

人工智慧半監督式數位病理影像分割方法

AI-based Semi-supervised Semantic Segmentation Method for Digital Pathology Images

邱建毓、詹寶珠

Chien-Yu Chiou, Pau-Choo Chung

數位掃描器取得的數位病理影像，能讓病理醫師檢視患者體內組織，對疾病診斷十分重要。本文介紹多倍率異質性 AI 模型，從不同角度擷取更完整病理特徵，提高偵測準確率；搭配異質性模型交互監督機制產生無標註影像的偽標籤，減少訓練需要的病理標註數量。在肝癌與大腸癌病理影像上，本文方法準確率超過其他半監督式學習方法。

Digital pathological images acquired by digital scanners allow pathologists to directly examine tissues within patients, which is crucial for disease diagnosis. This paper introduces a multi-magnification heterogeneous pathology AI model to extract more complete pathological features from different perspectives, improving detection accuracy. Combined with a heterogeneous model cross supervision mechanism, pseudo-labels are generated for unlabeled images, reducing the number of pathological annotations required for training. In liver cancer and colorectal cancer pathological images, the accuracy of this method outperforms other semi-supervised learning methods.

一、AI 激起的病理影像診斷新思維

醫師在診斷疾病時，時常會仰賴病理組織切片的判讀。醫師會擷取病患一小塊患病區域的器官組織，製作成病理組織切片，再使用高倍率的顯微鏡或數位病理掃描器取得數位病理影像。不同於電腦斷層 (computed tomography, CT) 與核磁共振 (magnetic resonance imaging, MRI) 影像，數位病理影像由於能讓病理醫師可以直接觀察到患者體內組織細胞層級的外觀，對疾病的診斷十分重要，同時也經常成為癌症最終確定診斷的標準。

目前病理影像的診斷仍然大幅仰賴醫師在顯微鏡下，在不同倍率間，觀察影像在不同解析度視野下之影像結構，以判別疾病狀態。病理醫師在觀察病變區域時，會同時考慮低倍率影像中不同病理組織之間的關聯與差異，以及高倍率影像中細胞的紋理與排列。如圖 1(b)

所示，在低倍率的病理影像中，可以看見病變 (如腫瘤) 區域呈現與周圍其他組織不同的外觀病理特徵；而如圖 1(c) 所示，在高倍率的病理影像中，可以看見腫瘤區域的大顆腫瘤細胞呈現混亂而密集的排列。其過程一般會非常耗時，對於需要計算量化數據之情況，則更需仰賴醫師經驗以估計其量化數據，不僅非常耗時，也高度仰賴醫師經驗。




圖 1. 不同倍率病理影像，黑色方框表示放大區域。(a) 全幅影像。(b) 低倍率病理影像可見病理組織之間關聯。(c) 高倍率影像可見細胞紋理。

近年來 AI 興起，利用 AI 來協助診斷乃開始受到普遍重視。基於深度學習的病理 AI 模型可以協助偵測病變組織區域、分析病理影像病徵，並計算各項病理量化指標，提供醫師診斷時的輔助參考資訊。其中精準分割出影像中的腫瘤區域，對病理醫師診斷與後續在腫瘤區域內進行分析均十分重要。為了準確辨識腫瘤區域，病理 AI 模型需要同時考量不同倍率病理影像的病理特徵。此外，由於病理影像尺寸十分巨大，長寬通常超過一萬像素，病理醫師標註訓練用資料十分耗時。如何能充分利用無標註的病理影像資料，減少病理醫師標註訓練資料的負擔，也是 AI 在病理影像分析中十分重要的研究議題。在本文接下來的章節，將分別介紹結合多倍率病理影像，提升病理 AI 模型的準確度，以及利用半監督式學習，減少訓練病理 AI 模型需要使用的病理標註數量。本文相關研究成果發表於⁽¹⁻³⁾。

二、結合不同倍率病理影像提升病理 AI 模型準確率

如同前一章節提到的，病理醫師進行診斷時，會來回切換不同倍率檢視病理影像，以大視野範圍的低倍率觀察病理組織的關聯與差異，以及以小視野範圍的高倍率確認細胞的紋理與排列，同時考量不同倍率下觀察到的病理特徵，能更精確地辨識腫瘤區域。因此病理 AI 模型若能有效從不同倍率與視野範圍的病理影像中，擷取更完整的病理特徵資訊，應能提升模型準確率。

由於全幅數位病理影像 (whole slide images, WSI) 尺寸巨大，受限於記憶體空間，無法以病理 AI 模型直接分析整張 WSI，需要切成 patch 分別處理後再整合分析結果。為了讓模型能夠取得細胞層級與組織層級的更完整病理特徵資訊，常見作法是在切 patch 時，以同一個中心位置，同時擷取具有局部細胞細節資訊的高倍率病理影像 patch X^c ，以及大範圍組織關聯資訊的低倍率病理影像 patch X^l ，以兩張相同位置不同倍率與視野範圍的 patch 作為模型的影像輸入。

為了能有效擷取高倍率病理影像中擷取細胞紋理資訊與低倍率病理影像中擷取組織關聯資訊，並整合完整的病理特徵提高偵測準確率。我們提出了多倍率影像異質模型，如圖 2 所示。模型分為兩個不同架構的子模型 MSUnetFusion 與 MSUSegFormer，每個子模型各有一條 Local Encoder E^L 與 Global Encoder E^G ，分別擷取高倍率病理影像 patch X_i^c 的細胞層級病理特徵與低倍率病理影像 patch X_i^t 的組織層級病理特徵。

子模型的 Local Encoder E^L 在 X^c 上擷取模型多階層不同 layer 的細胞層級病理特徵 F^c ：

$$F^c = \{F_i^c\}_{i=1}^n = E^L(X^c) \quad (1)$$

其中 i 表示 Local Encoder 的不同層 layer。同樣地，子模型的 Global Encoder E^G 在 X^t 上擷取模型多階層不同 layer 的組織層級病理特徵 F^t ：

$$F^t = \{F_j^t\}_{j=1}^m = E^G(X^t) \quad (2)$$

其中 j 表示 Global Encoder 的不同層 layer。

融合兩個不同倍率影像的特徵，便可以讓病理 AI 模型在進行影像分割時能同時考慮高倍率影像的細胞紋理特徵與低倍率影像的組織關聯特徵。然而兩張 patch 的影像倍率不同，每個像素對應到原 WSI 的座標也不相同，Local Encoder 的高倍率影像特徵圖與 Global Encoder 的低倍率影像特徵圖在 patch 坐標系上相同位置像素的特徵，表示的是原 WSI 坐標系上不同位置像素的特徵，不能直接相加或串接。高倍率影像 patch 在原 WSI 上對應到低倍率影像 patch 的中間區域，因此，我們可以使用特徵中央融合模組 (feature center fusion)，取得 Global Encoder 低倍率影像特徵圖對應高倍率影像位置的中央區域，與 Local Encoder 最後一層 layer 的特徵 F_n^t 融合得到融合特徵 $\hat{F}_n^c$ ，如圖 2(c) 所示。

首先 Global Encoder 每一層 layer 的特徵 F_j^t ，會先使用中央特徵裁切模組 (feature center cop, FCC($\cdot$))，裁切對應高倍率影像範圍的中央區域。假設高倍率影像與低倍率影像的倍率比例為 s (例如：高倍率影像為 10 倍放大倍率，低倍率影像為 2.5 倍放大倍率，則 $s = 4$)， F_j^t 特徵圖的尺寸為 $h \times w$ ，則 F_j^t 特徵圖中央中心點 $(h/2, w/2)$ ，尺寸為 $h/s \times w/s$ 的區域，對應到高倍率影像的範圍，以 FCC($\cdot$) 裁切此範圍的特徵圖，得到 $\hat{F}_j^{t\text{-cf}}$ ：

$$\hat{F}_j^{t\text{-cf}} = \text{FCC}(\text{MLP}(F_j^t)) \forall j \quad (3)$$

接著將 Global Encoder 不同層 layer 中央區域的特徵圖 $\hat{F}_j^{t\text{-cf}}$ 上採樣縮放至與 Local Encoder 最後一層 layer 特徵圖 F_n^t 相同大小後串接得到 $\hat{F}^{t\text{-cf}}$ ：

$$\hat{F}^{t\text{-cf}} = \text{Concat}\left(\left\{\text{Upsample}(F_j^t)\right\}_{j=1}^m\right) \quad (4)$$

將 $\hat{F}^{t\text{-cf}}$ 與 F_n^t 融合可得到同時具有組織層級與細胞層級病理特徵的融合特徵 F_n^c ：

$$\hat{F}_n^c = \text{MLP}\left(\text{Concat}(F_n^t, \hat{F}^{t\text{-cf}})\right) \quad (5)$$




圖 2. 結合多倍率異質性模型交互監督的半監督式數位病理影像分割方法示意圖。

最後每個子模型的 U-Net-based Decoder G 整合 Local Encoder 不同層 layer 的特徵 F_i^t 與融合特徵 $\hat{F}_n^c$ ，產生腫瘤區域的影像分割 P^c ：

$$P^c = G\left(\text{Concat}(\{F_i^t\}_{i=1}^{n-1}, \hat{F}_n^c)\right) \quad (6)$$

除此之外，不同模型架構的具有不同能力，例如 CNN 架構模型擅長學習局部區域的紋理，而 Transformer 架構的全局注意力機制則能夠擷取全局的關聯。考量前述處理低倍率影像的 Global Encoder E^G 需要在中央區域擷取到周圍區域的全局組織關聯，因此 Global Encoder E^G 採用 Transformer 架構模型，而 Local Encoder E^L 則分別使用 CNN 架構模型與 Transformer 架構模型，分別組成子模型 MSUNetFusion 與 MSUSegFormer，讓兩個子模型能夠從不同視角分析病理影像。

三、利用半監督式學習減少訓練所需病理標註資料量

為了減少病理醫師準備訓練模型用的病理標註所需的時間，常見作法是利用半監督式學習⁽⁴⁻⁵⁾進行訓練。半監督式學習的訓練資料集包含少量的有標註資料集 D^l 與數量較多的無標註資料集 D^u ，通常會基於模型預測結果產生無標註資料的偽標註，再使用偽標註來計算無標註病理影像的損失函數，利用數量較多的無標註病理影像增加訓練資料量，減少訓練所需的標註資料量。

令 P_F^c 與 P_S^c 分別為本文介紹的 MSUNetFusion 與 MSUSegFormer 兩個子模型的腫瘤分割預測遮罩 (也就是分別以 MSUNetFusion 與 MSUSegFormer 使用 Eq. 6 取得的 P^c)，有標註的

病理影像以監督式學習計算損失函數 L_{SUP} ：

$$L_{\text{SUP}} = \frac{1}{|D^l|} \sum_{X^c, X^l, Y \in D^l} (l_{\text{CE}}(\mathbf{P}_F^c, Y^c) + l_{\text{CE}}(\mathbf{P}_S^c, Y^c)) \quad (7)$$

其中 Y^c 是高倍率病理影像 patch 對應範圍的影像分割標註。

而對於無標註病理影像，使用兩個子模型的分割預測遮罩產生偽標註 $\hat{Y}_F^c$ 與 $\hat{Y}_S^c$ 如下：

$$\hat{Y}_F^c = \arg \max(\mathbf{P}_F^c) \quad (8)$$

$$\hat{Y}_S^c = \arg \max(\mathbf{P}_S^c) \quad (9)$$

傳統半監督式學習常碰到的問題是偽標籤可能出錯，模型使用自己產生的錯誤偽標籤訓練，會學習錯誤的預測而影響模型準確率。為了解決這個問題，我們基於交互監督⁽⁴⁾ 提出了異質性模型交互監督的機制，讓異質性架構的兩個子模型互相使用對方產生的偽標籤計算損失函數。由於兩個子模型的架構不同，會從不同的視角分析輸入的病理影像，不容易同時發生相同錯誤，可以提升偽標註訓練無標註病理影像的可靠性。損失函數 L_{CS} 計算如下：

$$L_{\text{CS}} = \frac{1}{|D^u|} \sum_{X^c, X^l \in D^u} (l_{\text{CE}}(\mathbf{P}_F^c, \hat{Y}_S^c) + l_{\text{CE}}(\mathbf{P}_S^c, \hat{Y}_F^c)) \quad (10)$$

最後的損失函數 L 計算如下：

$$L = L_{\text{SUP}} + \lambda L_{\text{CS}} \quad (11)$$

其中 $\lambda (= 1)$ 是調整無標註影像訓練權重的超參數。藉由異質性模型進行交互監督的半監督式學習，可以有效而可靠地利用數量較多的無標註病理影像，減少訓練模型所需的病理標註資料量。

四、實驗結果

1. 實驗設置

本文中使用原發性肝癌 (liver hepatocellular carcinoma, HCC) 與大腸癌 (colorectal cancer, CRC) 的數位病理影像資料集驗證本文介紹的方法效果，並與其他半監督式學習方法進行比較。實驗經過成大醫院與高雄榮總的人體研究倫理審查委員會審查通過，並免除當事人知情同意。以回溯性收案方式蒐集成功大學醫學院附設醫院與高雄榮民總醫院去識別化的病理影像。病理切片採常規蘇木精－伊紅染色 (hematoxylin and eosin stain, H&E) 凸顯細胞與組織分布，用 Leica Aperio AT2 掃描器以 40 倍掃描成數位病理影像，並由專業病理醫師標註腫瘤區域。

肝癌資料集包含共 129 張全幅數位病理影像 (whole slide images, WSI)，隨機切分為 75 張 WSI 的訓練資料集，14 張 WSI 的驗證資料集，與 40 張 WSI 的測試資料集。大腸癌資料集共包含 65 張 WSI，隨機切分為 45 張 WSI 的訓練資料集，5 張 WSI 的驗證資料集，以及 15 張 WSI 的測試資料集。實驗以半監督式學習進行，僅使用一部分比例 WSI 的病理標註，其餘 WSI 以無標註方式用於訓練。模型準確率使用 Intersection-over-Union (IoU) 計算，採三輪固定資料切分但不同隨機種子訓練的平均與標準差。

由於 WSI 尺寸巨大，可達數萬像素，會切成多倍率影像 patch 進行訓練與測試。多倍率影像 patch 的擷取以高倍率的細胞層級影像為主，在高倍率下每隔 512 像素不重疊取一張 512×512 像素尺寸的 patch，並在低倍率下以相同中心點取一張 512×512 像素尺寸的 patch。測試時直接將每張 patch 的預測結果作為原 WSI 對應區域的預測結果。肝癌資料集細胞層級與組織層級的多倍率影像分別縮放到 10 倍與 1.25 倍的倍率，總計約有 175,000 張 patch，大腸癌資料集細胞層級與組織層級的多倍率影像則分別縮放到 10 倍與 2.5 倍的倍率，總計約有 63,000 張 patch。

其他方法的實驗分為兩個部分，一個部分是使用既有的半監督式學習方法，訓練單倍率影像模型，另一個部分是使用既有的半監督式學習方法訓練本文說明的多倍率影像模型。單倍率影像模型使用前述多倍率影像 patch 的高倍率 patch 部分進行訓練與測試。除了要進行比較的半監督式學習方法與模型不同之外，所有實驗均採用相同設定，使用帶動量的 SGD 優化器，初始 learning rate 設為 0.01，動量 (momentum) 設為 0.9，採用多項式學習率衰減策略 (Poly Learning Rate Policy, $(1-(\text{iter}/\text{maxiter}))^{0.9}$)。Batch size 設為 18，肝癌資料集訓練 15 epoch，大腸癌資料集訓練 20 epoch。偽標籤均使用 hard label，本文介紹的方法與 CPS⁽⁴⁾ 均未使用 confidence threshold 與 warm-up，UniMatch⁽⁵⁾ 使用 confidence threshold 0.95 過濾偽標籤，且前 1,000 個 batch iteration 作為 warm-up 不使用偽標籤。

2. 腫瘤區域分割結果量化比較

本文介紹的方法與其他半監督式學習方法的腫瘤區域語意分割結果，模型準確率的量化比較如表 1 與表 2 所示。表 1 呈現肝癌資料集的語意分割結果比較，本文方法比較僅使用有標註 WSI 訓練的監督式學習 (supervised)，以及兩個半監督式學習方法 CPS⁽⁴⁾ 與 UniMatch⁽⁵⁾，實驗分別使用不同比例數量的 WSI 標註。首先如表 1 第三列所示，由於 Supervised 方法僅使用少量有標註的 WSI 進行訓練，模型準確率較低，且隨著使用的 WSI 數量減少，IoU 會快速下降，如第四到七欄所示。而半監督式學習方法利用模型產生無標註影像的偽標註，可以利用更多影像訓練模型，增加模型學習到的資料，因此相較於 Supervised 方法能大幅提升準確率，如表 1 第四列與第五列所示。而我們提出的方法，利用 CNN 與 Transformer 的異質性模型架構處理不同倍率的病理影像，並且進行交互監督，讓模型能擷取病理影像中更完整的病理特徵，因此相較於其他半監督式學習方法，能更進一步提升模型準確率，如表 1 第八列所示。此外，由於本文方法的多倍率異質模型交互監督，能更全面擷取病理特徵，因此僅需少量標註資料 (3 張 WSI)，即可達到接近 Supervised 使用全部 75 張 WSI 標註的準確率。

表 1. 肝癌病理影像腫瘤區域語意分割結果比較。

		Label Data Ratio	1/25 (3 WSIs)	1/15 (5 WSIs)	1/8 (10 WSIs)	1/4 (20 WSIs)	1 75 WSIs
S	Method	Model	IoU	IoU	IoU	IoU	IoU
S	Supervised	Unet	67.8±1.2	74.0±0.3	78.7±0.8	82.2±1.1	86.3±0.5
	CPS ⁽⁴⁾		75.3±3.0	78.8±1.0	83.0±0.8	85.2±0.2	
	UniMatch ⁽⁵⁾		82.0±0.8	80.8±0.2	83.7±0.6	84.3±1.8	
M	Supervised	MSUnet	77.2±1.5	80.5±0.9	84.1±0.9	86.5±0.7	88.3±0.2
	UniMatch ⁽⁵⁾		88.1±0.9	87.9±0.3	88.1±0.8	88.2±2.5	
	MSCS (Ours)		87.7±1.4	88.5±0.4	89.3±0.4	89.7±0.5	
S	Supervised	Seg-Former	73.1±0.6	77.6±1.1	80.5±0.2	84.2±0.5	87.7±0.3
	CPS ⁽⁴⁾		76.8±1.2	81.3±0.5	81.8±0.5	85.0±0.4	
	UniMatch ⁽⁵⁾		82.1±0.5	81.9±0.9	83.2±1.4	86.5±0.5	
M	Supervised	MS-Useg-Former	77.5±1.0	80.9±1.2	85.2±0.2	87.0±0.6	88.7±0.4
	UniMatch ⁽⁵⁾		85.3±2.1	85.6±1.7	87.3±2.3	88.8±0.1	
	MSCS (Ours)		87.6±1.2	88.7±0.1	89.0±0.6	89.8±0.4	

表 2. 大腸癌病理影像腫瘤區域語意分割結果比較。

		Label Data ratio	1/22 (2 WSIs)	1/9 (5 WSIs)	1/4 (10 WSIs)
S	Method	Model	IoU	IoU	IoU
S	Supervised	Unet	60.4±0.9	68.9±1.5	72.3±0.9
	CPS ⁽⁴⁾		69.1±0.5	74.3±1.6	75.7±0.3
	UniMatch ⁽⁵⁾		72.0±0.6	73.0±1.6	75.3±0.6
M	Supervised	MSUnet	60.1±3.6	71.5±0.4	75.3±0.2
	UniMatch ⁽⁵⁾		76.9±0.9	78.9±0.2	78.0±1.6
	MSCS (Ours)		77.5±0.3	78.9±0.3	79.4±0.2
S	Supervised	Seg-Former	56.4±1.9	67.3±4.1	74.6±0.4
	CPS ⁽⁴⁾		57.9±1.2	75.1±0.3	76.4±0.3
	UniMatch ⁽⁵⁾		67.9±4.0	75.9±0.9	77.3±0.3
M	Supervised	MS-Useg-Former	61.4±3.3	72.3±1.0	75.7±0.4
	UniMatch ⁽⁵⁾		75.4±5.3	78.8±0.2	79.0±0.2
	MSCS (Ours)		77.9±0.4	79.0±0.4	79.7±0.1

同時我們並比較使用單倍率影像與多倍率影像的差異，在第一欄以 S 表示單倍率影像，M 表示使用多倍率影像。如表 1 第六列所示，Supervised 方法利用本文介紹的多倍率影像異質模型，結合高倍率影像的細胞紋理特徵與低倍率影像的組織關聯特徵，能更完整表示腫瘤區域的病理特徵，因此相較於表 1 第三列僅使用單倍率影像，使用多倍率影像異質模型




圖 3. 腫瘤區域分割結果比較。奇數列呈現全幅影像，偶數列呈現放大區域的影像，全幅影像上的紅框為放大區域。(a) 原圖。(b) GT。(c) CPS⁽⁴⁾。(d) UniMatch⁽⁵⁾。(e) 我們的方法。

的效能大幅提升。此外，由於本文方法的異質模型交互監督機制，利用兩個不同架構的模型，從不同視角產生無標註影像的偽標註，能有效降低偽標註錯誤的影響。因此如表 1 第 13 與第 14 列所示，同樣使用多倍率影像模型進行訓練，本文方法準確率仍高於其他半監督式學習方法。

大腸癌病理影像的腫瘤區域分割結果如表 2 所示。肝臟病理切片通常呈現一整塊肝臟組織，原發性肝癌的腫瘤區域常見整塊與周圍組織明顯不同的細胞密集區域。與之相對，大腸病理切片可能包含多個腺體與不規則絨毛，腫瘤區域可能分散在不同腺體區域，且有時腫瘤區域外觀與正常組織外觀差異較不明顯。因此，表 2 中所有方法大腸癌腫瘤區域的分割準確率相較於肝癌均有下降。然而本文方法利用多倍率異質模型進行交互監督，除了能更全面結合高倍率細胞細節與低倍率組織關聯的資訊，並能提升偽標註的穩定性與準確率。因此本文方法的腫瘤區域分割準確率高於監督式學習與其他半監督式學習模型的準確率，如表 2 所示。在肝臟與大腸病理影像的測試結果，顯示本文方法相較預期他半監督式學習方法，能更全面擷取病理特徵，並更有效利用無標註影像，提升模型準確率。

3. 腫瘤區域分割結果質化比較

圖 3 比較不同方法的腫瘤區域分割的視覺化結果圖。圖 3 第一列與第二列的肝癌案例，右側整塊腫瘤區域與左側正常組織區域有明顯外觀差異，腫瘤區域細胞密集而雜亂排列。因此所有方法均能完整分割出整塊肝癌腫瘤區域，僅在邊緣交界處與腫瘤區域內間質有少量誤判。而圖 3 第三列與第四列的肝癌影像，左側腫瘤區域外觀與右側正常組織區域的細胞外觀差異較小，僅使用高倍率影像較難以分辨，因此其他半監督式學習方法在腫瘤區域內部出現大量誤判為正常組織。而本文方法採用多倍率異質模型，採用能尋找全局相關性的 Transformer 架構擷取低倍率病理影像中大範圍的組織關聯特徵，搭配 CNN 學習高倍率病理影像的局部細胞紋理特徵，因此能有效分辨腫瘤區域與正常組織區域。最後一個案例是大腸癌病理影像，如圖 3 第五與第六列所示。由於大腸病理影像中有大量不規則皺褶與絨毛，細胞排列較為雜亂，與腫瘤區域差異較不明顯，因此如圖 3 第六列放大圖的左側與右下角，其他半監督式學習方法將許多正常的絨毛組織誤判為腫瘤區域。而本文提出的多倍率異質模型能取得較大範圍的組織關聯特徵，搭配異質性模型交互監督機制，提升偽標籤的可靠性與穩定性，因此模型僅在左上角腫瘤區域邊緣將少許正常組織誤判為腫瘤區域，而能成功辨識出左下角與右下角的正常組織區域。從圖 3 不同方法的腫瘤區域分割的視覺化結果圖比較，可以看見本文方法的多倍率影像異質模型與異質性模型交互監督機制，讓模型能更精確辨識腫瘤區域與正常組織區域。

五、結論

病理組織切片以顯微鏡或數位病理掃描器取得的數位病理影像，可以讓病理醫師直接觀察患者體內組織與細胞的外觀，對疾病的診斷十分重要。病理 AI 模型可以輔助病理醫師分析尺寸巨大的數位病理影像，並提供客觀的量化分析做為診斷的輔助參考資訊。為了提升病理 AI 模型偵測腫瘤區域的準確率，並減少訓練需要的病理標註資料，本文介紹結合多倍率異質性模型交互監督的半監督式數位病理影像分割方法。本方法結合 CNN 架構與 Transformer 架構的異質性模型，從高倍率與低倍率病理影像中擷取更完整病理特徵，並透過異質性模型的交互監督機制，互相產生可靠的偽標註，有效利用無標註影像資料。因此在肝癌與大腸癌病理影像資料集，本文介紹的方法均能比其他半監督式學習方法訓練的模型取得更精準的腫瘤區域分割結果。未來本文方法腫瘤區域的偵測結果，除了可以提供病理醫師作為疾病診斷的參考，也可作為後續進階分析的前處理。

參考文獻

1. Tsung-Lung Yang *et al.*, *Artificial Intelligence in Medicine*, **125**, 102244 (2022).
2. Chia Wei Chao *et al.*, *IEEE Computational Intelligence Magazine*, **18** (3), 54 (2023).
3. Min-En Hsieh, Chien-Yu Chiou, Hung-Wen Tsai, Yu-Cheng Chang, Pau-Choo Chung, *IEEE Transactions on Artificial Intelligence*, **5** (12), 6356 (2024).
4. Xiaokang Chen, Yuhui Yuan, Gang Zeng, Jingdong Wang, in Proc. IEEE/CVF Conf. *Computer Vision and Pattern Recognition*, 2613 (2021).
5. Lihe Yang, Lei Qi, Litong Feng, Wayne Zhang, Yinghuan Shi,” in Proc. IEEE/CVF Conf., *Computer Vision and Pattern Recognition*, 7236 (2023).

作者簡介

邱建毓先生為國立成功大學電機研究所博士，現為國立中正大學電機系助理教授。

Chien-Yu Chiou received his Ph.D. in Electrical Engineering from National Cheng Kung University. He is currently an Assistant Professor in the Department of Electrical Engineering at National Chung Cheng University.

詹寶珠女士為美國德州理工大學電機研究所博士，現為國立成功大學電機系特聘教授。

英文簡介

Pau-Choo Chung received her Ph.D. in Electrical Engineering from Texas Tech University, Texas, USA. She is currently a Distinguished Professor in the Department of Electrical Engineering at National Cheng Kung University.