博士前期過程 田中 一輝さんをはじめ、本研究室の先輩の皆様、同輩の皆様、後輩の皆様に深く感謝いたします。

最後に、学業ならびに研究活動を遂行するにあたり、陰ながら見守り支援してくれた両親に心から感謝いたします。

2025 年 2 月 金子 慧士

参考文献

- [1] 虚血性心疾患 . Accessed: Jan. 12, 2025. [Online]. Available: <https://www.ncvc.go.jp/hospital/pub/knowledge/disease/ischemic-heart-disease/>
- [2] PCI (心臓の血管のカテーテル治療) . Accessed: Jan. 12, 2025. [Online]. Available: https://www.cvut.jp/_new/patient/info_p/pci.php
- [3] B. Babapoor, S. Sadeghieh-Ahari, M. Sadeghi Hariri, and B. Shahbazzadegan, “Survey of effective factors in slow flow and no reflow in primary percutaneous coronary intervention patients,” *Int J Community Med Public Heal*, vol. 9, p. 1222, 2022.
- [4] 日比潔, 本田康浩, 木村一雄, and 梅村敏, *IVUS (血管内超音波法)*, vol. 第102. in 動脈硬化症：診断と診療の進歩, no. 第2号, vol. 第102. 日本内科学会雑誌, 2013.
- [5] IVUS カテーテルの見方を覚えるエクササイズだ！. Accessed: Jan. 12, 2025. [Online]. Available: <https://med-infom.com/?p=3475>
- [6] T. Nishi *et al.*, “Deep learning-based intravascular ultrasound segmentation for the assessment of coronary artery disease,” *Int. J. Cardiol.*, vol. 333, pp. 55–59, 2021.
- [7] L.-C. Chen, “Rethinking atrous convolution for semantic image segmentation,” *ArXiv Prepr. ArXiv170605587*, 2017.
- [8] X. Wu *et al.*, “The Relationship Between Attenuated Plaque Identified by Intravascular Ultrasound and No-Reflow After Stenting in Acute Myocardial Infarction,” *JACC Cardiovasc. Interv.*, vol. 4, no. 5, pp. 495–502, May 2011, doi: 10.1016/j.jcin.2010.12.012.
- [9] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA: IEEE, Jun. 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.
- [10] A. Amyar, R. Modzelewski, H. Li, and S. Ruan, “Multi-task deep learning based CT imaging analysis for COVID-19 pneumonia: Classification and segmentation,” *Comput. Biol. Med.*, vol. 126, p. 104037, 2020.
- [11] W. J. Youden, “Index for rating diagnostic tests,” *Cancer*, vol. 3, no. 1, pp. 32–35, 1950, doi: 10.1002/1097-0142(1950)3:1<32::AID-CNCR2820030106>3.0.CO;2-3.

卒業論文 複数タスク融合と2次元学習による経皮的冠動脈形成術の合併症予測 金子 慧士（二〇二四年度）