



國立臺灣大學醫學院暨工學院醫學工程學研究所

碩士論文

Department of Biomedical Engineering

College of Medicine and College of Engineering

National Taiwan University

Master's Thesis

體素層級監督式對比學習融合 3D U-Net 之冠狀動脈

光學同調斷層影像鈣化斑塊分割

Voxel-level Supervised Contrastive Learning with a 3D U-

Net for Calcified Plaque Segmentation on Intracoronary

Optical Coherence Tomography Images

殷語芊

Yu-Qian Yin

指導教授：陳中明博士

Advisor: Chung-Ming Chen, Ph.D.

中華民國 115 年 1 月

January 2026



摘要

冠狀動脈鈣化 (Coronary Artery Calcium, CAC) 與不良臨床預後相關，亦可能影響經皮冠狀動脈介入治療 (Percutaneous Coronary Intervention, PCI) 之處置策略與手術結果。臨床上，對其範圍與嚴重程度之辨識與量化具有重要價值。血管內光學同調斷層掃描 (Intravascular Optical Coherence Tomography, IVOCT) 可提供高解析度影像導引，然而單次 Pullback 之影像量龐大，且逐幀人工標注成本高，使得即時且一致的全面評估難以達成。因此，冠狀動脈斑塊的自動化分析方法具有重要的臨床應用價值。

本研究旨在建立冠狀動脈 OCT 影像之鈣化斑塊自動分割方法，以降低逐幀人工標注負擔，並支援後續臨床量化分析與治療規劃。研究資料依病患為單位分為訓練、驗證與測試資料集，訓練集包含 125 名病患，驗證集與測試集各 6 名病患；對應影像幀數分別為 31,967、1,499 與 1,482 幀。

方法上，本研究以監督式學習之三維 U 形網路 (3D U-Net) 作為分割骨幹，引入了體素層級的對比式學習 (Voxel-level Contrastive Learning)，用於在冠狀動脈光學同調斷層掃描 (OCT) 影像中分割冠狀動脈鈣化。針對鈣化病灶呈小體積或薄片狀與類別嚴重不平衡所導致之漏檢與邊界不穩定問題，該對比式分支以標注為依據定義正負樣本關係，直接在特徵空間強化鈣化與背景之可分離性，以期實現局部細緻分割，並降低漏檢風險。此外，本研究引入類別導向之位列式記憶庫以累積跨批次特徵，藉此擴充可用樣本對並降低小批次取樣偏差，使樣本集合可隨訓練歷程持續更新。另為避免負樣本集合被大量且易區分的背景所主導，進而稀釋對比學習的有效訊號，本研究採用困難負樣本挖掘結合隨機抽樣的混合策略，以實現聚




焦於易混淆背景的同時兼顧背景多樣性之維持。

結果顯示，體素層級的對比式學習結合 3D U-Net 的方式在冠狀動脈 OCT 影像之鈣化斑塊分割中呈現良好效能表現，相較於 3D U-Net 基礎模型，本研究方法取得穩定但幅度有限之提升，達到 Dice 係數 (Dice Coefficient, DSC) 0.8383 ± 0.0127 ，交並比 (Intersection-over-union, IoU) 0.7216 ± 0.0109 ，顯示鈣化斑塊預測區域與人工標注之空間重疊度良好。精確率 (Precision) 0.8825 ± 0.0134 、平衡準確率 (Balanced Accuracy, BalAcc) 0.8964 ± 0.0136 與 馬修斯相關係數 (Matthews Correlation Coefficient, MCC) 為 0.8313 ± 0.0126 。值得注意的是，靈敏度達到 (Sensitivity; 亦即 Recall) 0.7984 ± 0.0121 ，比之 3D U-Net 基礎模型上升了 1.99%，體現其增加了鈣化之檢出。影像層面之觀察亦指出，本方法對體積較小或薄片狀鈣化病灶能提供較穩定之分割邊界。

綜合而言，本研究提出之體素層級監督式對比式學習，透過標注導向的表徵學習機制，提升小目標且嚴重類別不平衡情境下之鈣化分割能力，具有作為冠狀動脈鈣化量化流程輔助工具之潛力。

關鍵詞：冠狀動脈心臟病、鈣化斑塊、光學同調斷層掃描、人工智慧、卷積神經網路、影像分割、對比式學習



Abstract

Coronary artery calcification (CAC) is associated with adverse clinical outcomes and may influence both procedural strategy and outcomes in percutaneous coronary intervention (PCI). Accurate identification and quantification of CAC extent and severity are therefore clinically important. Intravascular optical coherence tomography (IVOCT) provides high-resolution imaging guidance; however, a single Pullback contains a large number of frames, and frame-by-frame manual annotation is labor-intensive. These factors make real-time, consistent, and comprehensive assessment difficult in routine practice. Consequently, automated analysis of coronary plaque has substantial clinical value.

This study aims to develop an automatic calcified plaque segmentation method for coronary OCT images to reduce the burden of frame-level manual annotation and to support downstream quantitative analysis and treatment planning. The dataset was split at the patient level into training, validation, and test sets. The training set included 125 patients, while the validation and test sets each included 6 patients, corresponding to 31,967, 1,499, and 1,482 frames, respectively.

Methodologically, we used a 3D U-Net as the supervised segmentation backbone and incorporated voxel-level contrastive learning to segment calcified plaque in coronary OCT images. To address missed detections and unstable boundaries caused by small-volume or thin, sheet-like lesions and severe class imbalance, the contrastive branch defined positive and negative pairs using manual annotations. This design explicitly increases the separability between calcification and background in feature space, with the goal of improving local, fine-grained segmentation and reducing false negatives. In addition, we introduced a queue-based memory bank with class-aware sampling to accumulate cross-batch embeddings, thereby expanding the pool of available contrastive pairs and alleviating mini-batch sampling bias. To avoid the negative pool being overwhelmed by abundant, easily separable background, which would weaken the contrastive signal, we further adopted a hybrid strategy that combines hard negative

mining with random sampling. This approach emphasizes confusing background regions while maintaining background diversity.

The proposed method demonstrated strong performance for calcified plaque segmentation in coronary OCT images. Compared with the 3D U-Net base model, it achieved a consistent but modest improvement, reaching a Dice coefficient (DSC) of 0.8383 ± 0.0127 and an intersection-over-union (IoU) of 0.7216 ± 0.0109 , indicating good spatial overlap with manual annotations. It also achieved a precision of 0.8825 ± 0.0134 , a balanced accuracy (BalAcc) of 0.8964 ± 0.0136 , and a Matthews correlation coefficient (MCC) of 0.8313 ± 0.0126 . Notably, sensitivity (Recall) reached 0.7984 ± 0.0121 , representing a 1.99% increase over the 3D U-Net baseline and suggesting improved detection of calcified lesions. Qualitative inspection further indicated that the proposed method produced more stable boundaries for small or thin, sheet-like calcifications.

In summary, we propose a voxel-level supervised contrastive learning framework that leverages annotation-guided representation learning to improve calcification segmentation under small-target and severely imbalanced conditions. The method shows potential as an assistive tool for coronary calcification quantification workflows.

Keywords: Coronary Artery Disease, Calcified Plaque, Optical Coherence Tomography (OCT), Artificial Intelligence, Convolutional Neural Networks, Image Segmentation, Contrastive Learning

目次




摘要	i
Abstract	iii
目次	v
圖次	viii
表次	x
第一章 緒論	1
1.1 研究背景	1
1.2 研究目的	3
第二章 文獻回顧	7
2.1 深度學習用於醫學影像分割之相關研究	7
2.2 冠狀動脈光學同調斷層掃描影像分割之相關研究	8
2.3 對比式學習應用於影像分割之相關研究	10
第三章 研究材料與方法	12
3.1 研究材料	12
3.2 驗證方法與資料分配	13
3.3 影像前處理	13
3.3.1 管腔面積分割與移除	14
3.3.2 極座標與灰階轉換	15
3.3.3 影像增強	17



3.3.4 資料擴增	18
3.3.5 A-line 徑向像素平移對齊	19
3.3.6 導絲陰影移除	20
3.3.7 VOI 堆疊	22
3.4 3D U-Net 之基礎分割模型	23
3.4.1 損失函數	23
3.4.2 非等向之 3D U-Net 網路架構	24
3.4.3 訓練細節	25
3.5 監督式體素層級對比學習	27
3.5.1 體素層級監督式對比學習架構	27
3.5.2 類別導向之佇列式記憶庫	29
3.5.3 雙視角輸入設計	30
3.5.4 負樣本之選取	33
3.5.5 軟正樣本加權體素層級監督式對比損失	35
3.6 後處理	37
第四章 結果與討論	39
4.1 資料擴增之結果	39
4.2 評估指標	40
4.3 3D U-Net 方法之分割結果與討論	41
4.4 先期探索：不同表徵學習策略之比較（以 BYOL 為例）	43
4.5 體素級對比式學習之結果與討論	48
4.6 嵌入空間之類內凝聚與類間可分性分析	51

4.7 本研究之限制與未來工作.....	55
第五章 結論.....	59
參考文獻.....	62
附錄.....	71





圖次

圖 1 血管攝影技術之影像對比.....	2
圖 2 商用軟體標註之鈣化斑塊（標註區域均為鈣化）.....	3
圖 3 鈣化斑塊之影像標注.....	12
圖 4 資料前處理流程圖.....	14
圖 5 管腔分割（Lumen Segmentation）之 2D U-Net 模型結構圖（節錄自[39]）.....	15
圖 6 管腔面積分割圖.....	15
圖 7 極座標轉換前後之影像及標註掩膜.....	16
圖 8 增強前後之影像.....	18
圖 9 資料擴增之示意圖.....	19
圖 10 A-line 徑向平移前後之影像.....	20
圖 11 導絲陰影移除示意圖.....	21
圖 12 VOI 堆疊之示意圖.....	22
圖 13 Attention Gate 運算過程示意圖.....	27
圖 14 體素層級監督式對比學習+ 3D U-Net 模型架構圖.....	28
圖 15 影像角向位移前後示意圖.....	31
圖 16 影像翻轉前後示意圖.....	32
圖 17 負樣本選取之流程圖.....	33
圖 18 後處理之方法示意圖.....	38
圖 19 資料擴增結果.....	39

圖 20 鈣化分割之四種結果示意圖.....	40
圖 21 3D U-Net 冠狀動脈 OCT 影像鈣化斑塊之自動分割結果.....	42
圖 22 BYOL 架構圖.....	43
圖 23 BYOL 預訓練之各項結果指標.....	44
圖 24 BYOL 與 3D U-Net 分割結果對比圖.....	46
圖 25 體素層級監督式對比學習+ 3D U-Net 鈣化分割結果.....	48
圖 26 體素層級監督式對比學習融合 3D U-Net 之困難鈣化分割結果	50
圖 27 類內與類間餘弦相似度分布圖.....	51
圖 28 t 分佈隨機鄰域嵌入 (t-distributed Stochastic Neighbor Embedding, t-SNE)	52
圖 29 不同背景定義差異下之餘弦相似度分布 (KDE)	54
圖 30 不同背景定義差異下之類間餘弦相似度分布 (KDE)	54
圖 31 不同背景定義下之 ROC.....	55
圖 32 困難案例示例：鈣化區域異質性導致之分割碎片化.....	56
圖 33 困難案例示例：鈣化區域後訊號衰減導致之分割厚度被低估 .57	
圖 34 Dice Loss 之收斂曲綫.....	71
圖 35 訓練過程中驗證集多指標走勢.....	71
圖 36 hard negative 之來源比例曲綫.....	72
圖 37 邊界帶狀背景定義下之類間餘弦相似度分布直方圖.....	72
圖 38 困難背景定義下之類間餘弦相似度分布直方圖.....	73



表次

表 1 資料分配表.....	13
表 2 訓練最佳化與學習率調度之超參數設定.....	26
表 3 不同標註資料量下，3D U-Net 與 BYOL 預訓練模型之 Dice 係數 比較.....	45
表 4 加入體素級對比式學習前後之評價指標對比.....	49



第一章 緒論

1.1 研究背景

截至 2024 年，全球主要死亡原因中，心血管疾病約占總體 16%，而其中冠狀動脈疾病（Coronary Artery Disease, CAD）為主要致死性疾病之一，每年約導致 1,780 萬人死亡[1-3]。

冠狀動脈鈣化(Coronary Artery Calcium, CAC)是動脈粥樣硬化的標志性特徵，是 CAD 發病率和死亡率的獨立預測因子[4]。其嚴重程度與動脈粥樣硬化的程度高度相關。既有綜述指出其可降低血管順應性、並致血管運動反應異常，及心肌灌注受損[5]。

先前以電腦斷層攝影（Computed Tomography, CT）量測冠狀動脈鈣化之研究同樣表明，CAC 的存在與否與其嚴重程度可提供重要的預後訊息：可用於心血管事件風險分層，且較高 CAC 負荷通常對應較高不良臨床事件風險[6-7]。心血管成像是診斷冠狀動脈疾病和評估冠狀動脈鈣化中起著關鍵作用。

臨床醫師常規使用冠狀動脈造影（Coronary Angiogram, CAG）評估血管管腔形態（圖 1（a）），並據以規劃治療策略。然而，CAG 主要呈現管腔輪廓，難以直接提供血管壁和斑塊成分相關資訊[8]。當鈣化病灶嚴重時，造影可能出現鈣化徵象，但仍不足以界定鈣化於血管壁內的分布範圍與邊界[9]。

雖然血管內超聲（Intravascular Ultrasound, IVUS）也可識別冠狀動脈鈣化的位置，能評估支架植入術並進行斑塊特徵分析[10]，有較佳穿透深度（約 4-10mm; IVOCT: 1-2mm）[11]，且成像時無需清除血液，但由於射頻信號從鈣化組織界面反射形成聲影(圖 1（b）之黃色箭頭)，無法準確評估冠狀動脈鈣化（CAC）的面積與



厚度[12]。現今,隨著醫學影像技術的快速進展,對於 CAD 的診斷得到了顯著提升 [13]。

血管內光學同調斷層掃描 (Intravascular Optical Coherence Tomography, IVOCT) 是一種高對比度、高解析度 (軸向: $15\mu\text{m}$, 橫向: $25\text{-}30\mu\text{m}$) 的血管內成像技術, 它利用近紅外光生成冠狀動脈的橫截面圖像。與血管內超聲 (IVUS) 相比, 其具有相對更高的軸向解析度 ($10\text{-}20\mu\text{m}$; IVUS: $100\text{-}150\mu\text{m}$) 和橫向解析度 ($20\text{-}40\mu\text{m}$; IVUS: $150\text{-}300\mu\text{m}$) [11-16]。能夠細緻呈現冠狀動脈血管壁淺層結構[17], 包括血管管腔尺寸和血管壁特徵。該技術不僅可識別鈣化, 定位鈣化位置, 同時較能清晰描繪近血管腔面的鈣化邊界, 測定鈣化角度、厚度、深度, 進而量化鈣化程度[18-19]。從而實現對目標血管中鈣化斑塊長度、弧度及深度的精準量化。

由此可見, 血管內光學同調斷層掃描 (IVOCT) 相較於其他成像方式在診斷冠狀動脈鈣化方面具有顯著優勢, 是目前臨床評估淺表性冠狀動脈鈣化極為重要的工具之一。如圖 1 (c) 所示, 在 IVOCT 成像下, 冠狀動脈鈣化表現為邊界清晰的低訊號區域[20]。




圖 1 血管攝影技術之影像對比: (a) CAG 影像 (紅色箭頭為血管狹窄); (b) IVUS 影像 (黃色箭頭為鈣化); (c) 冠狀動脈 OCT 影像 (白色箭頭區域為鈣化)

儘管血管內光學同調斷層掃描 (IVOCT) 具有高解析度, 影像判讀與鈣化斑塊病灶範圍判定仍具挑戰性。其困難主要源於 IVOCT 影像中不同鈣化斑塊之大小與形態特徵可能差異明顯, 且其輪廓可呈不規則形狀, 如圖 2 所示。鈣化在 OCT 影



像中呈現低後向散射文獻多將鈣化描述為訊號偏低或異質性區域，並強調常伴隨清晰、銳利的邊界面，因而可據以描繪鈣化範圍，並進一步測量鈣化角度、厚度、深度等指標，用於量化鈣化嚴重程度[21]。

然而，當鈣化較厚或伴隨明顯訊號衰減時，鈣化後緣可能因訊號衰減不易判讀，進而增加邊界描繪與厚度量測的不確定性[22]。另一方面，影像取得過程亦會引入多種偽影，可能受到殘餘血液或血栓造成的散射與衰減陰影影響，導絲與金屬支架亦可能形成遮蔽，進而增加鈣化斑塊區域範圍判斷與定量分析的困難[15]。

由上述因素可見，IVOCT 影像的判讀具有挑戰性，加之人工逐幀判讀與標註不僅耗時，且可能存在觀察者內與觀察者間差異影響，因此本研究聚焦於建立自動化鈣化分割方法，以支援後續量化分析。





圖 2 商用軟體標註之鈣化斑塊（標註區域均為鈣化）

1.2 研究目的

經皮冠狀動脈介入治療（Percutaneous Coronary Intervention, PCI）是治療冠狀動脈疾病（CAD）最常施行的手段之一[23]。多份臨床研究結果表明，冠狀動脈鈣化（Coronary Artery Calcification, CAC）被視為影響 PCI 手術成功與後續臨床結局的重要因素之一。全球 PCI 每年施行量逾 200 萬例[24]。



在 PCI 處置中（包括球囊血管成形術與支架置放），血管壁鈣化斑塊可能增加處置難度，並與再狹窄、冠狀動脈夾層風險上升相關；於支架置放後，鈣化病灶亦可能增加支架內血栓形成之發生可能性[25-28]。此外，鈣化病灶可能導致支架擴張不足與支撐杆貼壁不良，進而使得支架失效之機率升高[29-30]。


整體而言，嚴重鈣化病灶常與較高的並發症風險與不良事件發生率相關，並可能導致較差的臨床結局與預後[31]。但值得注意的是，CAC 在接受 PCI 的病例中相當常見，文獻報告其出現比例約為 17% 至 35% [32-34]。

基於上述背景，臨床上如何準確評估鈣化程度並選擇合適的病灶處置策略，遂成為改善 PCI 療效的重要課題。

既有研究顯示，影像導引之 PCI 與較佳程序結果，且在部分研究中與較佳臨床結局相關。臨床團隊若能準確辨識並量化冠狀動脈鈣化病灶（Coronary Artery Calcification, CAC）的範圍與嚴重程度，即有助於規劃 PCI 之病灶處置策略，並支援術後支架結果之評估[23-35]。

在 PCI 情境下，IVOCT 因具較高空間解析度，得以較清晰地表徵板塊形態，因而可作為 PCI 之影像導引工具，以支援術中決策與支架植入後結果評估[36]。既有研究亦提出基於 OCT 之鈣化評分系統，並以鈣化角度、厚度與長度等量測特徵作為指標，用以預測支架擴張不足與輔助病灶處置策略[19]。與單純 X 射綫血管造影引導的 PCI 相比，IVOCT 導引之 PCI 可提供血管造影難以完整呈現之病灶與支架相關資訊，為患者治療帶來額外價值[37]。這些優勢促使 IVOCT 在臨床和科研領域獲得更廣泛應用。

醫師需要準確掌握冠狀動脈鈣化(CAC)的形態特徵(如角度、深度和厚度等)，並據以規劃病灶處置與支架置放策略，以降低支架擴張不足之發生風險。但臨床上



要對 IVOCT 影像中冠狀動脈斑塊進行評估具有挑戰性，需要基於大量的專業知識，在鈣化病竈判讀方面，CAC 在 IVOCT 影像中呈現異質性特徵，且 OCT 之穿透深度受限，常使臨床醫師不易準確判定斑塊性質，並進一步增加量化評估的難度。判讀過程不僅耗費人力及時間，且其過程易受到主觀影響，存在觀察者間和觀察者內的高度差異[38]，從而提升誤判風險。此外，每位病患進行一次血管內攝影即會產生上百張影像，單次 2-3 秒的 IVOCT Pullback 掃描通常就會產生 300-500 幀圖像，如此龐大的影像量使醫師無法在經皮冠狀動脈介入治療（PCI）過程中實時完成全面分析。由此可見，配備快速、準確且自動化的鈣化分析方法，對於制定及時的治療決策至關重要，在 IVOCT 影像中實現自動化斑塊分析具有明確需求。

隨著精準醫療的蓬勃發展，目前已有許多研究將人工智慧中的兩大分支：機器學習（Machine Learning, ML）和深度學習（Deep Learning, DL）應用於醫學領域中。近年研究已提出以深度學習為基礎之冠狀動脈 OCT 影像中鈣化病灶偵測與自動分割方法，幫助實現冠狀動脈 OCT 影像判讀自動化。然而，鈣化病灶多呈小面積且類別高度不平衡，使現行方法在漏檢控制與邊界穩定性上仍面臨挑戰。

儘管各種深度學習模型用於冠狀動脈 OCT 影像之斑塊分割已取得了一定成效，但目前此領域之現行深度學習中，現行訓練多仍以交叉熵（Cross-Entropy）與 Dice 係數（Dice Coefficient, DSC）等監督式損失為主，主要聚焦在單張影像的局部資訊，忽略整個資料集裏同類樣本所提供的全域資訊。此類設計雖能有效促進局部判別，但在目標結構在整張影像中占比面積極小，且類別極度不平衡的情境下，模型的更新方向容易受到大量背景樣本影響，使少數類別之有效學習訊號相對不足。以 IVOCT 鈣化分割為例，鈣化區域往往僅占影像中極小比例；在此條件下，即使採



用 Cross-Entropy 與 Dice 的加權組合，模型仍可能傾向優先優化整體損失，導致對細小鈣化區域的辨識與邊界刻畫不易穩定提升。

基於上述限制，且對鈣化分割任務而言，漏檢可能導致病灶量化低估，進而影響後續風險評估與治療規劃之可靠性。因此，本研究將提升鈣化檢出能力與困難區域之可分辨性作為主要目標，在監督式學習基礎上引入體素層級之對比式學習，目的在於在特徵空間直接施加同類更近、異類更遠的結構化約束，使目標體素與背景體素在表徵上更可分，而不僅依賴單張影像內的局部擬合。具體而言，本研究以相似度量測作為對比目標，以在特徵空間拉開類間距離、壓縮類內距離，從而在目標很小與極度不平衡的情況下，更充分地對其表徵進行學習。

此外，本研究透過記憶庫（Memory Bank）機制擴展正負樣本的來源，使對比約束不僅局限於當前 Mini-batch，而能在訓練過程中累積並利用整個數據集的樣本資訊。此一設計有助於模型同時學習單張影像的局部結構特徵與資料集層級的同類表徵一致性，在原模型的基礎上進一步提升鈣化目標在不同影像條件下的可辨識度與穩健性。

本研究以 3D U-Net 為核心分割架構，並於監督式訓練中引入體素層級對比式學習分支，以強化鈣化體素與背景在特徵空間之可分辨性，進而降低小目標與嚴重類別不平衡下之漏檢風險。另一方面，本研究結合記憶庫與困難負樣本挖掘策略，使對比約束可累積跨批次之樣本訊息，提升模型在不同影像條件下之辨識穩健性。整體而言，本研究目標在建構可用於術前冠狀動脈 OCT 影像之血管結構與鈣化斑塊自動分割模型，作為臨床判讀與量化流程之輔助依據。



第二章 文獻回顧

為建構可應用於冠狀動脈光學同調斷層掃描(OCT)影像的鈣化斑塊(Coronary Artery Calcified, CAC)分割模型，本研究除回顧冠狀動脈 OCT 相關之分割研究外，亦參考既有醫學影像分割文獻之方法與模型架構，並整合對比式學習於醫學影像表徵學習之相關研究。

2.1 深度學習用於醫學影像分割之相關研究

U-Net (2015) 為醫學影像像素級分割奠定了經典的端到端架構，設計目的在於同時獲取充分的上下文資訊並維持精準定位能力。Ronneberger 等學者指出，深度網路的成功訓練通常仰賴大量標注資料，但生醫影像往往難以取得足夠標注，因此作者在訓練策略上強化資料擴增，以提升少量標注樣本的利用效率[39]。分割任務需要同時兼顧語意判別與精準定位；為提升定位能力，該研究提出由收縮路徑(Contracting Path)與擴張路徑(Expansive Path)構成的編碼器—解碼器網路，並以跨層特徵串接方式將高解析度特徵引入解碼端。更關鍵的是，為補償下採樣所帶來的空間細節流失，U-Net 在每一層上採樣過程中，將解碼端的上採樣特徵與編碼端對應層級之高解析度特徵圖進行串接(Concatenation；亦即 Skip Connection)，使後續卷積得以在保留語意上下文的同时重建邊界與局部結構，進而形成較為精確的分割輸出。

相較於 2D 影像，3D U-Net(2016)進一步回應了體積影像(Volumetric Data)在標注成本與學習有效性上的挑戰。Çiçek 等人指出，逐張切片完整標注 3D 影像相當耗時，且相鄰切片資訊高度冗餘[40]；因此其將 U-Net 的 2D 運算全面替換

為 3D 卷積、3D 最大池化與 3D 上採樣 (Up-convolution) 捲積，使模型可直接從 3D 影像學習並輸出體素級 (Voxel-wise) 分割，實現了直接利用三維上下文。

綜上所述，U-Net 家族提供一套端到端的通用分割框架。該系列方法以多解析度特徵表示與跨層特徵串接為核心，使模型在學習語意判別的同時，仍能保留空間定位資訊並準確描繪結構邊界。基於上述特性，U-Net 及其衍生模型已被廣泛應用於各類醫學影像分割任務，且在同時要求局部細節保留與全域上下文整合的任務中，其跨層特徵串接所帶來的細節保留能力，使其具備方法上的優勢。

2.2 冠狀動脈光學同調斷層掃描影像分割之相關研究

先前研究已運用機器學習與深度學習技術，嘗試在冠狀動脈光學同調斷層掃描 (OCT) 影像中辨識斑塊成分，推動冠狀動脈鈣化 (CAC) 的自動化分析。既有方法的發展大致可分為兩條脈絡：早期採用以影像處理與特徵工程為主的傳統機器學習方法，以及近年以端到端學習為核心的深度學習分割方法。以下依研究演進整理相關工作。

在傳統方法方面，Wang 等人提出以主動輪廓為核心之半自動流程，用於冠內 OCT 影像中鈣化斑塊之分割與量化[41]；該方法以 Level-set 形式實作主動輪廓，並結合強度與梯度資訊以追蹤鈣化邊界。後續研究[42-43]管腔邊界為基礎界定 IVOCT 掃描的有效成像深度再結合隨機森林、K 均值聚類等模型進行鈣化斑塊的偵測。Ughi 團隊[42]在最大穿透深度內建立血管壁之分析區域 (ROI) 的基礎上，進一步結合光學衰減係數與多項紋理特徵，並以 Random Forests 進行監督式像素分類，以辨識纖維、脂質與鈣化等組織成分；其報告之整體分類準確率為 81.5%。黃等人 (2018) 則開發了一種基於支持向量機 (SVM) 的血管內 OCT 圖像分割方法[44]。該技術可分割三種斑塊成分：含脂質區域、纖維組織和鈣化灶。以灰階共




生矩陣推得之衰减係數與影像紋理特徵作為模型特徵，其像素級準確率為 83%，其中纖維組織為 89%、鈣化組織為 79.3%、脂質組織為 86.5%。

近年來，深度學習方法已廣泛應用於 OCT 影像分析，並在多項研究中呈現良好表現；相較於依賴手工特徵工程之傳統方法，深度模型可透過端到端學習自動擷取判別性表徵，從而降低特徵設計負擔，同時並維持對斑塊邊界與組織差異的辨識能力。多種語意分割架構已被引入 OCT 影像分析，例如 U-net[39]、SegNet [45] 和 Deeplab v3+[46]。作為典型的二維分割模型，SegNet[45]也被多項研究[47-48]應用於鈣化、脂質等特徵的像素級分割，並結合條件隨機場進行後處理，以維持 A-line 間的空間相似性。相較於僅以單一橫截面作為輸入的 2D 分割流程，Gessert 團隊[49]提出極座標與笛卡兒雙路徑的 CNN 架構，並在斑塊偵測與 CAC 分類任務中分別達到 91.7% 與 79.4% 的準確率。由於冠狀動脈病灶具有三維連續性，研究亦提出偽 3D、2.5D 或 3D CNN 可能更具分析優勢。

He 等[50]利用 ResNet-3D 網路對 OCT Pullback 圖像中的冠狀動脈鈣化(CAC)進行識別，以 4860 幀 OCT 影像數據集訓練模型，驗證了三維卷積神經網路在 OCT 影像分析中的可行性。借鑒 He 等人的方法，Lee 團隊[51]在此基礎上開發了全自動的"檢測-分割"兩步法用於 IVOCT Pullback 影像中的 CAC 表徵。該研究首先運用三維卷積神經網路(3D CNN)模型檢測主要鈣化病灶，繼而採用 SegNet 實現像素級分類。

與單幀輸入模型不同，Chu 等人於 2021 年提出了一種端到端的深度卷積神經網路(CNN)模型，該模型採用偽三維輸入實現多類別分割[52]。延續多類別斑塊分割的研究脈絡，Wang 等人則以冠狀動脈 OCT 多類別病灶分割為目標(Normal Tissue、Fibrosis、Lipid、Calcification，並含 Background)，在 U-Net 架構底部整




合 SPP 與 Sk-Conv 模組以強化多解析度層級特徵表徵[53]。Liu[54]等人提出了一種結合增強特徵分割 (Augmented Feature Split, AFS) 模組之 Transformer 模型，用於 OCT 影像中鈣化斑塊的分割，並透過自注意力機制與 Location Embedding 引入位置資訊。研究成果顯示，該方法在鈣化斑塊分割中取得了 83.79% 的 Dice 係數。

回顧既有研究可見，IVOCT 斑塊分析技術已從早期以人工輔助流程與手工特徵萃取為主的機器學習方法，演進至以深度學習為核心的分割模型。研究已顯示了自動化分割技術在提升鈣化斑塊分割準確性、減少人工介入與提升判讀效率方面具備發展潛力。

2.3 對比式學習應用於影像分割之相關研究

本文以對比式學習 (Contrastive Learning) 作為核心方法，並聚焦其於影像分割任務之應用脈絡。對比式學習屬於表徵學習方法之一，其主要概念為透過正負樣本配對與對比式損失，促使模型在特徵空間中拉近相似樣本並推離不相似樣本，以形成具判別力之嵌入表示。早期研究已以對比式損失學習不變表徵並建立嵌入空間[55]，其後 CPC 所提出之 InfoNCE 形式奠定自監督對比學習的重要基礎。隨後，SimCLR 與 MoCo 等方法以資料增強後之雙視角構成正樣本對，系統化推動對比式預訓練並提升標注效率[56]。

然而，多數自監督對比學習框架，如 SimCLR、MoCo 等主要為影像分類而設計，訓練目標傾向於學得全域不變表徵，降低對裁切、翻轉與色彩變化等擾動之敏感度。相較之下，分割與偵測等密集預測 (Dense Prediction) 任務更依賴局部對應關係與空間細節，因此研究逐步將對比學習由影像層級延伸至局部的像素或區塊層級，例如 DenseCL 將對比目標下放至局部，以提升對密集任務之適用性[57]。



另一方面，Alonso 等人提出以像素層級對比模組，進行表徵對齊，其結果顯示，在標注資料比例偏低的情境下仍可取得良好表現[58]。此外，Khosla 等人提出監督式對比學習（Supervised Contrastive Learning），將類別標籤直接納入正樣本定義，使對比式學習能更自然地與監督式任務整合，常被用於提升下游模型之泛化與穩定性[59]。

Chae Eun Lee 等人採用全監督體素層級表徵學習，於 3D U-Net 訓練階段以標註定義同類體素配對，以 SimSiam 與 Stop-gradient 促進同類嵌入聚合以強化跨體積語意表徵。其方法應用於腹部電腦斷層影像之多器官分割時，平均 Dice 由 0.786 提升至 0.806，且 HD95 與 ASSD 同步改善，增益在小器官上更為明顯[60]。

儘管相關方法已於自然影像與部分醫學影像任務中顯示潛力，但醫學影像分割任務中普遍面臨類別嚴重不平衡與小目標病灶之挑戰。在冠狀動脈 OCT 影像中，鈣化斑塊於單次 Pullback 中常僅出現於少量幀，且其在單張影像中所占像素比例亦相當有限，因而形成顯著的前景稀少問題並提高漏檢風險。為提升嚴重類別不平衡條件下之鈣化分割表現，本研究在 3D U-Net 基礎上引入全監督體素層級對比式學習（Voxel-level Contrastive Learning），藉由標注導向之表徵，強化鈣化與背景之可分離性，並進一步結合記憶庫（Memory Bank）機制以利用跨批次與跨樣本之同類關聯。此設計旨在改善鈣化分割之準確性與細緻度，提升不規則與形狀複雜病灶之辨識能力，期望本研究能夠為冠狀動脈疾病之影像診斷、評估與後續介入治療提供更可靠之技術支持。



第三章 研究材料與方法

3.1 研究材料

本研究使用之冠狀動脈光學同調斷層掃描 (OCT) 影像資料由臺北榮民總醫院 (Taipei Veterans General Hospital) 提供，使用 Abott OPTIS 成像系統取得影像。

在資料組成上，本研究之已標注資料從含影像中可辨識鈣化斑塊之病患資料中，隨機選取 137 名病患共 191 段冠狀動脈之 OCT 影像序列；其中包含鈣化區段共 436 段。各段 OCT 影像序列皆同時有含鈣化斑塊與不含鈣化斑塊之影像，影像中鈣化區域的標注根據兩位醫師的共識結果，圖 3 中分別為未標注之冠狀動脈 OCT 影像與已標注影像之示意圖。




圖 3 鈣化斑塊之影像標注：(a) 未標註鈣化斑塊區域之影像；(b) 已標註鈣化斑塊區域之影像

在影像的數量及解析度方面，本研究共使用已標注之冠狀動脈 OCT 影像共 34948 幀，其中含鈣化斑塊之影像共 26644 幀，無鈣化斑塊影像數量為 8304 幀，所有影像的原始輸出解析度均為 704×704 像素。此外，於先期探索之對比實驗中，



共納入 106 位病患的 110 段血管，未標注之 IVOCT 影像共計 24041 幀，未刻意挑選含有影像中可辨識鈣化之病例及影像。

本研究之影像資料處理流程，先以 MATLAB 進行影像前處理；模型建置與訓練則以 Python 搭配 TensorFlow 與 Keras 框架建立深度學習模型。為確保訓練流程之可重現性與運算效能，並在 Nvidia GeForce RTX3090 顯示卡以及 Intel Core i9-9900X 中央處理器之工作站上執行模型訓練。

3.2 驗證方法與資料分配

本研究之已標注影像共納入 137 位受試者之資料，其中 125 位作為訓練資料集，6 位作為驗證資料集，另 6 位作為測試資料集。模型以訓練資料進行參數學習，並於各訓練 Epoch 以驗證資料集之損失值作為模型選擇之準則，取驗證損失最低之權重組合作為最佳模型。

表 1 資料分配表

	病患數量	血管數量	影像幀數
訓練資料集	125	176	31967
驗證資料集	6	6	1499
測試資料集	6	9	1482

3.3 影像前處理

為建立一致之模型輸入表徵並降低非目標訊號與偽影對後續學習之影響，本研究依 OCT 影像之特性對原始影像數據進行了一系列前處理，其步驟依序包括：

- (1) 管腔 (Lumen) 面積分割；
- (2) 極坐標與灰階影像轉換；
- (3) 影像增強；
- (4) 資料擴增
- (5) A-line 徑向像素平移對齊
- (6) 導絲陰影移除；
- (7) 沿 Pullback



方向進行感興趣體積 (Volume of Interest, VOI) 堆疊，以形成後續模型輸入之體積資料，流程如圖 4 所示。

上述影像前處理皆於 MATLAB R2023b (MathWorks, Natick, MA, USA) 環境下實作。

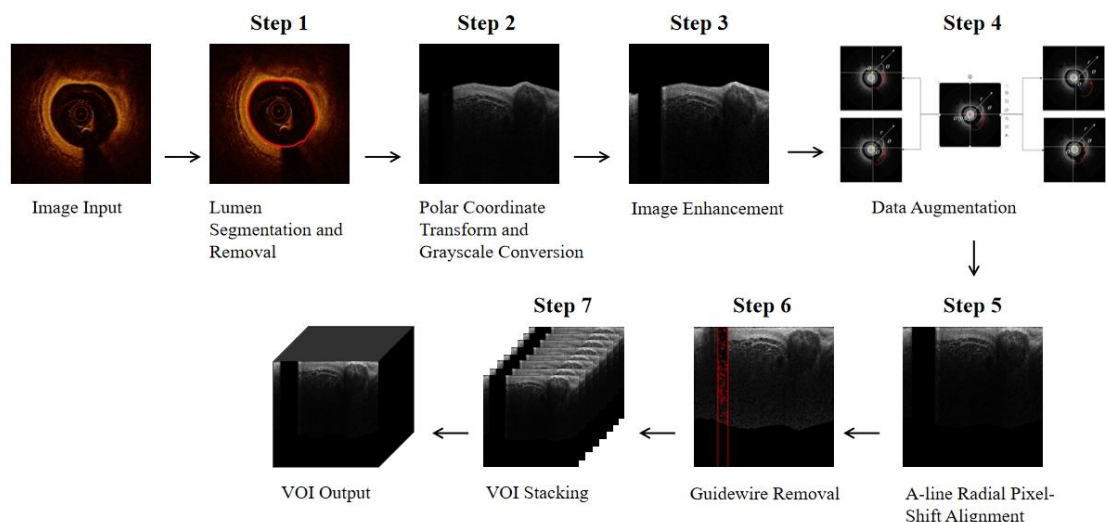


圖 4 資料前處理流程圖

3.3.1 管腔面積分割與移除

鑒於冠狀動脈 OCT 影像中病灶 (含鈣化斑塊) 主要位於管腔邊界之外之血管壁區域，本研究於前處理階段先進行管腔面積分割，以取得管腔遮罩作為幾何參考並界定後續分析之有效範圍。另一方面，管腔內區域及導管相關結構 (如血液及沖洗液所形成之低訊號區與導管中心區域) 以及導絲陰影等偽影，可能引入與目標病灶無關之影像訊號並干擾模型學習。故本研究於後續流程中以管腔遮罩遮蔽管腔內區域，使分割模型聚焦於血管壁範圍，並降低非目標訊號對模型訓練與分割結果之影響。

基於上述目的，本研究首先建立管腔分割模型以得到管腔遮罩，於笛卡兒座標（直角坐標，Cartesian Coordinate）影像上採用 2D U-Net 進行管腔分割（模型結構如圖 5）[39]，管腔分割模型之參數採用本實驗室先前研究所訓練之權重[61]。所得管腔遮罩除用於遮蔽管腔內區域外，亦為後續步驟影像強度增強及導絲陰影移除之計算依據，如圖 6 所示。




圖 5 管腔分割（Lumen Segmentation）之 2D U-Net 模型結構圖（節錄自[39]）




圖 6 管腔面積分割圖：(a) OCT 之原始影像；(b) U-Net 之管腔分割結果；(c) 移除管腔雜訊之影像

3.3.2 極座標與灰階轉換

為提升座標表徵的一致性，並利於後續前處理及模型學習，本研究將每張冠狀動脈 OCT 橫截面影像由笛卡兒座標系（直角座標系，Cartesian Coordinate System）

重取樣至極座標 (r, θ) 表示。在冠狀動脈 OCT 影像中，管腔與血管壁結構多以導管位置為近似中心呈放射狀分布，具有明顯的環狀幾何特性。轉換至極座標後， r 軸對應徑向深度， θ 軸對應周向角度，原本繞中心的周向變化可轉換為 θ 軸方向的位移，因此能使以平移等變性之卷積運算得以以共享權重一致建模不同周向位置的紋理差異。故因此本後續模型訓練採用極座標影像作為輸入。

在具體實作上，本文以影像中心 (x_c, y_c) 作為極座標原點，以六點鐘方向為 0 度角，逆時針 360° 環繞整張影像，自管腔內部至血管壁外部進行等距離取樣，其中最大徑向範圍設定為原影像邊長之 $1/2$ ，以涵蓋影像中心至邊界的徑向範圍。再對每一取樣點 (r, θ) ，依座標對應關係(公式(1))反算其於原始影像中的位置 (x, y) ，並自原笛卡兒座標影像擷取對應之灰階強度值。由於 (x, y) 通常落於非整數像素位置，本文採雙綫性插值估計其強度，最終輸出固定尺寸為 256×256 之極座標影像，如圖 7 所示。此外，由於沿徑向之強度增強與沿周向之偽影處理在極座標表示下可自然對應至 r 與 θ 方向之運算，較易操作。綜上，本研究後續前處理與訓練統一採用極座標表徵。

$$I_{\text{polar}}(r, \theta) = I(x_c + r\cos\theta, y_c + r\sin\theta), \quad (1)$$




圖 7 極座標轉換前後之影像及標註掩膜: (a) 極座標轉換前之影像及標註掩膜;
(b) 極座標轉換後之影像及標註掩膜

另外，OCT 影像本質上反映的是組織回散射（或背向反射）光之強度分布，臨床與研究中常以灰階（或固定色階）方式呈現其訊號強弱[62]。所以本研究由公



式(2)，其中， Y 為灰階強度值， R 、 G 、 B 為 RGB 三通道像素值，將原始 RGB 影像轉換為單通道灰階影像，以降低色階選擇對數值表徵之影響；同時，相較於三通道之 RGB 影像，單通道輸入可降低資料維度，並在相同解析度下減少前端卷積運算量與 GPU 記憶體占用，有助於後續模型訓練與推論效率。

$$Y = 0.299 \times R + 0.587 \times G + 0.114 \times B \quad (2)$$

3.3.3 影像增強

在血管內光學同調斷層掃描 (IVOCT) 中，量測到的回散射訊號會隨深度增加而衰減，主要源於組織吸收與散射[62]。

因而影像在距離管腔較遠的深層位置常呈現較低訊號與對比，影像亮度較暗，像素值較低，可能不利於後續自動化分析充分利用深層資訊。

基於上述特性，本研究於前處理階段對每張極座標灰階影像切片進行深度相關影像增強，以強化深層區域訊號，提升可辨識性，同時盡量維持淺層對比資訊。

首先，使用管腔遮罩 $M(r, \theta)$ 將 Lumen 區域之像素強度設為 0，並以 Lumen Mask 定義每一角 (θ) 向掃描綫的參考起始深度 $s(\theta)$ ，即 Lumen 邊界之外的第一個組織像素位置。接著，對 Lumen 邊界之後的像素 ($r \geq s(\theta)$) 依其相對深度 $d = r - s(\theta) + 1$ 施加隨深度遞增的增益權重 $g(d)$ ，以對深層給予較大增強幅度；本研究公式 (3) 進行影像增強

$$I'(r, \theta) = I(r, \theta) \cdot g(d), \quad g(d) = \frac{256}{\max(H-d, 1)} \quad (3)$$

其中 H 為徑向深度取樣點數， δ 用以避免分母為 0，考量本研究輸入與輸出影像皆為 8 位元灰階表示，其像素強度動態範圍介於 0-255，故固定增益函數中之比例常數為 256 用以調整整體增強幅度，使深層訊號之強度提升能在既有灰階



範圍內有效呈現；同時，輸出維持原始資料型別並在必要時進行截斷，以避免超出可表示範圍所造成的飽和。

經公式 (3) 增強前後之影響對比如圖 8 所示。由此可見，該方法將不同深度的像素值根據不同權重進行影像增強，在加強深層訊號的同時，亦降低對淺層對比資訊的干擾，進而可望提升模型更有效地學習距離管腔較遠的深層位置之特徵。




圖 8 增強前後之影像: (a) 增強前之影像; (b) 增強後之影像

3.3.4 資料擴增

臨床 IVOCT 影像可能因導管偏心 (Decentration)、不同中心和系統在前處理時把影像對齊至中心方式之差異，使得極座標轉換所採用的原點存在一定程度的不確定性。本研究提出擾動極座標轉換之中心點作為資料擴增策略。具體做法為：以原 OCT 影像中心 (x, y) 作為基準圓心，隨機產生 4 組位移向量 $(\Delta x, \Delta y)$ ，以位移後坐標 $(x + \Delta x, y + \Delta y)$ 作為新的極坐標轉換中心點，於同一案例額外生成 4 組中心不同的極坐標擴增影像。位移幅度採混合尺度抽樣：以較高機率 (85%) 取小幅偏移，最大半徑 $r_{\max} \in [5, 15]$ 像素，以模擬常見情境；以較低機率 (15%) 引入較大位移，最大半徑 $r_{\max} \in [20, 30]$ 像素，以涵蓋較明顯之偏心情境，增進模型之魯棒性 (Robustness)。通過此擴增策略，可降低模型對固定圓心極座標轉換的



依賴，並增加訓練資料多樣性，以提升模型在跨病例與不同掃描條件下之泛化能力與穩健性。

圖 9 為中心擾動式極座標轉換之資料擴增示意圖。本研究以原直角坐標影像中心作為基準圓心（圖中紅點），並於其外圍之同心圓環區域內隨機取樣新的極座標轉換中心。基準圓心周圍深色小半徑區為高機率小幅位移，淺色大半徑區為低機率較大位移。圖中為隨機取值的一組資料擴增示意圖， r 和 θ 分別對應徑向方向周向角度。

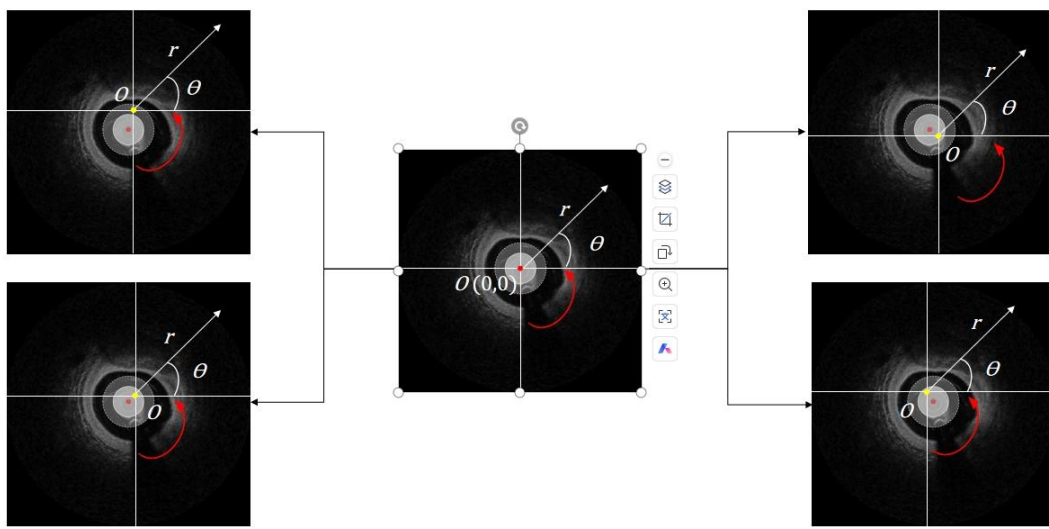


圖 9 資料擴增之示意圖

3.3.5 A-line 徑向像素平移對齊

在血管內光學同調斷層影像 (IVOCT) 中，單一深度方向的反射訊號剖面稱為 A-line (A-scan)，沿周向掃描取得連續 A-lines 後可組成血管橫截面影像 (B-scan) [63]。

IVOCT 影像在臨床取得過程中可能出現腔面邊界的錯位或不連續；例如文獻指出，單一橫截面形成期間若發生血管或成像導絲的快速相對移動，可能導致腔面邊界出現單點錯位 (Sew-up Artifact)。在本研究的 (r, θ) 表示中， r 為沿 A-line



的徑向取樣索引；因此當腔面在不同角度、影像幀 (Frame) 的徑向位置不一致時，血管壁組織在 r 向的表觀位置亦會隨之改變，形成後續深度學習分割需適應的額外變異。

為降低不同角度 A-line 的徑向起始位置差異，本研究以參考界面 (例如腔面邊界) 為基準，對每條 A-line 沿徑向 r 方向進行像素平移，使所有血管壁 A-lines 在徑向方向具有相同的起始像素位置；此步驟為深度學習創建了較小的感興趣區域 (Region of Interest, ROI)，同時實現組織對齊，從而使不同鈣化病竈在網路輸入中呈現更高的相似度。因此本研究將其納入前處理流程，以支援後續之鈣化斑塊分割，如圖 10 所示。




圖 10 A-line 徑向平移前後之影像：(a) A-line 徑向平移前之影像；
(b) A-line 徑向平移後之影像

3.3.6 導絲陰影移除

為降低導絲及其陰影於血管內光學同調斷層影像中所造成的遮蔽效應，並避免其干擾後續模型訓練與定量分析，本研究於模型訓練前進行導絲陰影移除。該方法以完成 A-line 徑向像素平移對齊後之 (r, θ) 極座標影像為輸入。考量 IVOCT 影像之穿透深度受限，深層訊號易因衰減而降低，於影像上呈現低像素值；且 A-line 徑向平移後，導絲陰影於靠近腔面之淺層區域呈現相對穩定之帶狀暗區，故本



研究採於影像上方、亦即靠近管腔內側的固定深度範圍內進行導絲帶狀陰影偵測，以降低深層低訊噪區域對定位之影響。

具體做法為：先於徑向固定深度範圍建立角向強度剖面 $I(\theta)$ ，並利用一階差分近似角 (θ) 向變化量作為邊界線索（角向採環狀索引），例如：

$$\Delta I(\theta) = I(\theta + 1) - I(\theta) \quad (4)$$

由於導絲遮蔽帶兩側常伴隨明顯強度突變，本研究於一組候選寬度內搜尋同時滿足帶內較暗、帶外較亮且邊界變化量較大的角向帶狀區段，以定位導絲陰影之角度範圍。

此外，為降低雜訊或局部高衰減結構造成之誤判，本研究引入列（Row）級相對暗度一致性之門控機制：當多數列於相近角度位置均支持同一暗帶區段時，方接受該次定位結果，以避免僅由局部像素值驟降所導致之錯誤偵測。定位完成後，進一步沿 Pullback 之 z 向對角度位置進行平滑處理，並補齊少量缺口，以減少單張漏偵測造成的切片間不連續。

最後，所得到之移除遮罩沿整幅深度一致套用，使深部影像亦同步排除陰影區段之影響；並以相同遮罩同步處理原始影像與對應之人工標註遮罩（Mask），以維持訓練資料之影像的標注一致性。另設定單張切片之最大移除比例上限 $\leq 10\%$ ，以降低過度移除造成的額外資訊損失，如圖 11 所示。




圖 11 導絲陰影移除示意圖：(a) 導絲陰影移除前之影像；(b) 導絲陰影移除結果；(c) 導絲陰影移除後之影像



3.3.7 VOI 堆疊

冠狀動脈本質上屬於空間三維結構，為了描繪鈣化斑塊之邊界，臨床實踐中醫師解讀、分析冠狀動脈 OCT 圖像時常需並行參照多張相鄰切片，而非僅逐張序列式判讀。綜合利用全域三維上下文信息與局部細節特徵，對提升自動化鈣化斑塊分析至關重要。

僅基於一維 (A-line) 或二維資訊 (單張 B-scan 影像) 之方法，多以單張切片形式為輸入進行獨立預測，未能考量斑塊在空間上的分布特徵與跨切片之連續性。在此情況下，冠狀動脈光學同調斷層掃描 (OCT) 所提供之三維結構資訊難以被充分利用，進而可能使鈣化斑塊邊界於回拉 (Pullback) 方向出現不連續或一致性不足。因此採用跨幀 (Frame) 之三維或 2.5 維方法是較合適的策略。

本研究將冠狀動脈 OCT 影像沿 Pullback 方向之連續切片 (Slice) 堆疊形成三維的感興趣體積 (Volume of Interest, VOI)，每一個 VOI 代表冠狀動脈沿 Pullback 方向的一短段血管區域。具體而言，每個 VOI 由 Pullback 方向連續 $D = 8$ 張極坐標灰階影像構成，可表示為 $D \times H \times W = 8 \times 256 \times 256$ 的三維張量，其中 H 對應徑向深度， W 表示周向角度 (θ)，以引入跨幀 (Frame) 之上下文資訊。並以移動步長 (Stride) = 3 於序列中滑動取樣，以產生相鄰之 VOI，如圖 12 所示。




圖 12 VOI 堆疊之示意圖



3.4 3D U-Net 之基礎分割模型

3.4.1 損失函數

本研究以 3D U-Net 作為基礎分割模型，以 Dice Loss 作為分割訓練之損失函數，以直接促進模型預測之鈣化斑塊區域與人工標注遮罩在空間上的重疊一致性。Dice Loss 之核心為 Dice 相似係數 (Dice Similarity Coefficient, DSC)，其最初被提出作為樣本相似度的量化指標；而在影像分割任務中，DSC 常被用作衡量預測分割與標註區域之空間重疊程度。其取值介於 0 與 1；當兩者重疊越充分時，DSC 越接近 1，若幾乎無重疊則趨近 0 [64]。

DSC 可藉由比較模型預測機率圖與人工標注遮罩在像素或體素層級的交集與聯集，如公式 (5) 和 (6) 所示，量化兩者的一致性，並以最小化 Dice Loss 作為模型訓練之最佳化目標，即等價於最大化預測結果與真實標籤之間的重疊程度。

$$DSC = \frac{2|y_{\text{pred}} \cap y_{\text{groundtruth}}|}{|y_{\text{pred}}| + |y_{\text{groundtruth}}|} \quad (5)$$

$$\mathcal{L}_{Dice} = 1 - DSC \quad (6)$$

由於冠狀動脈 OCT 影像中 CAC 像素比例相對較低，資料分佈常呈現類別不平衡，Dice Loss 對小目標區域較具敏感度，能降低類別不平衡對學習過程的不利影響；且能在不需顯式設定類別權重的情況下，降低背景主導梯度的風險，進而提升對鈣化區域之學習效率與分割穩定性。訓練過程中，本研究以 Soft Dice 使用連續機率輸出計算損失，以確保損失函數可微並利於反向傳播；同時於分母加入平滑項 ϵ 以避免在正類極少或空標注情境下出現數值不穩定。如公式 (7) 所示

$$DSC(\mathbf{p}, \mathbf{y}) = \frac{2 \sum_i p_i y_i + \epsilon}{\sum_i p_i + \sum_i y_i + \epsilon}, \quad \mathcal{L}_{Dice} = 1 - DSC, \quad (7)$$

其中 $\mathbf{p} \in [0,1]$ 為模型輸出機率圖， $\mathbf{y} \in \{0,1\}$ 為標註




3.4.2 非等向之 3D U-Net 網路架構

冠狀動脈血管內光學同調斷層掃描 (OCT) 影像採螺旋掃描方式取得，平面內解析度較高 (軸向：15-25 μm ，側向：20-40 μm)，而沿 Pullback 方向之跨幀解析度通常在 100-200 μm 範圍內，原始輸入 OCT 影像的平面內解析度約為跨幀解析度的 10 倍。基於上述各向異性取樣特性，本研究之網路架構採非等向的 3D U-Net 設計，以兼顧平面內細節保留、跨切片連續資訊利用與 GPU 記憶體限制。

編碼器 (Encoder) 的部分共包含五層捲積層 (Convolution Layers)，在第一層中使用 2D 捲積層，以保留平面內細節，降低平面內細節在網路初段即被過度平滑的風險，第二到五層中則使用 3D Convolution Kernel 來提取平面內與相鄰切片間的特徵，這一方式相較於二維卷積神經網路能更好地運用空間資訊，同時相較於完整的三維卷積神經網路，則有助於模型在較低計算量與 GPU 記憶體需求下獲取必要的跨幀資訊。各層卷積核之平面尺寸固定為 3×3 ，並依層級需求配置對應的深度尺寸，而通道數隨網路深度逐層倍增，激發函數 (Activation Function) 都使用 ReLU。此外，在每一層的第一次 Convolution 中都加入原始影像的資訊，用以避免在多次卷積運算中所導致的特徵損失。

為配合冠狀動脈 OCT 影像平面內解析度較高，沿 Pullback 方向解析度較低之特性。本研究於多解析度層級路徑中之下採樣與上採樣均使用 $\text{stride}=(1,2,2)$ 的解析度變換，僅在 H 、 W 方向調整特徵圖解析度，並保留 D (Pullback) 方向之深度維度。此配置可在控制計算量的同時，保留 Pullback 方向之深度維度，使跨切片連續資訊於各解析度層級仍具可用性，並維持網路表徵之非等向特性。

為兼顧單一切片內之細節與跨切片之連續性。本研究設計兩個互補分支於網路瓶頸端，分別對應平面向多解析度層級資訊與深度向鄰近關聯。其一為平面空洞



空間卷積池化金字塔 (Atrous Spatial Pyramid Pooling, ASPP) , ASPP 分支採用 $1 \times 3 \times 3$ 之空洞卷積 (Dilated Convolution) , 設定擴張率 (Dilation Rate) 為 $1/2/4$ 的並行擴張卷積分支, 以在同一層級特徵圖上, 在不額外降低解析度之前提下同時擷取不同感受野的上下文線索; 其二僅沿深度方向之空洞捲積, 本研究設定捲積核大小為 $3 \times 1 \times 1$, 擴張率 (Dilation Rate) 為 2 , 聚焦於深度方向的鄰近切片關聯。此分支旨在利用 IVOCT Pullback 方向的形態延續性, 與本研究的 3D U-Net 基礎模型結構與非等向體積輸入特性相呼應。

3.4.3 訓練細節

為提升訓練穩定性並兼顧記憶體限制, 本文採用梯度累積以形成較大的有效批次大小 (Batch Size) 。本文在實際批次大小為 16 的情況下, 透過累積步數使有效 batch size 達 32 。並在參數更新前對梯度進行範數裁剪 (本研究設定上限為 1.0) , 以降低梯度過大導致訓練發散之風險。

訓練過程中, 本研究採用自適應矩估計 (Adam Optimizer) 作為最佳化方法, 其結合了動量 (Momentum) 以及均方根傳播 (RMSProp) 兩種傳統最佳化方法的優點, 因此具有良好的收斂性和穩定性, 並採用其一階與二階動量估計機制 (β_1 , β_2) 以提升梯度更新之穩定性。

為提升訓練後期之收斂穩定性, 本研究採用 ReduceLROnPlateau 作為學習率調度器, 並以驗證集之 Soft Dice Loss 作為調度器監控指標, 以其改善情形判定是否需要降低學習率以促進後續收斂。訓練最佳化與學習率調度之超參數設定如表 2 所示。此外, 為降低短期波動造成之頻繁降速, 本研究另設定降學習率後啟用 2 個 Epoch 的冷卻期。



表 2 訓練最佳化與學習率調度之超參數設定

項目	設定值
編碼端初始學習率 (Encoder LR)	1×10^{-4}
解碼端初始學習率 (Decoder LR)	2×10^{-4}
編碼端最小學習率 (Encoder min LR)	1×10^{-5}
解碼端最小學習率 (Decoder min LR)	2×10^{-5}
改善門檻 (Threshold)	1×10^{-4}
學習率下降倍率 (Factor)	0.7
調度器啟用時機	第 16 個 Epoch 起
調降對象	編碼器+解碼器

訓練後期常出現驗證指標改善趨緩。當驗證集之 Soft Dice Loss 在一段時間內不再改善時，較大的學習率可能使參數更新在次佳解附近反覆震蕩，進而限制後續下降空間。基於此現象，學習率調度器先負責在指標停滯時降低學習率，使模型進行更細緻的參數更新，並嘗試恢復收斂。

若調度器已執行降學習率後，驗證指標仍長時間維持停滯，訓練流程即可能進入更新成本增加但收益有限的階段。此時，提前停止機制再負責判定是否需要停止訓練，以避免不必要的訓練延長。整體而言，訓練流程兼顧收斂效率與終止時機的合理性。

驗證集 Soft Dice Loss 同時作為學習率調整與本研究之早停機制 (Early Stopping) 的監控指標。此處將有效改善定義為驗證集 Soft Dice Loss 相較於歷史最佳值至少下降 1×10^{-4} ，即未達到此有效改善時，仍將未改善計數累加 1。本研究之 Epoch 上限設定為 100 個 Epoch，但在實際應用中，很少真正達到 Epoch 之上



限。早停耐心值設置為 10，即當驗證集 Soft Dice Loss 連續 10 個 Epoch 均未達有效改善量時，則模型進入停滯狀態。

停滯狀態不必然代表訓練的立即終止，為避免模型在仍可透過降低學習率改善的階段過早終止，本研究之早停機制條件額外要求 ReduceLROnPlateau 已觸發學習率下調至少 2 次。即本文僅在學習率下調次數至少 2 次，且驗證集之 Soft Dice Loss 連續未改善至少 10 個 Epoch，兩條件同時成立時，才會觸發早停並終止訓練。

同時，本研究在各解析度層級跳接之前加入注意力門控 (Attention Gate) 機制，用於抑制與目標無關的特徵回傳，並保留較具判別力的訊息。此注意力門控機制可與 U-Net 架構直接整合，如圖 13 所示。




圖 13 Attention Gate 運算過程示意圖

最終模型以 $1 \times 1 \times 1$ 卷積層 (Convolution Layer) 為分割頭，經過 Sigmoid 函數激發，輸出特徵值為 0 至 1 的分割機率圖，以此作為模型之輸出結果。

3.5 監督式體素層級對比學習

3.5.1 體素層級監督式對比學習架構

本研究以 3.3 中所述之 3D U-Net 模型為基礎，引入監督式體素層級的對比學習 (Voxel-level Supervised Contrastive Learning)。在具體流程上，模型同時建構分割輸出與對比學習所需之表徵，於分割網路之解碼器中額外加入對比式學習分支，

以直接在特徵空間強化鈣化與背景的可區分性。在分割支路上，本研究以解碼器輸出之特徵圖為基礎，先由分割頭以 $1 \times 1 \times 1$ 卷積層輸出分割機率圖；就對比學習支路而言，體素表徵由解碼器末端前一層之特徵圖 (Feature Map) 取得，並接續 $1 \times 1 \times 1$ 投影頭 (Projection Head) 映射至低維嵌入空間 (Embedding Space)，獲得嵌入向量，再對其施以 L2 正規化，以作為對比學習之表徵輸入，模型整體結構如圖 14 所示。




圖 14 體素層級監督式對比學習+ 3D U-Net 模型架構圖

在對比式學習解析度的選擇上，本研究之體素層級對比式學習的樣本構建與相似度計算置於解碼器末端前一層之 $1/2$ 空間解析度特徵圖上進行，即解析度為 128×128 。此解析度設定用以兼顧訓練效率與表徵穩定性，在較低解析度下，除能夠節省 GPU 記憶體資源之外，體素層級的對比式學習對邊界擾動與局部雜訊較為敏感也是考量之一。



正負樣本之定義為對比式學習的關鍵因素，具體而言，本研究將鈣化體素的嵌入表徵配對為正樣本對，並將非鈣化區域之體素嵌入則視為負樣本來源，以促進模型在學習分割的同時，也能強化鈣化與非鈣化區域之判別邊界，提升鈣化類別之表徵一致性。

為擴充樣本多樣性，本研究另以同一 VOI 為來源，生成增強視角 view2，並自原始視角 view1 與增強視角共同抽取體素嵌入以構成對比樣本，從而增加樣本對的多樣性並在訓練中引入跨視角一致性。

由於對比式學習需由解碼器特徵圖映射嵌入向量，並以嵌入距離計算相似度與對比損失，若訓練早期特徵表示仍高度不穩定，可能較難穩定捕捉鈣化與非鈣化之特徵差異，進而干擾分割表徵的收斂方向。基於上述考量，系統自第 6 個 Epoch 起啟用對比式學習模組，並與分割目標共同最佳化，以在較穩定的特徵基礎上引入體素級對比。

3.5.2 類別導向之佇列式記憶庫

由於體素層級存在顯著類別不平衡，本研究引入記憶庫（Memory Bank）機制，其概念與 MoCo 以佇列（Queue）保存特徵之作法相近。不同之處在於，本研究之記憶庫以類別為單位建立，分別為各類別存儲一個固定容量之佇列，將同類體素之嵌入向量存入對應佇列，以利後續對比式學習取樣。

在每一訓練步驟中，模型僅將少量新產生之體素嵌入向量寫入佇列，並自各佇列抽樣特徵，加入當前小批次（Mini-batch）之對比候選之集合。此設計可使對比樣本來源不局限於單一小批次，而能透過佇列逐步累積跨批次之已觀測特徵分布。由此，系統可降低小批次內正負樣本數量不足所造成之取樣偏差，並使正樣本與負樣本候選集合能隨訓練歷程持續更新。



本研究設定正類樣本佇列容量為 4096，負類樣本佇列容量為 8192。兩者皆採固定容量之循環佇列 (Ring Buffer)。即當佇列達容量上限時，以新特徵覆蓋最早納入之特徵，以避免特徵無限制增加造成記憶體負擔，並使記憶庫中之樣本集合較貼近當前模型狀態。

此外，冠狀動脈 OCT 影像經本文第 3.3 節所述方法進行前處理後，輸入模型之 VOI 因管腔與導絲移除而會包含像素值為 0 之無效區域。基於此特性，本研究以非零像素定義有效像素遮罩，並僅於有效區域取得體素嵌入向量以建立對比樣本。以避免無效區域對對比式學習之干擾。

3.5.3 雙視角輸入設計

本研究之對比式學習訓練採用雙視角輸入設計，以同一段冠狀動脈極座標 OCT 影像為基礎，互為正樣本與負樣本的 Voxel 取自原始 VOI view1 與經過增強的增強視角 view2，以提升表徵對導管旋轉、不同成像條件與顯示設定之穩健性。

本研究增強視角之生成採固定流程，依序包含：(1) 角向平移 (2) 翻轉 (3) 亮度、對比與 Gamma 調整。

(1) 角向循環平移

在本研究中，角向循環位移採用固定執行。於極座標 OCT 影像中，寬度維度 W 直接對應周向角度 θ ，極坐標影像可視為對 $[0, 2\pi)$ 的等間距離散取樣；第 j 個像素列對應某一固定角度 θ_j 。角向維度可對應血管壁的環狀結構，而導管於血管腔內的旋轉，常改變極坐標影像之角度原點，但通常不改變血管壁結構與鈣化斑塊之間的相對幾何關係。基於此特性，本研究在 view2 的生成流程中納入角向循環位移，使兩視角共享相同解剖內容，同時在角向起點上形成差異

令 $v \in \mathbb{R}^{D \times H \times W}$ 表示一個 VOI (深度 D ，徑向 H ，角向 W)，本研究對每



個 VOI 抽樣單位位移量 d ，並以均勻分布自集合 $\{2, 4, \dots, W - 2\}$ 取樣，使 view2 與 view1 之間必定存在非零角向差異，同時確保位移量為偶數。程式實作亦採用相同策略對標註同步施行位移。

其中 $d > 0$ 表示沿 θ 軸向向右平移 d 個像素列。平移運算 $R_d(\cdot)$ 定義為沿周向維度施行循環平移，其離散形式可表示為：

$$[R_d(v)]_{D,H,j} = v_{D,H,(j-d) \bmod W}, j = 2, \dots, W - 2. \quad (8)$$

$$\tilde{v}^{(k)} = \text{roll}(v, d_k, \text{axis} = \theta). \quad (9)$$

換言之，畫面右側被平移推出的 d 個像素列，將以周期邊界條件自畫面左側補入；整體表現為環狀平移，不涉及裁剪及填補。因此，原本在 θ 軸上相接的結構，在平移後於極座標平面中仍保持相接；若將其轉回直角座標系，此操作等價於以導管中心為旋轉中心對整個橫截面施加一剛體旋轉，不涉及任何插值扭曲或局部幾何變形，不會破壞血管影像本身之連續性，圖 15 為角向位移前後之示意圖。

由於後續對比式學習並非直接在原始 256×256 之解析度上配對，而是先將採用 stride 為 2 的池化下採樣，嵌入向量自解碼器末端前一層之 $1/2$ 空間解析度特徵圖上取得，為避免對比式損失計算產生誤差，角向循環位移量 d 取樣為偶數。




圖 15 影像角向位移前後示意圖：(a) 原 IVOCT 極坐標影像；(b) 經角向平移之 IVOCT 極坐標影像



(2) 角向翻轉

為降低模型對角向索引方向之敏感性，本研究同時納入角向水平翻轉作為另一種幾何擾動。對輸入之 VOI 施加沿 θ 軸的水平翻轉：此處的翻轉僅改變角向方向，不改變深度方向的相對順序，如圖 16 所示。為避免模型尚未建立基本表徵時承受過強擾動，本研究於前五個 Epoch 關閉翻轉，並於第 6-20 個 Epoch 使用 0.2 之翻轉機率，其後再調整為 0.15。




圖 16 影像翻轉前後示意圖：(a) 原 IVOCT 極坐標影像；(b) 翻轉後 IVOCT 極坐標影像

(3) 光度調整增強

光度調整包含對比度縮放、亮度平移與 Gamma 調整三類操作，其參數範圍分別設定為 0.95 至 1.05，-0.02 至 0.02，以及 0.95 至 1.08。光度增強同樣採分段式機率控制，僅於第 6-20 個 Epoch 以 0.2 機率啟用，其餘 Epoch 則不執行，其以避免在模型尚未建立基本表徵時引入過強的外觀變動。

經本文第 3.3 節所述之前處理後，輸入模型之 VOI 因經管腔與導絲移除處理，會包含像素值為 0 之無效區域，故本研究以非零值定義有效像素遮罩，並僅在有效區域內施行光度擾動，以避免無效區域對外觀增強造成不必要之干擾。



需要強調的是，本研究以 VOI 作為增強之基本單位，即對一個 VOI 之所有切片進行統一的依次角向位移、翻轉與光度處理，而非對不同切片之間施加不同的變換，以降低相鄰影像切片間異質性，符合 3D U-Net 基礎模型架構。

3.5.4 負樣本之選取

由於冠狀動脈 OCT 影像中鈣化斑塊分割任務在體素層級存在顯著類別不平衡，為使體素層級對比式學習能提供有效的判別訊號，本研究特別關注負樣本構成與困難樣本之比例。由於冠狀動脈 OCT 影像分割任務中背景體素占比極高，若負樣本主要由大量且容易區分之背景組成，對比損失在訓練過程中可能較難聚焦於背景與鈣化高度相似的情境，可能會使訓練過程過度簡化，削弱對比式學習效果。基於此，為抑制嵌入空間出現過度離散（Over-dispersion），同時避免正樣本被過多的負樣本淹沒，本研究以固定數量之負樣本進行對比式學習之訓練，並採用困難負樣本挖掘（Hard Negative Mining）與隨機抽樣的混合策略，以同時兼顧困難負樣本強化與背景樣本多樣性。負樣本選取之整體流程如圖 17 所示。

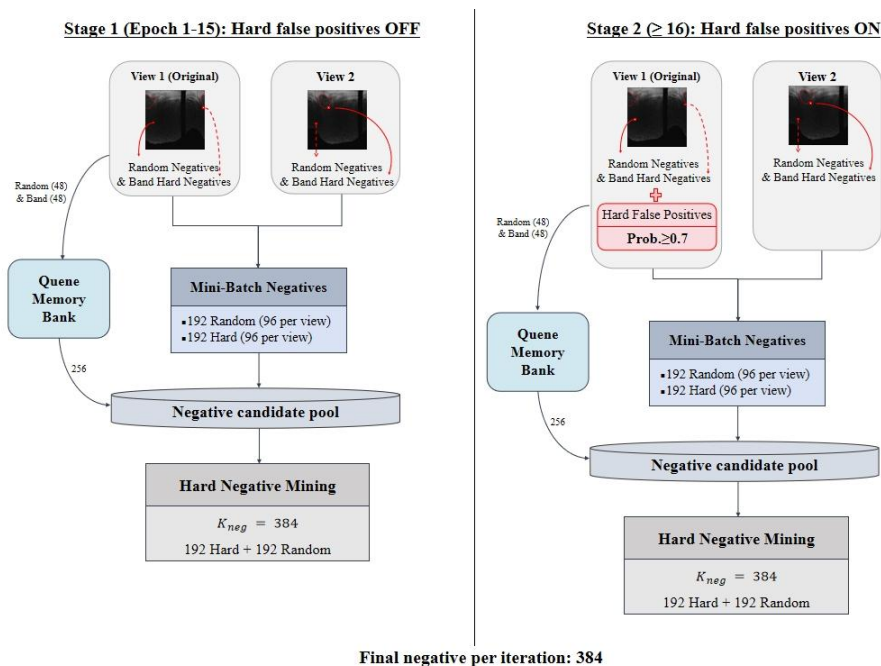



圖 17 負樣本選取之流程圖



在資料抽樣方面，本研究每個 Mini-batch 選取 50% 一定含鈣化標註的 VOI，其餘 50% 則隨機抽取。故每一批次之含鈣化樣本的 VOI 比例至少可維持半數。

此外，本研究採用之體素級對比式學習的另一項關鍵在於困難樣本之定義與選取策略。在困難負樣本來源上，本研究採用兩類候選集合。第一類為邊界帶狀背景 (Band Hard Negatives)，其由正類標註在 $1/2$ 解析度特徵網格上向外擴張半徑 2 像素所形成，且僅在二維平面運算，以避免跨切片混合。

第二類為困難偽陽性 (Hard False Positives)，即特徵接近目標的背景部分，作為困難負樣本來源之一。本研究自第 16 個 Epoch 起啓用此機制，使用同一分割網路對原始 VOI 進行分割，於 $1/2$ 解析度特徵網格上進行幾率判定。對於除 0 像素外屬於背景之體素，若其被模型預測為目標之機率不低於 0.7，則納入困難假陽性之集合。上述之邊界帶狀背景與困難假陽性將共同構成困難負樣本池，用以強化模型在背景與鈣化高度相似情境下之特徵分辨能力。

在嵌入空間的困難負樣本挖掘階段，本研究同時使用當前 Mini-batch 與跨批次記憶佇列所提供之背景嵌入向量，以提升候選負樣本之多樣性。具體而言，每次迭代先搜集固定數量之背景嵌入向量作為負樣本候選集合，當候選負樣本數量超過固定值 384 時，本研究以餘弦相似度 (Cosine Similarity) 衡量各錨點 (Anchor) 與候選負樣本之相似程度，並對每一錨點優先選取相似度最高之 32 個嵌入向量作為困難候選。最終每次迭代固定使用 384 個負樣本，其中 50% 來自上述相似度導向之困難負樣本集合，其餘 50% 由剩餘候選中隨機抽樣補足，以兼顧聚焦於最易混淆的負樣本的同時維持負樣本多樣性。



3.5.5 軟正樣本加權體素層級監督式對比損失

3.5.5.1 嵌入表示、相似度與軟正樣本權重

令 \mathbf{v}_i 表示體素 i 經投影頭輸出之嵌入向量，本研究先以 L2 正規化得到單位向量 \mathbf{z}_i ，並以溫度縮放之歸一化內積定義相似度。由於 \mathbf{z}_i 已正規化，該相似度等價於餘弦相似度乘上溫度係數之縮放。

$$\mathbf{z}_i = \frac{\mathbf{v}_i}{\|\mathbf{v}_i\|_2} \quad (10)$$

$$s_{ij} = \frac{\mathbf{z}_i^\top \mathbf{z}_j}{\tau} \quad (11)$$

其中 τ 為溫度參數，本研究之溫度係數固定採用 0.01。對於每一錨點體素 i ，本研究令 \mathcal{P}_i 表示其正樣本集合。正樣本來源除同一視角內之同類體素外，亦包含同一 VOI 之增強視角所取得之同類體素，以增加正樣本對之多樣性並引入跨視角一致性訊號。

本研究採用軟式正樣本加權 (Soft Positives)，主要基於訓練穩定性與 IVOCT 鈣化影像特性之考量。於訓練早期，模型嵌入表徵尚未穩定，若以硬式正樣本 (Hard Positives) 將所有鈣化體素等權視為完全同質並強制緊密聚集，對比損失引入的約束可能過強，易導致梯度震蕩並影響收斂。其次，冠狀動脈 OCT 影像中的細小與薄片型鈣化在分割上易被漏檢。若採硬式正樣本，正樣本對的梯度貢獻易被面積較大且形態典型之鈣化區主導，弱化對細小鈣化局部結構的辨識。相對地，軟正樣本以幾何鄰近或結構一致性作為權重依據，可使細小鈣化在表徵學習中獲得更貼近其局部形態的正向訊號，而不必被迫向大型鈣化的表徵中心靠攏。

此外，本研究之任務存在嚴重類別不平衡。軟正樣本加權可將有限的正樣本訊號集中於更可靠且更具一致性的正樣本對，降低因正樣本稀少而造成的取樣不穩定。再者，冠狀動脈 OCT 影像中的鈣化邊界常受訊號衰减、散射與陰影效應等成



像影響，使邊界附近的影像綫索與標注之間可能存在不確定帶。若將邊界附近體素亦視為等權正樣本，則會在對比學習引入不必要的強約束與額外梯度噪聲。Soft Positives 樣本加權可在不改變標籤定義之前提下，對不確定之區域賦予較小權重，使對比約束更為平滑並提升訓練穩定性。最後，冠狀動脈 OCT 影像中鈣化類內異質性明顯，厚薄、邊界清晰度與衰減程度皆可能不同。若將所有同類體素等權拉近，模型可能被迫將差異甚大的鈣化型態壓縮至過於集中的特徵區域，增加過度約束與泛化不良之風險。本研究中正樣本以距離加權，使更相近的鈣化樣本對貢獻較大，可降低上述副作用並更符合鈣化外觀的多樣性。

為建構軟正樣本之權重，本研究以錨點 i 與正樣本候選 p 在 $1/2$ 解析度之下採樣網格上的幾何距離決定權重大小。令座標為 (r_i, θ_i) 與 (r_p, θ_p) ，角向寬度為 W 。考量角向之周期性，考量冠狀動脈 OCT 影像之角向周期性，本研究採用周期距離定義角向差異：

$$d_\theta(i, p) = \min(|\theta_i - \theta_p|, W - |\theta_i - \theta_p|) \quad (12)$$

$$d_{ip} = \sqrt{(r_i - r_p)^2 + d_\theta(i, p)^2} \quad (13)$$

本研究以距離遞減函數形成未正規化權重，其中 σ 為距離尺度超參數：

$$\tilde{w}_{ip} = \exp\left(-\frac{d_{ip}^2}{2\sigma^2}\right) \quad (14)$$

為避免單一錨點納入過多弱相關正樣本，本研究對每一 Anchor 僅保留權重最高的前 8 個正樣本候選，並設定權重下限 $w_{\min} = 0.05$ 。其後，本研究將保留之權重正規化為 $\sum_{p \in \mathcal{P}_i} w_{ip} = 1$ ：

$$w_{ip} = \frac{\max(\tilde{w}_{ip}, w_{\min})}{\sum_{q \in \mathcal{P}_i} \max(\tilde{w}_{iq}, w_{\min})} \quad (15)$$

此設計使幾何上更接近之正樣本對具有較大梯度貢獻，同時降低邊界不確定帶或類內差異過大時對比約束過強所導致的不穩定。



3.5.5.2 加權對比損失與總訓練目標

令 \mathcal{A}_t 表示第 t 次迭代所選取之錨點集合， Q_i 表示錨點 i 的候選集合，包含其正樣本與負樣本。負樣本之來源與固定取用數量上限已於前一節定義。本研究採用加權 NCE 形式之對比損失，並將軟正樣本權重納入正樣本項：

$$\ell_i = -\sum_{p \in \mathcal{P}_i} w_{ip} \log \frac{\exp(s_{ip})}{\sum_{k \in Q_i} \exp(s_{ik})} \quad (16)$$

$$\mathcal{L}_{con} = \frac{1}{|\mathcal{A}_t|} \sum_{i \in \mathcal{A}_t} \ell_i \quad (17)$$

當某次迭代可用正樣本不足以形成對比目標時，本研究令該迭代之 $\mathcal{L}_{con} = 0$ ，以維持數值穩定並避免以不完整配對驅動更新。

最後，本研究以分割損失 Dice 與對比損失 \mathcal{L}_{con} 加權形成總損失，計算方法如公式 (18) 所示。

$$\mathcal{L}_{total}(t) = \mathcal{L}_{Dice}(t) + \lambda_{con}(t) \mathcal{L}_{con}(t) \quad (18)$$

其中對比損失權重 λ_{con} 採用 warm-up 與線性遞增策略，訓練前 5 個 Epoch 令對比式學習權重為 0，自第 6 個 Epoch 起，於 10 個 Epoch 內 λ_{con} 線性增加至上限 λ_{max} （本研究設 $\lambda_{max} = 0.20$ ），其權重具體公式為

$$\lambda(t) = \begin{cases} 0, & t \in \text{epoch}1-5, \\ \lambda_{max} \cdot \frac{k(t)}{10}, & t \in \text{epoch}6-15, \\ \lambda_{max}, & t \in \text{epoch} \geq 16, \end{cases} \quad (19)$$

其中 t 為 Epoch(或迭代步)，其中 $k(t) \in \{1, 2, \dots, 10\}$ 表示 t 所屬之 Epoch 自第 6 個 Epoch 之累計訓練周期數。

3.6 後處理

本研究爲了讓模型能充分學習前後影像幀 (Frame) 之間的關係，以前處理所建立之感興趣體積 (VOI)，進行訓練與推論；由於 VOI 係沿 Pullback 方向以滑動視窗方式產生（每個 VOI 含連續 $D = 8$ 張切片，移動步長 $\text{Stride} = 3$ ），故同

一張切片在推論階段通常會被多個相鄰 VOI 所涵蓋，並對應產生多次預測結果。故在模型輸出後，需將影像進行後處理，還原為 Pullback 序列中逐張切片之最終預測。本研究之後處理方法，針對每一張切片（及其像素位置），將所有包含該切片之 VOI 所輸出之預測機率逐一對齊並將機率值取平均，作為最終結果。如圖 18 所示。




圖 18 後處理之方法示意圖



第四章 結果與討論

4.1 資料擴增之結果

本研究於第 3.2.7 節提出以多個直角座標中心點作為極座標轉換原點之資料擴增策略，藉由對同一張冠狀動脈 OCT 影像施加不同的極坐標轉換中心位移，產生多組對應的極座標影像，以增加訓練資料的多樣性。其擴增效果如圖 19 所示：在維持主要解剖結構與病灶形態連續性的前提下，不同中心設定會使極座標影像中周向相位 (θ 軸) 與徑向對應關係 (r 軸) 呈現可觀察之差異，進而形成多組在極座標表徵下呈現略有差異但語意一致的訓練樣本。此結果顯示，中心擾動擴增能有效模擬臨床情境中導管偏心 (Decentration)，並可作為後續模型學習之資料多樣性來源。




圖 19 資料擴增結果



4.2 評估指標

本研究之鈣化斑塊分割屬於體素級二元判別問題，且背景體素數量遠高於鈣化體素，呈現顯著類別不平衡。為準確評估模型性能並進行較為全面的比較，以混淆矩陣 (Confusion Matrix) 之四項計數：真陽性 (True Positive, TP)、偽陽性 (False Positive, FP)、偽陰性 (False Negative, FN) 與真陰性 (True Negative, TN) 作為計算基礎，據以推得各項評估指標。圖 20 顯示了二元分割之四種判別結果，其中以鈣化體素為正類、背景體素為負類。TP 表示模型正確將鈣化判為鈣化；TN 表示模型正確將背景判為背景；FP 表示模型錯誤將背景判為鈣化；FN 表示模型錯誤將鈣化判為背景。





圖 20 鈣化分割之四種結果示意圖：TP (真陽性)、TN (真陰性)、FP (偽陽性)、FN (偽陰性)、GT (標注值)、Pred (預測值) 以及 L (管腔)

除了用 Dice 係數 (Dice Coefficient, DSC) 與交並比 (Intersection-over-union, IoU) 衡量預測區域與標注區域之重疊程度外，本研究亦採用精確率 (Precision)、靈敏度/召回率 (Sensitivity; 亦即 Recall)、平衡準確率 (Balanced Accuracy, BalAcc) 與 馬修斯相關係數 (Matthews Correlation Coefficient, MCC) 等指標，對模型分割表現進行綜合評估，以分別反映模型在重疊品質、誤檢控制、漏檢程度、類別均衡表現，以及整體判別一致性等面向之行爲。



各指標定義及公式如下：

- Dice coefficient (DSC)：衡量預測與標註之重疊程度：

$$\text{Dice} = \frac{2TP}{2TP+FP+FN} \quad (20)$$

- Intersection-over-Union (IoU)：以交集與聯集之比衡量重疊程度：

$$\text{IoU} = \frac{TP}{TP+FP+FN} \quad (21)$$

- 靈敏度/召回率 (Sensitivity; Recall)：在所有真實鈣化體素中，被正確檢出之比例：

$$\text{Sensitivity} = \text{Recall} = \frac{TP}{TP+FN} \quad (22)$$

- 平衡準確率 (Balanced Accuracy, BalAcc)：以靈敏度與特異度之平均反映正負類均衡表現：

$$\text{BalAcc} = \frac{\text{Sensitivity} + \text{Specificity}}{2} = \frac{1}{2} \left(\frac{TP}{TP+FN} + \frac{TN}{TN+FP} \right) \quad (23)$$

- Matthews correlation coefficient (MCC)：綜合 TP、TN、FP、FN 評估預測與標註之整體一致性：

$$\text{MCC} = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP+FP)(TP+FN)(TN+FP)(TN+FN)}} \quad (24)$$

4.3 3D U-Net 方法之分割結果與討論

本研究以 3.4 中所述之 3D U-Net 作為基礎模型，在測試集上以固定閾值 0.5 將模型輸出機率圖轉為二值遮罩。整體而言，模型於測試集之評估達到 Dice 0.8317 ± 0.0143 與 IoU 0.7148 ± 0.0123 ，顯示之鈣化斑塊預測區域與人工標註之空間重疊度良好。值得注意的是，Precision 為 0.8918 ± 0.0153 ，高於 Recall 之 0.7828 ± 0.0134 ，反映模型在判定鈣化時較為保守，傾向於降低偽陽性以維持較高的預測精確度，但仍存在一定程度的漏檢。MCC 為 0.8275 ± 0.0142 ，佐證了在類別不平衡情境下模型對鈣化的辨識並非僅受背景主導，而是具備穩定的鈣化辨識



能力，部分可視化結果如圖 21 所示，整體而言，模型對大、中、小鈣化都具有一
定辨識能力。

由於本研究採用固定閾值進行二值化，且以本文之 3.3.5 之方法，將 Pullback
序列以步長 (Stride) =3 取樣，並以視窗長度 8 之連續切片構成一個三維感興趣
體積 (VOI)，作為用於模型訓練之基本單位。並以 3.6 之方式進行後處理，機率
圖在同一切片被多視窗平均後可能趨於平滑，對臨界邊界體素的機率分布更敏感。
在此設定下，Precision 明顯高於 Recall，較符合邊界不確定區域被閾值排除而形
成偽陰性之情境，尤其 IVOCT 鈣化常伴隨衰減、陰影與訊號低對比，邊界定義易
受成像條件影響，導致模型較難在薄鈣化或邊緣過渡區維持穩定敏感度。換言之，
本模型較能可靠地指出高精確度之鈣化區，但對於弱訊號或形態不典型之鈣化仍
可能低估其範圍。




圖 21 3D U-Net 冠狀動脈 OCT 影像鈣化斑塊之自動分割結果。圖像依次為：(a)
IVOCT 原始影像；(b) 標注影像；(c) 自動分割影像；(d) 標注遮罩；(e) 自動分
割遮罩。三個示例均顯示人工評估與自動評估具有良好一致性

4.4 先期探索：不同表徵學習策略之比較（以 BYOL 為例）

本研究先前以未標註 IVOCT 影像進行自監督預訓練作為先期探索，目的在於評估僅依賴跨視角一致性所驅動之表徵學習，是否能在標注量受限的情境下有效利用未標注資料，進而提升下游鈣化分割表現並降低對密集標注之依賴。惟本研究之實驗結果顯示，該預訓練策略於本資料規模與任務設定下未能穩定提升下游任務之分割效能，因此本文將其定位為探索性結果，並用以界定未標注預訓練於本任務中的適用條件與限制。

為比較不同表徵學習策略對 IVOCT 鈣化分割之影響，本文進一步納入 BYOL (Bootstrap Your Own Latent) 作為跨視角一致性導向之自監督預訓練代表方法，並以其結果與本文之 3D U-Net 進行對照，其整體架構如圖 22 所示。

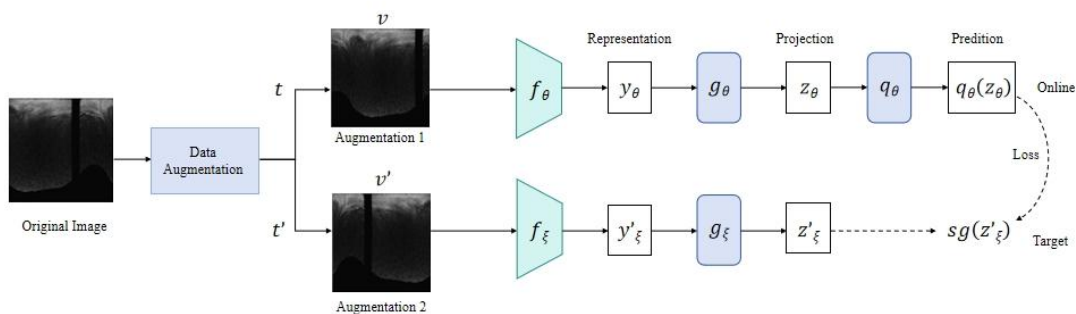


圖 22 BYOL 架構圖

具體而言，對同一輸入之 VOI 產生兩個隨機增強視角 v 與 v' ，並分別送入 Online 與 Target 兩個網路分支以形成對稱式學習訊號；本研究以對稱式餘弦回歸損失 (Cosine Loss) 作為學習目標，使線上分支 (Online Predictor) 之輸出對齊目標分支 (Target Projector) 之表徵。Online 分支包含 Encoder 與 Projection Head，並額外接上 Prediction Head 以輸出嵌入向量；Target 分支僅包含 Encoder 與 Projection Head，輸出嵌入向量，且其梯度於訓練時停止回傳 (Stop-gradient)。



BYOL 預訓練使用未標註影像共 24041 幀，由於本研究可用之未標註影像規模有限，BYOL 預訓練可能無法充分發揮其表徵學習效益，因此於結果討論時將資料量限制列為可能影響之因素。

預訓練之過程如圖 23 (a) 所示，預訓練之損失雖在早期訓練階段出現震蕩，在仍呈現快速下降；訓練曲線在約第 14–16 個 Epoch 後呈現一致性的下降與平臺化。在相同訓練過程中，圖 23 (d) 呈現 Predictor 與 Target Embedding 間餘弦相似度均值持續上升並在中後期接近飽和，反映兩視角表徵對齊逐漸穩定。相對應地，圖 23 (c) 顯示 Predictor Embeddings 與 Target Embeddings 的跨維度標準差在預訓練前期由較低值上升並趨於平穩，且兩者在中後期趨於一致，代表嵌入空間的表徵數值量級與分散程度達到相對穩定的平衡，並未呈現全面性崩塌。由圖 23 (b) 可見學習率隨餘弦衰減逐步下調，顯示兩視角表徵對齊逐漸穩定。整體而言，預訓練過程雖歷經初期波動，但後續結果支持本研究之 BYOL 設計能在自監督目標上達到穩定的收斂行為。

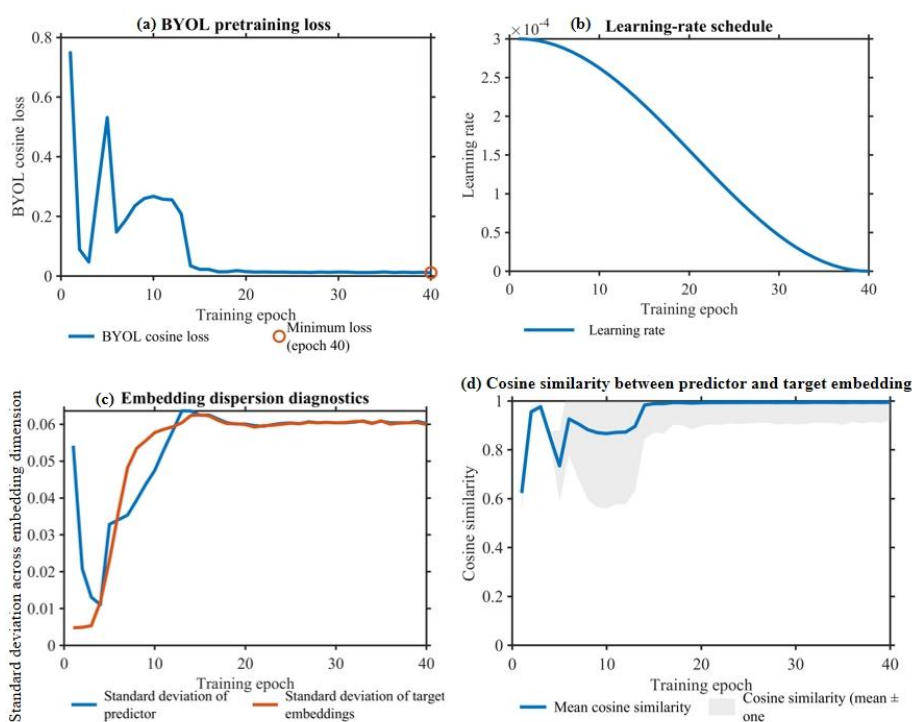


圖 23 BYOL 預訓練之各項結果指標



即使預訓練在全域對齊上收斂良好，其是否形成具良好跨樣本可分性之嵌入表徵，能帶來下游分割增益仍需在下游實驗中額外驗證，預訓練任務需要與下游任務的表徵粒度一致，而不是僅以預訓練中損失的高低做結論。

本研究嘗試驗證了在較少的影像數據量下，經過 BYOL 預訓練之 3D U-Net 是否會有更好的鈣化斑塊分割表現，表 3 顯示了在相同資料切分與訓練設定下，各對比式學習策略於測試集之 Dice 表現。由於本研究主要著重於不同策略間之相對行為比較，且每一設定均於固定隨機種子下訓練一次，故結果呈現單次訓練之量測值。

表 3 不同標註資料量下，3D U-Net 與 BYOL 預訓練模型之 Dice 係數比較

標註資料比例	標註切片數	3D U-Net (Mean Dice)	BYOL → U-Net (Mean Dice)
100%	34948	0.8317±0.0143	0.8174
50%	17333	0.8305	0.8045
20%	6980	0.8195	0.7717
10%	3466	0.7889	0.7111

由表 3 中可見，對於冠狀動脈 OCT 影像中分割鈣化斑塊之任務，經過 BYOL 預訓練的 3D U-Net 模型在 100%、50%、20%、10% 的標註比例下皆未優於直接以監督式訓練的 3D U-Net，且 3D U-Net 基礎模型已經能够在較少資料量下得到較好之鈣化斑塊分割效果。該結果指出，預訓練目標的良好收斂本身不足以保證下游密集預測任務的效益。當下遊任務屬於小目標、強不平衡、且以邊界辨識為核心的醫學分割時，自監督表徵未必能自然轉化為 Dice 的提升。

本研究造成此結果之原因可能為影像層級自監督學習 (SSL) 多以全域表徵對齊與不變性為主要目標，於是 BYOL 主要對齊的是全域嵌入表徵，其訓練目標是使正樣本對的整體表徵在增強擾動下趨於一致；而分割等密集預測任務則需

要保留局部空間結構與邊界細節方面的資訊。當標注更少時，理想情況是預訓練提供更好的初始化以補足監督訊號不足，但此時兩者在學習目標上存在落差，預訓練表徵學習過程中模型學得之特徵可能更偏向全域對齊，未能保留分割所需之局部結構與邊界細節，因此限制下游分割任務之效能。由圖 24 可見，經過 BYOL 預訓練過後之影像分割結果部分呈現分割區域碎片化之情形。

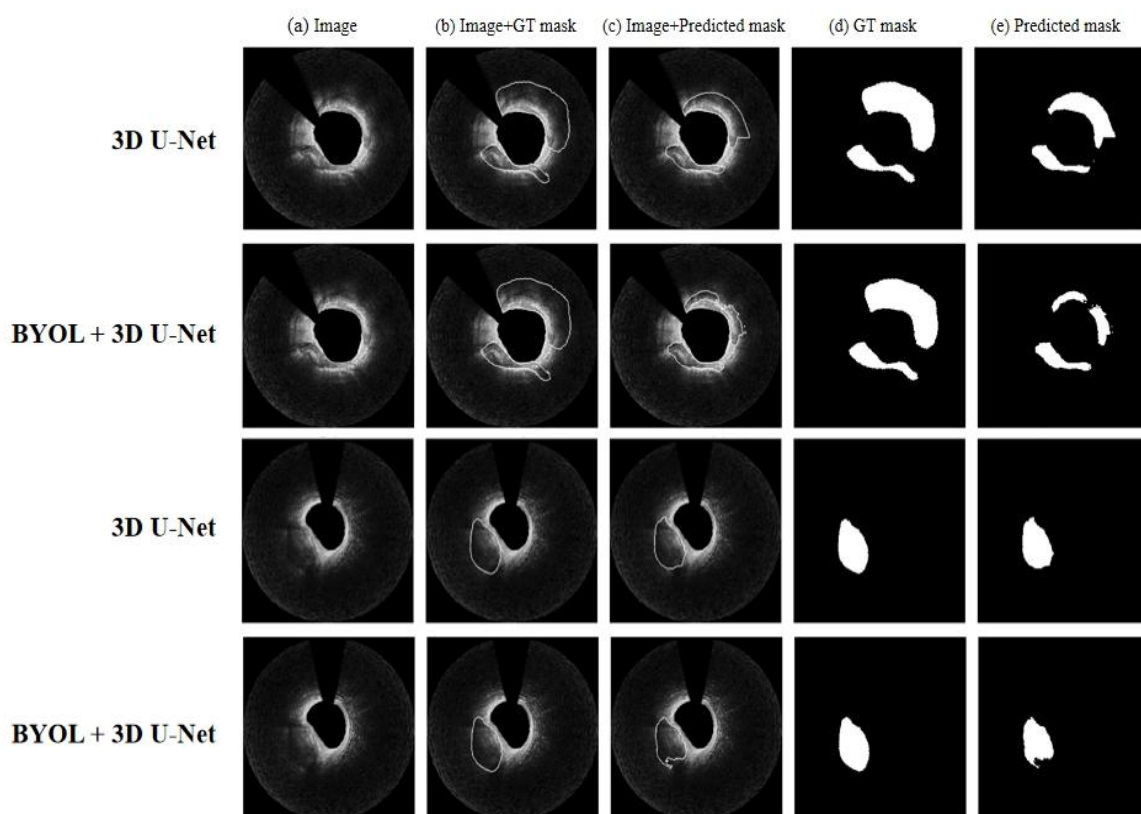


圖 24 BYOL 與 3D U-Net 分割結果對比圖

就冠狀動脈 OCT 影像而言，BYOL 可能更容易學到血管壁整體之背景結構、紋理特徵、明分布這類整體特徵。但本研究的目標是分割影像中的鈣化，而鈣化的關鍵訊號往往更體現在影像的局部紋理差異，例如訊號偏低，邊界銳利等，且鈣化可能只占整張影像的極小面積。加之在增強擾動下，BYOL 可能會傾向將一些對分割判別有意義的細微差異也一並視為應被消除的變化，導致表徵更偏向全域一致性而非邊界敏感性；這種過度不變性在小目標情境下可能使鈣化與背景在特徵



空間的間隔不足，造成了學習目標與任務需求不一致。預訓練學到的穩定性與下遊分割所需的邊界與少數類敏感性存在落差，Fine-tune 階段反而需要先克服既有表徵偏好，導致對比式學習效益受限，最終反映為 Dice 不易提升。

其次，未標注影像資料量不足與類別極端不平衡會放大自監督遷移的不確定性。鈣化像素在冠狀動脈 OCT 影像中占比偏低，而 BYOL 訓練訊號不利用標注，模型在預訓練階段較可能優先以大量背景作為表徵基底，使少數類鈣化相關綫索缺乏任務導向的驅動，學習更好對齊、但與鈣化不直接相關的特徵。近期研究亦指出，在小型且不平衡的醫學資料上，SSL 相較於監督學習未必穩定占優；在有限的資料量，且在極度不平衡設定下，自監督方法的效能下滑幅度亦可能較明顯，而監督式方法整體呈現較佳的穩健性[65]。

此外，3D U-Net 本身具備多解析度層級編碼解碼與跳躍連接結構，對於 IVOCT 這種同一血管段落內具強局部結構綫索的資料，監督式損失可直接把梯度集中在鈣化區域與其邊界，較能明確分割所需的判別特徵。

基於上述特性，本研究目的在提升 IVOCT 鈣化之可分性與邊界辨識，因此將對比式約束直接嵌入監督式訓練，於體素層級以標註定義正負樣本關係，通常更有機會使表徵學習更聚焦於少數類鈣化與易混淆背景，而非僅強化跨外觀擾動之全域不變表徵。



4.5 體素級對比式學習之結果與討論

整體而言，在 3D U-Net 監督式分割模型中加入體素級對比式學習之方法對於不同形狀、大小的鈣化分割都有較佳的表現，包括體積較小之薄片狀鈣化，分割結果如圖 25 所示。




圖 25 體素層級監督式對比學習+ 3D U-Net 鈣化分割結果

表 4 加入體素級對比式學習前後之評價指標對比

評估指標	模型方法	Voxel-level Contrast+3D U-Net	3D U-Net
Dice 相似係數 (Dice Similarity Coefficient, DSC)		0.8383±0.0127	0.8317±0.0143
交並比 (Intersection over Union, IoU)		0.7216±0.0109	0.7148±0.0123
精確率 (Precision, Prec)		0.8825±0.0134	0.8918±0.0153
召回率 (Recall, Rec)		0.7984±0.0121	0.7828±0.0134
平衡準確率 (Balanced Accuracy, BalAcc)		0.8964±0.0136	0.8904±0.0153
馬修斯相關係數 (Matthews Correlation Coefficient, MCC)		0.8313±0.0126	0.8275±0.0142

本研究之結果在各項指標上亦整體表現良好。表 4 顯示，加入體素層級對比式學習後，模型於整體重疊類指標呈現小幅改善。Dice 由 0.8317±0.0143 上升至 0.8383±0.0127，IoU 由 0.7148±0.0123 上升至 0.7216±0.0109。若以兩方法之均值差作為提升量，Dice 之提升為 0.0066，約為 0.79% 相對提升，IoU 之提升為 0.0068，約為 0.95% 相對提升。雖然 Dice 的提升幅度有限，但 Dice 較容易被較大鈣化所影響，因此模型在細小鈣化、邊界附近或易混淆低訊號區的改善不一定能够在整體 Dice 數值上得到充分體現。且就影像層面而言，模型整體預測形態仍與 3D U-Net 相近，主要原因在於分割分支仍由監督式目標主導；然而，在困難區域的可分辨性上，本研究方法呈現較有利的趨勢。

相較重疊類指標之變化，錯誤型態的轉移更具解讀價值。原本 3D U-Net 之 Precision 為 0.8918±0.0153，Recall 為 0.7828±0.0134，顯示模型偏向保守判定，並以降低偽陽性 (FP) 來換取較高的精確率。加入體素層級對比式學習後，各項指標中模型最主要的變化體現在 Recall 提升至 0.7984±0.0121，約為 1.99% 的相對提升。同時，Precision 下降至 0.8825±0.0134，約為 1.04% 之相對下降。上述結



果反映，模型加入對比式學習後，模型更願意做出正類判定，從而降低漏檢，雖然在其過程中，也伴隨有限之誤檢增加。

此外，BalAcc 與 MCC 均呈現上升，分別由 0.8904 ± 0.0153 提升至 0.8964 ± 0.0136 ，以及由 0.8275 ± 0.0142 提升至 0.8313 ± 0.0126 。此結果支持模型在正負類別的整體判別性上獲得小幅改善，而非僅由單一指標造成的偶然波動。

整體而言，本研究方法的主要貢獻並非來自大幅提升整體 Dice，而更可能來自少數類鈣化之檢出能力提升。圖 26 中視覺化結果顯示，此方法對於形狀複雜之鈣化分割具有較佳適應性，並可對不規則之鈣化邊界提供較細緻之描繪，且在體積較小或薄片狀之鈣化病灶具有較佳分割表現。





圖 26 體素層級監督式對比學習融合 3D U-Net 之困難鈣化分割結果




4.6 嵌入空間之類內凝聚與類間可分性分析

本節以視覺化結果作為主要呈現，說明模型在嵌入空間中對鈣化與背景體素之分離情形。本研究於驗證資料集抽樣取得鈣化體素與背景體素之嵌入向量，並以餘弦相似度比較鈣化對鈣化，與鈣化對背景之分布差異，鈣化對鈣化，與鈣化對背景配對各共計抽樣 200,000 組。



(a)



(b)

圖 27 類內與類間餘弦相似度分布圖：(a) Kernel density estimate of cosine similarity (KDE curve)；(b) Cosine similarity Histogram

在背景定義採用嚴格有效區域內之全背景下，類內與類間餘弦相似度分布圖（圖 27）呈現明顯分離趨勢。鈣化對鈣化之相似度分佈集中於高值區域，其中位數為 0.896，四分位範圍為 0.738 至 0.968，P95 為 0.994。相對地，鈣化對背景之相似度分布主要落在接近零或偏負的區域，其中位數為 -0.016，四分位範圍

為 -0.125 至 0.212 。就可分性指標而言，兩分佈之平均差距為 0.711 ，且以相似度區分類內與類間配對的 AUROC (Area Under the Receiver Operating Characteristic) 為 0.922 ，顯示嵌入表徵具備良好之類別判別性。然而，鈣化對背景之相似度分布在正相似度方向仍可見延伸之尾端，反映少部分背景體素與鈣化體素在嵌入空間中具有較高相似度。整體而言，類內分佈與類間分佈呈現明顯位移與有限重疊。

本研究進一步以體素層級之嵌入表徵為基礎，檢視鈣化體素與背景體素在特徵空間中的聚合與分離情形。圖 28 中以 t-SNE (t-distributed Stochastic Neighbor Embedding) 將高維嵌入投影至二維後，可見鈣化體素與背景體素大致形成兩個呈現明顯區隔的主要群集；但仍有少量點落入對方群集或分布於群集邊緣。上述視覺化結果與相似度分布所呈現的主體分離與尾端重疊相互呼應。






圖 28 t 分佈隨機鄰域嵌入 (t-distributed Stochastic Neighbor Embedding, t-SNE)

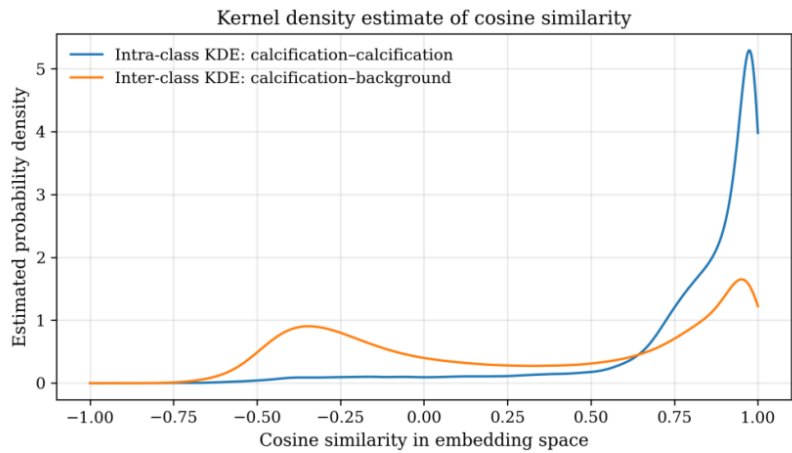


上述結果顯示，模型在嵌入空間同時具備類內凝聚與類間分離兩項特性。結合冠狀動脈 OCT 影像原理及特性推測，類間分布右側之高相似度背景體素可能較常出現在鈣化邊界鄰近的低對比區域，或位於訊號衰減或陰影導致之可視性不足區段，因而在表徵上更接近鈣化。

在此基礎上，本研究進一步將背景定義收斂至更貼近錯誤來源的集合，即 3.5.3 中所定義之困難負樣本，比較類間分布之位移。如圖 29 (a) 中所示，當背景限制為邊界帶狀背景時，類間相似度之中位數上升至 0.191，但類間相似度分布在高相似度區間呈現更加明顯的右側長尾，顯示存在具混淆性的背景體素，P95 為 0.971。當加入困難背景時，類間相似度分布進一步右移，其中位數上升至 0.378，P95 達 0.985。圖 29 (b) 顯示困難背景在高相似度區域具有更高密度，反映該背景集合確實包含更多與鈣化嵌入相近的體素，符合模型推論錯誤多集中於具混淆性的背景體素（如邊界鄰近或易誤判區域）之一般觀察。此外，上述結果佐證本研究之困難背景定義能有效搜集與鈣化嵌入表徵相近之混淆負樣本，因而具備作為困難負樣本挖掘之合理性；同時，為避免負樣本過度集中於單一混淆子群並維持背景多樣性，本研究採用困難挖掘結合隨機抽樣之混合策略。



(a)



(b)

圖 29 不同背景定義差異下之餘弦相似度分布 (KDE)：(a) 邊界帶狀背景定義下之餘弦相似度核密度估計 (KDE) 曲線；(b) 困難背景定義下之餘弦相似度核密度估計 (KDE) 曲線

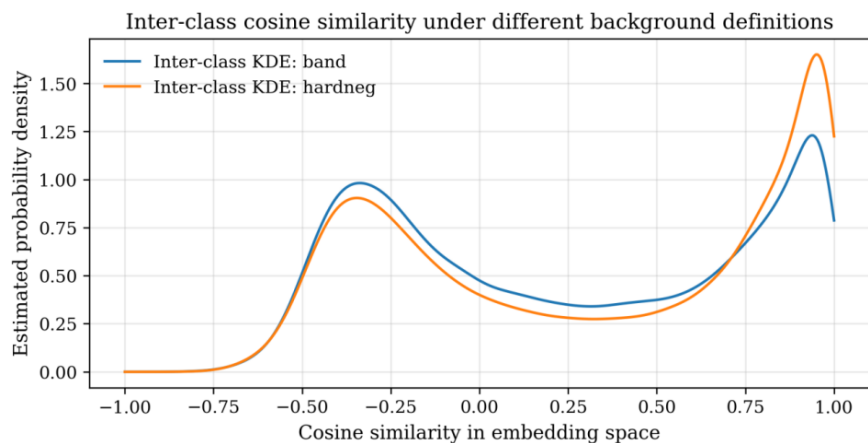


圖 30 不同背景定義差異下之類間餘弦相似度分布 (KDE)

ROC (Receiver Operating Characteristic) 曲線可作為上述分布差異之整體量化指標。以邊界帶背景作為負類時，AUROC 為 0.800；當負類改為困難背景時，AUROC 降至 0.760，可解釋為是由背景區隔難度提升所致。此結果亦提示分割錯誤可能較集中於相似度分布右側之與目標之高相似度背景樣本；在困難背景設定下，該類樣本占比提高，因而拉近類間分布並降低模型整體區辨能力。儘管如此，兩種設定之 AUROC 仍明顯高於 0.5 (隨機水準)，表示模型在較嚴格條件下仍保有一定程度之表徵可分性，如圖 31 所示。

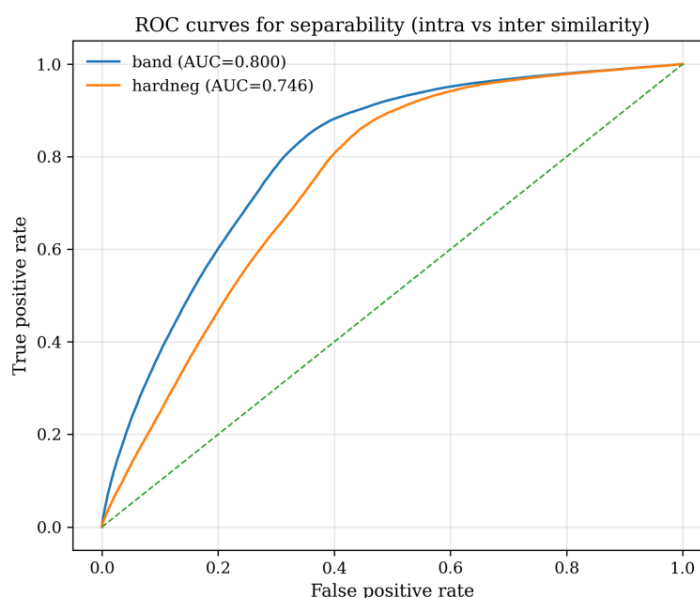


圖 31 不同背景定義下之 ROC

4.7 本研究之限制與未來工作

本研究提出之體素層級監督式對比學習雖可強化模型在邊界模糊與易混淆背景下之可分辨性，並使鈣化邊界描繪更為細緻，然而部分情境仍可觀察到預測結果之不穩定與表現受限之現象。

首先，當鈣化內部體素呈現高度異質性，或鈣化與非鈣化組織在低訊號區域的外觀相近時，模型的分割結果可能出現較為細碎的碎片化現象，模型整體分割品質

降低，此一現象與 IVOCT 成像特性密切相關。鈣化斑塊在 IVOCT 影像中呈現為低訊號值區域。而在血管壁深層、脂質斑塊或陰影區域同樣可能會呈現與鈣化斑塊相似的低灰階值的特點，使模型在嵌入空間中面臨大量外觀相似但標籤相異的配對；當對比式學習將此類配對視為必須推離之負對時，模型可能在局部區域形成更强的判別壓力，進而使鈣化區域的連續性較易被切割。因此，本研究於圖 32 所示案例中觀察到，鈣化區域在部分切面上可能被分割為多個不連續之小區塊。




圖 32 困難案例示例：鈣化區域異質性導致之分割碎片化

此外，IVOCT 影像血管壁深層區域的訊號衰減，可能導致鈣化斑塊的厚度被模型低估，可視化實例如圖 33。冠狀動脈 OCT 影像中，鈣化斑塊多呈訊號偏低且邊界清楚之區域；當鈣化厚度較大或位於穿透受限的深層時，深部邊界可能不易辨識[21]，致使鈣化後方或鄰近結構之影像資訊不足。更進一步而言，OCT 影像之解析度伴隨深度的增加而顯著下降[66]，因此可能無法完整、準確地呈現組織邊界，進而低估深層鈣化之厚度，並使其嚴重程度之判定趨於保守，並可能影響後續治療決策之制定[67]。




圖 33 困難案例示例：鈣化區域後訊號衰減導致之分割厚度被低估

其次，本研究方法高度依賴大規模數據集和高質量標注。體素層級對比式學習需要以標注定義正負樣本關係，若標注因在鈣化後緣或低訊號區域存在不確定帶，或其他原因導致的標注不準確，對比損失可能難以收斂，並影響其對下游分割的增益。但臨床上要對 IVOCT 影像中冠狀動脈斑塊進行完整人工標注是一項非常具有挑戰性的任務，影像判讀需要基於大量的專業知識，逐幀仔細考量圖像特徵，例如當 400 幀 Pullback 影像中鈣化斑塊（CAC）占比不足 10% 時，經驗豐富的分析師可能需要耗費 30 分鐘以上方能完成精確標注[68]。即便出於研究目的，人工分析單次 IVOCT Pullback 數據也動輒耗費數小時，且存在觀察者間與觀察者內的差異性[38]。

此外，本研究亦受限於資料可得性與可比性。就目前公開資源而言，尚缺乏大規模且具一致標注規範的冠狀動脈 OCT 影像資料，因此不同研究往往採用各自蒐集之資料與標註流程。當病例組成、成像系統、與標注準則不同時，模型之分割表

現可能產生明顯差異，且不易與既有方法在相同基準資料集上進行直接比較，因而限制了跨研究之客觀對照與泛化能力評估。

綜上所述，本研究之體素層級對比式學習在困難情境下具備改善可分辨性之潛力，但其效益仍受限於低訊號混淆帶來的外觀相似性，以及高品質密集標注資料之取得難度。因此，臨床實務上不易取得高品質之密集標注資料，亦使本方法在中心或跨儀器資料集上可能擴展受限。基於此限制，未來研究可將未標注資料的利用列為核心策略，克服標注資料匱乏以及傳統模型泛化能力不足的限制，而非僅以擴充標注數量解決問題。

未來研究中，可考慮採用跨層級對比學習（Cross-level Contrastive Learning），將同一空間位置於不同層級之表徵投影至共同嵌入空間後進行對齊，以深層特徵所提供之較穩定全域語意，約束淺層特徵形成的過強局部判別壓力。此一設計可建立跨層一致性並緩解單一尺度表徵所造成的偏誤，且能夠搭配類別標注定義跨樣本之正負關係，以降低碎片化分割，提升鈣化分割的連續性與穩定性。其次，可嘗試多解析度對比學習（Multi-resolution Contrastive Learning），即在不同解析度之特徵圖分別施加體素層級對比約束，使深層表徵維持全域語意穩定性，同時由淺層表徵保留邊界與局部定位相關資訊。

第五章 結論



本研究以冠狀動脈血管內光學同調斷層掃描影像之鈣化斑塊分割為研究目標。針對鈣化病灶小型化與類別嚴重不平衡所造成之漏檢與邊界不穩定問題，本文提出體素層級監督式對比學習融合 3D U-Net 之方法，並整理其主要貢獻如下：

第一，本研究依據冠狀動脈 OCT 之成像原理與影像特性，建立系統性之前處理流程，以降低幹擾，並提供一致之模型輸入表徵。

第二，本研究採用非等向性三維 U 型網路架構，以 OCT 影像之平面內解析度顯著高於幀間解析度之特性為出發點，並在計算量與 GPU 記憶體需求可控的條件下保留必要的跨幀資訊，使模型兼顧面內細節與 Pullback 方向連續性。

第三，對比式學習被直接嵌入監督式訓練流程，並於體素層級依據人工標注明確定義正負樣本關係以在特徵空間強化鈣化與背景之可分離性。此一設計使學習訊號能聚焦於少數類鈣化與易混淆背景之判別需求，而非僅追求跨外觀擾動之不變表徵。因而較有機會改善邊界模糊與低訊號混淆等困難情境。

第四，設置類別導向之佇列式記憶庫，以擴充對比樣本來源，並透過跨批次特徵累積降低小批次取樣偏差，使樣本集合可隨訓練歷程持續更新，有助於模型學習整個數據集中同類樣本的關聯性。

第五，本研究以雙視角策略共同抽取體素嵌入以構成對比樣本，藉此引入跨視角一致性並擴充正樣本來源；同時，本文採用軟式正樣本加權，依幾何距離賦予權重並保留權重較高之正樣本，以降低低品質正對對學習方向之幹擾。

第六，本研究採用困難樣本挖掘結合隨機抽樣之混合策略，在聚焦易混淆負樣本之同時維持負樣本多樣性，並避免負樣本被大量易區分背景稀釋而削弱學習效



果。

另為評估未標註影像之表徵學習效益，本文以 BYOL 進行自監督預訓練對照實驗。該預訓練使用未標註影像共 24041 幀。結果顯示，預訓練過程呈現收斂行為，但在多種標註比例下未能帶來下游分割增益，推測造成此結果之原因為預訓練目標與分割任務所需之局部判別表徵存在落差。

在量化結果方面，加入體素層級對比學習後，Dice 由 0.8317 ± 0.0143 提升至 0.8383 ± 0.0127 ，IoU 由 0.7148 ± 0.0123 提升至 0.7216 ± 0.0109 。指標變化以敏感度提升最為明顯，Recall 由 0.7828 ± 0.0134 提升至 0.7984 ± 0.0121 。同時 Precision 由 0.8918 ± 0.0153 下降至 0.8825 ± 0.0134 ，反映模型傾向在可接受之誤檢增加下，換取漏檢的降低。整體而言，本文方法之主要貢獻較可能在於降低偽陰性並提升少數類判別之穩健性。

綜合 t-SNE、餘弦相似度分布與 ROC 分析，本研究證實所學得之體素嵌入能有效聚合鈣化表徵，並與多數背景分離，類內分布與類間分布呈現明顯位移與有限重疊。

本研究仍存在若干限制。其一，當鈣化內部異質性高或鈣化與其它低訊號組織外觀相近時，模型仍可能出現局部分割碎片化。其二，OCT 成像在厚鈣化或明顯訊號衰減時，鈣化後緣判讀不易，且殘餘血液、血栓、導絲與支架等偽影亦可能提高邊界定與厚度估計之不確定性。其三，臨床上高品質密集標註資料取得不易，使跨中心與跨儀器之擴展驗證仍受限制。且目前尚缺乏大規模且具一致標註規範之冠狀動脈 OCT 影像資料，用以與其他研究進行模型表現比較。

基於上述限制，後續研究可優先發展更貼近分割目標之表徵學習策略，以提升未標註資料之利用效益並降低對密集標註之依賴；同時，後續工作亦可擴充跨中心

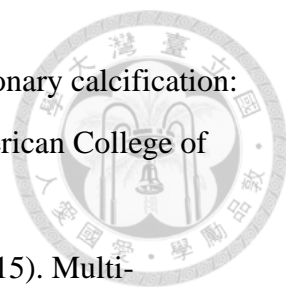
與跨儀器之外部驗證，並納入更完整的臨床情境評估，以支持模型在 PCI 決策支援流程中的可用性。

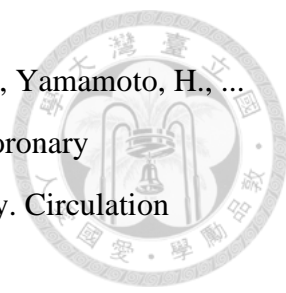
綜上，本文方法具備作為 IVOCT 鈣化病灶量化與治療規劃輔助工具之應用潛力，可提供跨切片較一致之鈣化分割結果，並改善易混淆區域之辨識穩定性，增加鈣化檢出，以支援臨床判讀。

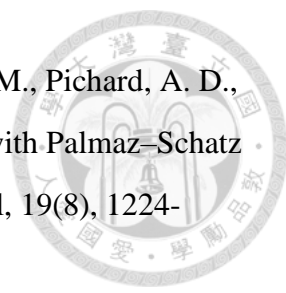
參考文獻

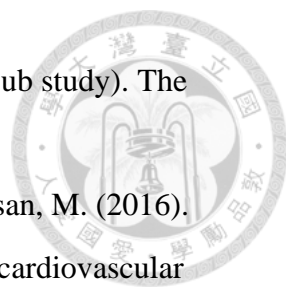


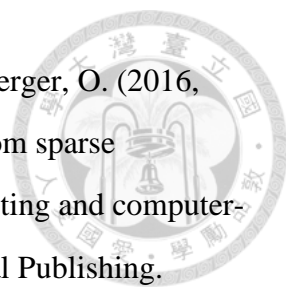
- [1] “Data Page: Leading causes of death,” part of the following publication: Saloni Dattani, Fiona Spooner, Hannah Ritchie and Max Roser (2023) – “Causes of Death.” Data adapted from IHME, Global Burden of Disease. Retrieved from <https://ourworldindata.org/grapher/leadingm-cause-of-death> [online resource]
- [2] “Data Page: The top 10 causes of death,” part of the following publication: World Economic Forum (2021) – “The top 10 causes of death.” Data adapted from WHO, Global Health Estimates. Retrieved from <https://www.weforum.org/stories/2021/02/top-10-global-causes-death> [online resource]
- [3] Hajar, R. (2017). Risk factors for coronary artery disease: historical perspectives. *Heart views*, 18(3), 109-114.
- [4] Vliegenthart, R., Oudkerk, M., Hofman, A., Oei, H. H. S., van Dijck, W., van Rooij, F. J., & Witteman, J. C. (2005). Coronary calcification improves cardiovascular risk prediction in the elderly. *Circulation*, 112(4), 572-577.
- [5] Liu, W., Zhang, Y., Yu, C. M., Ji, Q. W., Cai, M., Zhao, Y. X., & Zhou, Y. J. (2015). Current understanding of coronary artery calcification. *Journal of geriatric cardiology: JGC*, 12(6), 668.
- [6] M. J. Budoff, L. J. Shaw, S. T. Liu, et al., “Long-term prognosis associated with coronary calcification: observations from a registry of 25,253 patients,” *J. Am. Coll. Cardiol.* 49(18), 1860–1870 (2007).
- [7] M. H. Criqui, J. O. Denenberg, J. H. Ix, et al., “Calcium density of coronary artery plaque and risk of incident cardiovascular events,” *Jama* 311(3), 271–278 (2014).
- [8] G. S. Mintz et al., “Unstable angina/myocardial infarction/atherosclerosis: patterns of calcification in coronary artery disease a statistical analysis of intravascular ultrasound and coronary angiography in 1155 lesions,” *Circulation* 91(7), 1959–1965 (1995).
- [9] Tuzcu, E. M., Berkalp, B., De Franco, A. C., Ellis, S. G., Goormastic, M., Whitlow,

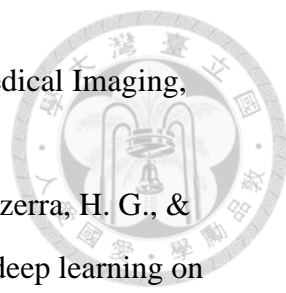
- 
- P. L., ... & Nissen, S. E. (1996). The dilemma of diagnosing coronary calcification: angiography versus intravascular ultrasound. *Journal of the American College of Cardiology*, 27(4), 832-838.
- [10] Ma, T., Yu, M., Chen, Z., Fei, C., Shung, K. K., & Zhou, Q. (2015). Multi-frequency intravascular ultrasound (IVUS) imaging. *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, 62(1), 97-107.
- [11] Huang, D., Swanson, E. A., Lin, C. P., Schuman, J. S., Stinson, W. G., Chang, W., ... & Fujimoto, J. G. (1991). Optical coherence tomography. *science*, 254(5035), 1178-1181.
- [12] Mintz, G. S. (2015). Intravascular imaging of coronary calcification and its clinical implications. *JACC: Cardiovascular Imaging*, 8(4), 461-471.
- [13] Tajima, A., Bouisset, F., Ohashi, H., Sakai, K., Mizukami, T., Rizzini, M. L., ... & Collet, C. (2024). Advanced CT Imaging for the Assessment of Calcific Coronary Artery Disease and PCI Planning. *Journal of the Society for Cardiovascular Angiography & Interventions*, 3(3), 101299.
- [14] Deng, C., Liu, Z., Zhao, R., & Shi, B. (2025). Intravascular imaging and functional assessment for coronary in-stent restenosis: Current status and future directions. *International Journal of Cardiology*, 421, 132918.
- [15] Bezerra, H. G., Costa, M. A., Guagliumi, G., Rollins, A. M., & Simon, D. I. (2009). Intracoronary optical coherence tomography: a comprehensive review: clinical and research applications. *JACC: Cardiovascular Interventions*, 2(11), 1035-1046.
- [16] Muramatsu, T., Ozaki, Y., Nanasato, M., Ishikawa, M., Nagasaka, R., Ohta, M., ... & MISTIC-1 Investigators. (2020). Comparison between optical frequency domain imaging and intravascular ultrasound for percutaneous coronary intervention guidance in biolimus A9-eluting stent implantation: a randomized MISTIC-1 non-inferiority trial. *Circulation: Cardiovascular Interventions*, 13(11), e009314.
- [17] Terashima, M., Kaneda, H., & Suzuki, T. (2012). The role of optical coherence tomography in coronary intervention. *The Korean journal of internal medicine*, 27(1), 1.

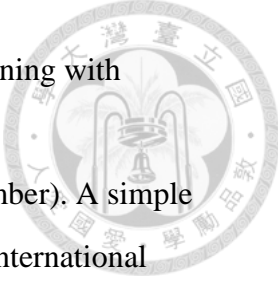
- 
- [18] Mehanna, E., Bezerra, H. G., Prabhu, D., Brandt, E., Chamié, D., Yamamoto, H., ... & Costa, M. A. (2013). Volumetric characterization of human coronary calcification by frequency-domain optical coherence tomography. *Circulation Journal*, 77(9), 2334-2340.
- [19] Fujino, A., Mintz, G. S., Matsumura, M., Lee, T., Kim, S. Y., Hoshino, M., ... & Maehara, A. (2018). A new optical coherence tomography-based calcium scoring system to predict stent underexpansion. *EuroIntervention*, 13(18), e2182-e2189.
- [20] G. J. Tearney et al., “Consensus standards for acquisition, measurement, and reporting of intravascular optical coherence tomography studies: A report from the international working group for intravascular optical coherence tomography standardization and validation,” *J. Amer. College Cardiol.*, vol. 59, no. 12, pp. 1058–1072, Mar. 2012.
- [21] Araki, M., Park, S. J., Dauerman, H. L., Uemura, S., Kim, J. S., Di Mario, C., ... & Jang, I. K. (2022). Optical coherence tomography in coronary atherosclerosis assessment and intervention. *Nature Reviews Cardiology*, 19(10), 684-703.
- [22] Hemetsberger, R., Gori, T., Toelg, R., Byrne, R., Allali, A., El-Mawardy, M., ... & Abdel-Wahab, M. (2021). Optical coherence tomography assessment in patients treated with rotational atherectomy versus modified balloons: PREPARE-CALC OCT. *Circulation: Cardiovascular Interventions*, 14(3), e009819.
- [23] Mozaffarian, D., Benjamin, E. J., Go, A. S., Arnett, D. K., Blaha, M. J., Cushman, M., ... & Turner, M. B. (2016). Heart disease and stroke statistics—2016 update: a report from the American Heart Association. *circulation*, 133(4), e38-e360.
- [24] Abubakar, M., Javed, I., Rasool, H. F., Raza, S., Basavaraju, D., Abdullah, R. M., ... & Hajjaj, M. (2023). Advancements in percutaneous coronary intervention techniques: a comprehensive literature review of mixed studies and practice guidelines. *Cureus*, 15(7).
- [25] Tan, K., Sulke, N., Taub, N., & Sowton, E. (1995). Clinical and lesion morphologic determinants of coronary angioplasty success and complications: current experience. *Journal of the American College of Cardiology*, 25(4), 855-865.

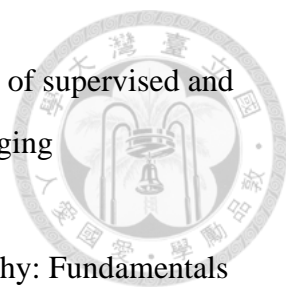
- 
- [26] Hoffmann, R., Mintz, G. S., Popma, J. J., Satler, L. F., Kent, K. M., Pichard, A. D., & Leon, M. B. (1998). Treatment of calcified coronary lesions with Palmaz–Schatz stents: An intravascular ultrasound study. *European heart journal*, 19(8), 1224-1231.
- [27] Nobuyoshi, M., Kimura, T., Ohishi, H., Horiuchi, H., Nosaka, H., Hamasaki, N., ... & Kim, K. (1991). Restenosis after percutaneous transluminal coronary angioplasty: pathologic observations in 20 patients. *Journal of the American College of Cardiology*, 17(2), 433-439.
- [28] Doi, H., Maehara, A., Mintz, G. S., Yu, A., Wang, H., Mandinov, L., ... & Stone, G. W. (2009). Impact of post-intervention minimal stent area on 9-month follow-up patency of paclitaxel-eluting stents: an integrated intravascular ultrasound analysis from the TAXUS IV, V, and VI and TAXUS ATLAS Workhorse, Long Lesion, and Direct Stent Trials. *JACC: Cardiovascular Interventions*, 2(12), 1269-1275.
- [29] Wang, X., Matsumura, M., Mintz, G. S., Lee, T., Zhang, W., Cao, Y., ... & Maehara, A. (2017). In vivo calcium detection by comparing optical coherence tomography, intravascular ultrasound, and angiography. *JACC: Cardiovascular Imaging*, 10(8), 869-879.
- [30] Ryan, T. J. Guidelines for percutaneous transluminal coronary angioplasty: A report of the American College of Cardiology/ American Heart Association Task Force on assessment of diagnostic and therapeutic cardiovascular procedures (subcommittee on percutaneous transluminal coronary angioplasty). *J. Am. Coll. Cardiol.* 12(2), 529–545 (1988).
- [31] Bangalore, S., Vlachos, H. A., Selzer, F., Wilensky, R. L., Kip, K. E., Williams, D. O., & Faxon, D. P. (2011). Percutaneous coronary intervention of moderate to severe calcified coronary lesions: insights from the National Heart, Lung, and Blood Institute Dynamic Registry. *Catheterization and Cardiovascular Interventions*, 77(1), 22-28.
- [32] Moussa, I., Ellis, S. G., Jones, M., Kereiakes, D. J., McMartin, D., Rutherford, B., ... & Stone, G. W. (2005). Impact of coronary culprit lesion calcium in patients

- 
- undergoing paclitaxel-eluting stent implantation (a TAXUS-IV sub study). *The American journal of cardiology*, 96(9), 1242-1247.
- [33] Farag, M., Costopoulos, C., Gorog, D. A., Prasad, A., & Srinivasan, M. (2016). Treatment of calcified coronary artery lesions. *Expert review of cardiovascular therapy*, 14(6), 683-690.
- [34] Kawaguchi, R., Tsurugaya, H., Hoshizaki, H., Toyama, T., Oshima, S., & Taniguchi, K. (2008). Impact of lesion calcification on clinical and angiographic outcome after sirolimus-eluting stent implantation in real-world patients. *Cardiovascular Revascularization Medicine*, 9(1), 2-8.
- [35] Mehanna, E., Abbott, J. D., & Bezerra, H. G. (2018). Optimizing percutaneous coronary intervention in calcified lesions: insights from optical coherence tomography of atherectomy. *Circulation: Cardiovascular Interventions*, 11(5), e006813.
- [36] Kubo, T., Tanaka, A., Kitabata, H., Ino, Y., Tanimoto, T., & Akasaka, T. (2012). Application of optical coherence tomography in percutaneous coronary intervention. *Circulation Journal*, 76(9), 2076-2083.
- [37] Prati, F., Di Vito, L., Biondi-Zoccai, G., Occhipinti, M., La Manna, A., Tamburino, C., ... & Albertucci, M. (2012). Angiography alone versus angiography plus optical coherence tomography to guide decision-making during percutaneous coronary intervention: the Centro per la Lotta contro l'Infarto-Optimisation of Percutaneous Coronary Intervention (CLI-OPCI) study. *EuroIntervention*, 8(7), 823-829.
- [38] Lu, H., Gargsha, M., Wang, Z., Chamie, D., Attizzani, G. F., Kanaya, T., ... & Wilson, D. L. (2012). Automatic stent detection in intravascular OCT images using bagged decision trees. *Biomedical optics express*, 3(11), 2809-2824.
- [39] Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234-241). Cham: Springer international publishing.

- 
- [40] Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T., & Ronneberger, O. (2016, October). 3D U-Net: learning dense volumetric segmentation from sparse annotation. In International conference on medical image computing and computer-assisted intervention (pp. 424-432). Cham: Springer International Publishing.
- [41] Wang, Z., Kyono, H., Bezerra, H. G., Wang, H., Gargsha, M., Alraies, C., ... & Rollins, A. M. (2010). Semiautomatic segmentation and quantification of calcified plaques in intracoronary optical coherence tomography images. *Journal of biomedical optics*, 15(6), 061711-061711.
- [42] Ughi, G. J., Adriaenssens, T., Sinnaeve, P., Desmet, W., & D'hooge, J. (2013). Automated tissue characterization of in vivo atherosclerotic plaques by intravascular optical coherence tomography images. *Biomedical optics express*, 4(7), 1014-1030.
- [43] Athanasiou, L. S., Bourantas, C. V., Rigas, G., Sakellarios, A. I., Exarchos, T. P., Siogkas, P. K., ... & Fotiadis, D. I. (2014). Methodology for fully automated segmentation and plaque characterization in intracoronary optical coherence tomography images. *Journal of biomedical optics*, 19(2), 026009-026009.
- [44] Huang, Y., He, C., Wang, J., Miao, Y., Zhu, T., Zhou, P., & Li, Z. (2018). Intravascular optical coherence tomography image segmentation based on support vector machine algorithm. *MCB Molecular and Cellular Biomechanics*, 15(2), 117-125.
- [45] Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 39(12), 2481-2495.
- [46] Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. In *Proceedings of the European conference on computer vision (ECCV)* (pp. 801-818).
- [47] Gharaibeh, Y., Prabhu, D., Kolluru, C., Lee, J., Zimin, V., Bezerra, H., & Wilson, D. (2019). Coronary calcification segmentation in intravascular OCT images using

- 
- deep learning: application to calcification scoring. *Journal of Medical Imaging*, 6(4), 045002-045002.
- [48] Lee, J., Prabhu, D., Kolluru, C., Gharaibeh, Y., Zimin, V. N., Bezerra, H. G., & Wilson, D. L. (2019). Automated plaque characterization using deep learning on coronary intravascular optical coherence tomographic images. *Biomedical optics express*, 10(12), 6497-6515.
- [49] Gessert, N., Lutz, M., Heyder, M., Latus, S., Leistner, D. M., Abdelwahed, Y. S., & Schlaefler, A. (2018). Automatic plaque detection in IVOCT pullbacks using convolutional neural networks. *IEEE transactions on medical imaging*, 38(2), 426-434.
- [50] He, C., Wang, J., Yin, Y., & Li, Z. (2020). Automated classification of coronary plaque calcification in OCT pullbacks with 3D deep neural networks. *Journal of Biomedical Optics*, 25(9), 095003-095003.
- [51] Lee, J., Gharaibeh, Y., Kolluru, C., Zimin, V. N., Dallan, L. A. P., Kim, J. N., ... & Wilson, D. L. (2020). Segmentation of coronary calcified plaque in intravascular OCT images using a two-step deep learning approach. *IEEE Access*, 8, 225581-225593.
- [52] Chu, M., Jia, H., Gutierrez-Chico, J. L., Maehara, A., Ali, Z. A., Zeng, X., ... & Tu, S. (2021). Artificial intelligence and optical coherence tomography for the automatic characterisation of human atherosclerotic plaques: AI and OCT for plaque characterisation. *EuroIntervention*, 2023, 17(1), 41.
- [53] Wang, Z., Zheng, J., Jiang, P., & Gao, D. (2023). Sk-Conv and SPP-based UNet for lesion segmentation of coronary optical coherence tomography. *Technology and Health Care*, 31(1_suppl), 347-355.
- [54] Liu, Y., Nezami, F. R., & Edelman, E. R. (2024). A Transformer-based pyramid network for coronary calcified plaque segmentation in intravascular optical coherence tomography images. *Computerized Medical Imaging and Graphics*, 113, 102347.

- 
- [55] Oord, A. V. D., Li, Y., & Vinyals, O. (2018). Representation learning with contrastive predictive coding. arXiv preprint arXiv:1807.03748.
- [56] Chen, T., Kornblith, S., Norouzi, M., & Hinton, G. (2020, November). A simple framework for contrastive learning of visual representations. In International conference on machine learning (pp. 1597-1607). PmLR.
- [57] Wang, X., Zhang, R., Shen, C., Kong, T., & Li, L. (2021). Dense contrastive learning for self-supervised visual pre-training. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 3024-3033).
- [58] Alonso, I., Sabater, A., Ferstl, D., Montesano, L., & Murillo, A. C. (2021). Semi-supervised semantic segmentation with pixel-level contrastive learning from a class-wise memory bank. In Proceedings of the IEEE/CVF international conference on computer vision (pp. 8219-8228).
- [59] Khosla, P., Teterwak, P., Wang, C., Sarna, A., Tian, Y., Isola, P., ... & Krishnan, D. (2020). Supervised contrastive learning. *Advances in neural information processing systems*, 33, 18661-18673.
- [60] Lee, C. E., Chung, M., & Shin, Y. G. (2022). Voxel-level siamese representation learning for abdominal multi-organ segmentation. *Computer methods and programs in biomedicine*, 213, 106547.
- [61] 鄭宇傑 (2022) 。冠狀動脈光學同調斷層掃描影像深度學習斑塊診斷模型之建構。碩士論文，國立臺灣大學醫學院暨工學院醫學工程學系研究所。
- [62] Gong, P., Almasian, M., Van Soest, G., De Bruin, D. M., Van Leeuwen, T. G., Sampson, D. D., & Faber, D. J. (2020). Parametric imaging of attenuation by optical coherence tomography: review of models, methods, and clinical translation. *Journal of biomedical optics*, 25(4), 040901-040901.
- [63] Prati, F., Jenkins, M. W., Di Giorgio, A., & Rollins, A. M. (2011). Intracoronary optical coherence tomography, basic theory and image acquisition techniques. *The international journal of cardiovascular imaging*, 27(2), 251-258.
- [64] Dice, L. R. (1945). Measures of the amount of ecologic association between species. *Ecology*, 26(3), 297-302.

- 
- [65] Espis, A., Marzi, C., & Diciotti, S. (2025). Comparative analysis of supervised and self-supervised learning with small and imbalanced medical imaging datasets. *Scientific Reports*, 15(1), 32345.
- [66] Subban, V., & Raffel, O. C. (2020). Optical coherence tomography: Fundamentals and clinical utility. *Cardiovascular Diagnosis and Therapy*, 10(5), 1389.
- [67] Kurogi, K., Ishii, M., Ikebe, S., Kaichi, R., Takae, M., Mori, T., ... & Tsujita, K. (2023). Calcium evaluation using coronary computed tomography in combination with optical coherence tomography. *The International Journal of Cardiovascular Imaging*, 39(9), 1815- 1824.
- [68] Huang, Z., Sun, J., Shao, Y., Wang, Z., Wang, S., Li, Q., ... & Yu, Q. (2024). PolarFormer: a transformer-based method for multi-lesion segmentation in intravascular OCT. *IEEE Transactions on Medical Imaging*, 43(12), 4190-4199.

附錄

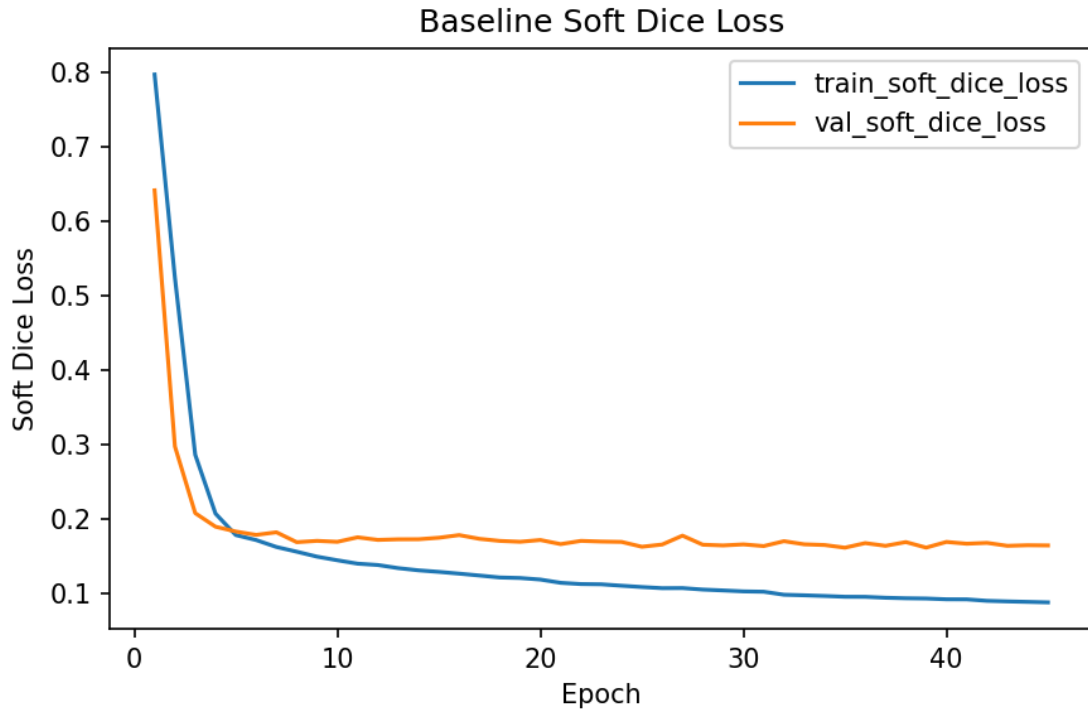


圖 34 Dice Loss 之收斂曲綫




圖 35 訓練過程中驗證集多指標走勢




圖 36 hard negative 之來源比例曲線

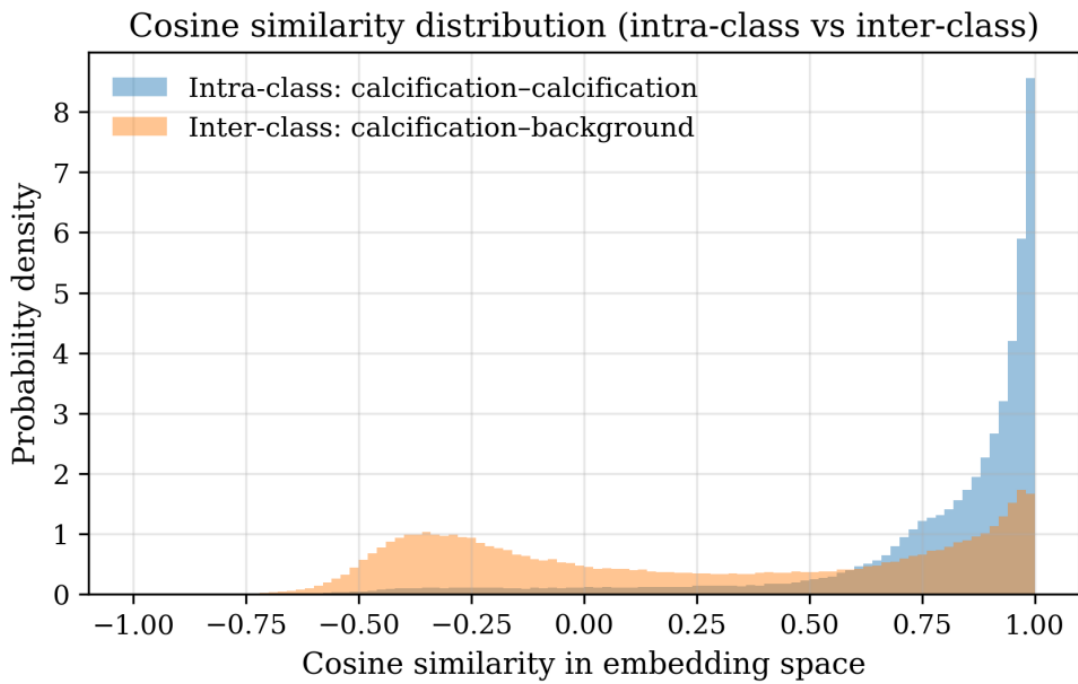


圖 37 邊界帶狀背景定義下之類間餘弦相似度分布直方圖



Cosine similarity distribution (intra-class vs inter-class)




圖 38 困難背景定義下之類間餘弦相似度分布直方圖