

张宇茜. 面向乳腺超声图像分割的半监督伪标签像素分类自集成网络[J]. 智能计算机与应用, 2025, 15(10): 1-9. DOI: 10.20169/j. issn. 2095-2163. 25032602

面向乳腺超声图像分割的半监督伪标签像素分类自集成网络

张宇茜

(山西大学 计算机与信息技术学院, 太原 030006)

摘 要: 乳腺超声图像的精准分割对于乳腺癌的早期诊断具有重要意义。尽管基于全监督学习的神经网络模型在乳腺超声图像分割领域取得了一定的进展, 但对标注数据的依赖限制了全监督模型的应用。为此, 提出一种伪标签像素级分类自集成网络(Pseudo-label Pixel Classification Self-integrated Network, P²CS-Net)。P²CS-Net 利用交叉双监督网络机制, 通过 2 个并行的分割网络生成差异性伪标签, 在训练过程中使伪标签逐渐趋于一致。同时通过计算伪标签像素间的交叉熵及设置阈值获取低置信度像素集, 并应用噪声转移矩阵对这些像素进行噪声建模及矫正, 有效挖掘了其中潜在的语义信息。此外, 将迭代训练过程中的伪标签基于指数平均移动方法进行自集成, 进一步增强了模型对语义信息的利用。在 3 个公开的乳腺超声图像数据集上对 P²CS-Net 进行了实验验证, 结果表明, 仅有 20%~30% 的标注数据参与训练时, P²CS-Net 就能够显著超越现有的半监督学习方法。此外, 即便标注数据有限, P²CS-Net 也能实现与全监督算法相媲美的性能, 充分证明了其在乳腺超声图像分割任务中的有效性和鲁棒性。

关键词: 乳腺超声图像分割; 像素分类; 伪标签矫正; 自集成; 半监督学习

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2025)10-0001-09

P²CS-Net: Semi-supervised pseudo-label pixel classification self-ensemble network for breast ultrasound image segmentation

ZHANG Yuxi

(School of Computer and Information Technology, Shanxi University, Taiyuan 030006, China)

Abstract: Accurate segmentation of breast ultrasound images plays a crucial role in the early detection of breast cancer. Although fully supervised models have achieved notable success in breast ultrasound image segmentation, their performance is contingent upon the availability of a large volume of annotated data, which has limited the generalization of deep neural networks. To overcome this limitation, a Pseudo-label Pixel Classification Self-integrated Network (P²CS-Net) based on semi-supervised learning is proposed. P²CS-Net introduces a cross pseudo supervision that leverages the strengths of two parallel yet initially uncorrelated segmentation networks. These two networks are trained concurrently to generate a diverse set of pseudo-labels, then progressively harmonized through a training process driven by consistency. By computing the cross-entropy between pseudo-labels, the model can identify low-confidence pixels. After that, noise transfer matrix is used to assist in noise modeling for low-confidence pixels. The semantic information in these easily overlooked pixels is extracted and refined through the process described above, and P²CS-Net improves the overall accuracy of segmentation. In addition, P²CS-Net self-integrates pseudo-labels by utilizing an exponential moving average method. This approach further improves the model's capacity to utilize semantic information while improving the pseudo-labels. Three publicly available datasets of breast ultrasound images are used to conduct a comprehensive experimental evaluation of P²CS-Net. The experimental results show that the P²CS-Net algorithm performs well in various indicators compared to other semi-supervised learning ultrasound segmentation methods, even with a training set that contained only 20% to 30% annotated data. Furthermore, P²CS-Net performs comparably to classical fully supervised medical image segmentation algorithms, even though it was only trained on a small amount of annotated data. The experimental results mentioned above demonstrate the reliability and effectiveness of P²CS-Net for segmenting breast ultrasound images.

Key words: breast ultrasound image segmentation; pixel classification; pseudo-label correction; self-integration; semi-supervised learning

基金项目: 国家自然科学基金面上项目(62276160)。

作者简介: 张宇茜(2000—), 女, 硕士研究生, 主要研究方向: 图像处理。Email: 202222407065@email.sxu.edu.cn。

收稿日期: 2025-03-26

哈尔滨工业大学主办 ◆ 学术研究与应用

0 引言

目前,根据世界卫生组织国际癌症研究机构发布的数据显示,乳腺癌已成为女性发病率与致死率最高的疾病^[1],因此乳腺癌的早期防治具有重大意义。而乳腺超声成像由于其无创性、无放射性成为乳腺癌早期防治的主要手段之一^[2-3]。使用计算机辅助乳腺超声图像分割可以帮助医生准确识别病灶区域,是一种提高乳腺癌诊断效率的重要手段^[4-5]。早期的乳腺超声图像分割方法主要依赖手工提取的图像特征,如基于阈值、基于分水岭等方法^[6],但大多都难以获得准确的分割结果。

近年来,深度卷积神经网络的发展极大地推动了乳腺超声图像分割的研究进步^[7]。Ronneberger等学者^[8-9]提出 U-Net 架构,由于其独特的编码器-解码器架构和跳跃连接,有效提高了分割任务中的特征传播和边缘检测能力。在 U-Net 之后,相继提出了基于编解码器结构的多种改进模型^[10],以适应乳腺超声图像的特点。Shareef 等学者^[11]提出的 STAN 网络通过改进特征融合机制,有效地整合了不同尺度的特征信息,尤其在小肿瘤分割任务中展现了优异的性能。Ning 等学者^[12]提出了一种形态感知网络,通过结合乳腺超声图像中的低级和高级特征生成显著图,有效地提升了网络分割性能和鲁棒性。

全监督模型在乳腺超声图像分割任务中虽性能优异,但依赖高成本的数据标注。由于乳腺超声图像含有多种背景噪声、肿瘤边缘模糊、对比度低及患者个体差异显著,导致手动标注耗时且昂贵,限制了模型泛化能力和性能提升。为解决这一问题,半监督学习成为有效策略。通过结合有监督和无监督学习,利用少量标注数据和大量无标注数据训练模型,减少人工干预,缓解数据标注压力^[13-15],已成为医学图像分割领域的重要研究方向^[16]。

在医学图像分割领域,研究者们已经开发出多种有效的基于半监督学习的网络架构。Huang 等学者^[17]等人提出一种深度主动学习框架,通过特征聚类和图像熵技术精选初始标记集,结合医生标注与未标注数据训练模型,获得了与全监督模型相近的分割性能。Xu 等学者^[18]采用学生-教师网络架构提出 SCO-SSL 方法,通过最小化两个网络的输出一致性损失实现正则化,在标注数据占比仅 20% 时仍展现出良好性能。郭敏等学者^[19]提出 TCA-Net,融合注意力机制,通过在学生模型的概率映射与教师

模型的伪标签之间添加一致性约束,有效提升了分割性能。

半监督学习方法在医学图像分割领域展现出巨大潜力,但面临诸多挑战。结合先验知识的方法虽能提高模型理解能力,但不完全的先验可能导致错误信息;一致性半监督学习,如 SCO-SSL 与 TCA-Net,通过正则化利用未标注数据结构,但未标注数据的噪声可能影响模型性能,且模型复杂度较高^[20]。

带有伪标签的半监督学习方法可以很好地克服这些限制,在减少对完全标注数据依赖的同时,避免了先验知识偏差和未标注数据噪声的不利影响,为医学图像分割领域开辟了新的研究方向和应用潜力。然而,在带有伪标签的半监督学习方法中,基于有限标注数据训练的模型可能无法完全捕捉数据分布,导致生成的伪标签含有噪声,进而影响模型的训练稳定性^[21]。针对这一挑战,Guo 等学者^[22]提出了一种联合类亲和分割框架,结合像素级和成对级亲和关系对伪标签的部分高置信度像素进行噪声抑制,配合类亲和损失矫正策略,进一步提升模型分割精度与鲁棒性。此外,Shi 等学者^[23]提出一种创新的保守-激进复合网络架构,其中保守网络倾向于将像素分类为背景,而激进网络则倾向于分类为前景。对于无标注数据,该方法将 2 个网络共同预测的交集区域即高置信度像素用来生成伪标签。尽管这些方法在处理伪标签噪声方面取得了进展,但却只关注了伪标签中被认为是高置信度的部分,而忽略了低置信度像素中同样有价值的语义信息^[24]。

在带有伪标签的半监督学习中,伪标签的质量同样会对后续模型的训练产生重要影响。Yao 等学者^[25]为提高伪标签质量,提出置信度感知交叉双监督网络架构,通过傅里叶变换和 KL 散度优化提升伪标签质量,在医学图像分割任务中表现了良好的泛化性。Li 等学者^[26]通过引入由简单线性迭代聚类 (SLIC) 算法^[27]得到的超像素图,对伪标签加以进一步细化^[28]来获得置信度更高的伪标签进行后续训练。Wang 等学者^[29]添加了一个信任模块来重新评估模型输出中的伪标签,并设置阈值来选择置信度更高的伪标签。以上方法虽然提高了伪标签的质量,但每次迭代训练的最终伪标签与标注数据合并进行单次训练后便被抛弃,导致潜在有用语义信息一同丢失。

针对伪标签语义信息利用不足的问题,本文提出了一种新颖的伪标签像素级分类自集成网络 (P²CS-Net)。该方法首先利用初始分割模型训练

不充分的特性,生成有差异的伪标签并对其进行像素分类,改进以往只关注高置信度像素的不足。对于低置信度像素,通过噪声转移矩阵进行伪标签矫正来挖掘并利用这些像素中的潜在语义信息。然后,将矫正后的低置信度像素与高置信度像素级联融合,生成新的伪标签。接着,将这个新生成的伪标签与上一轮迭代的最终伪标签进行自集成,以此增强模型对语义信息的捕捉能力。通过上述过程, $P^2CS-Net$ 能够有效地整合伪标签中丰富的语义信息,最终生成准确的分割结果。

1 本文方法

本文提出了一种伪标签像素级分类自集成方法 (Pseudo-Label Pixel Classification Self-Integrated Network, $P^2CS-Net$), 其整体框架如图 1 所示。该方法包括有监督学习部分与无监督学习部分, 采用 ResNet50 作为基线网络。有监督学习部分接受少量带标注数据作为输入, 由基线网络输出相应预测

结果, 计算预测输出与输入数据相应标注的损失 L_s , 进行有监督训练, 得到初始分割模型 f 。无监督学习部分将 f 复制得到 f_1 和 f_2 作为分割网络, 接受大量无标注数据作为输入, 输出伪标签 P_1^i 和 P_2^i 。本文设计像素级分类及矫正策略 (Pixel Level Classification and Correction Strategy, PLCC), 对 P_1^i 和 P_2^i 进行像素分类, 得到高置信度像素集 A_{hc} 与低置信度像素集 A_{lc} , 对 A_{lc} 通过噪声转移矩阵进行矫正, 矫正后的低置信度像素集 A'_{lc} 与高置信度像素集 A_{hc} 进行级联融合得到融合后的伪标签。此外, 本文还设计了基于 EMA 的伪标签自集成策略 (EMA-based Pseudo-label self-integration Strategy, EPS), 将融合后的伪标签 \hat{Z}_i^i 与前一次迭代训练中的最终伪标签进行自集成后得到当前次迭代训练的最终伪标签 Z_i^i , 接着与原超声图像进行数据合并继续迭代, 在迭代训练中不断更新分割网络, 获得最终的分割结果。

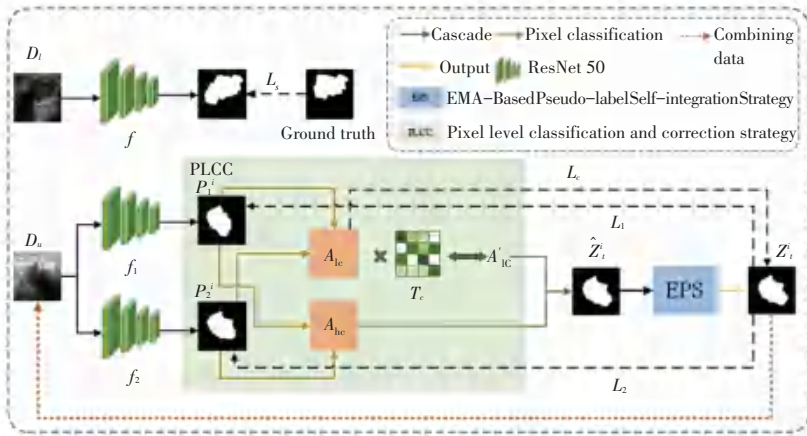


图 1 $P^2CS-Net$ 整体架构

Fig. 1 Diagram of $P^2CS-Net$ network structure

1.1 概述

定义带标注数据集 $D_l = \{(x_l^i, y_l^i)\}$ 以及无标注数据集 $D_u = \{(x_u^i, y_u^i)\}$, 有标注数据 D_l 首先作为输入进行有监督训练, 定义有监督学习部分输出为 $f(x_l^i; \theta)$, 其中 $f(\cdot)$ 为分割模型, 即初始分割模型。对于每个带标注图像, 本文采用交叉熵损失函数作为有监督学习部分的目标函数, 定义公式为:

$$L_s = \frac{1}{|D_l|} \sum_{(x_l^i, y_l^i) \in D_l} l_{ce}(f(x_l^i; \theta), y_l^i) \quad (1)$$

其中, y_l^i 表示第 i 张带标注图像的真实掩码。

交叉双监督网络机制 (Cross Pseudo Supervision, CPS) [30] 在自然图像半监督语义分割任务中

表现良好。该机制使用 2 个分割网络, 通过添加约束使得 2 个模型产生相互一致的输出, 这一过程不仅增强了网络对未标注数据的预测能力, 并且能够生成高质量的伪标签, 进而优化网络模型。

本文采用 CPS 网络机制, 复制初始分割模型得到 $f_1(\cdot)$ 和 $f_2(\cdot)$ 作为无监督部分的 2 个分割网络, 均接受无标注的数据集 D_u 作为输入, 输出预测结果 $f_1(x_u^i; \theta)$ 和 $f_2(x_u^i; \theta)$, 即 P_1^i 和 P_2^i 。并且由于初始分割模型由少量带标注数据训练得到, 因此 P_1^i 和 P_2^i 是 2 个具有差异的预测输出。

对于每个无标注数据, 无监督损失 L_u 包括 2 部分, 即通过 2 个分割模型 $f_1(\cdot)$ 和 $f_2(\cdot)$ 生成的预测

输出 P_1^i 和 P_2^i , 与对应图像的最终伪标签计算损失值 L_1, L_2 , 具体公式如下:

$$L_1 = \frac{1}{|D_u|} \sum_{(x_u^i, P_1^i) \in D_u} l_{ce}(f_1(x_u^i; \theta), Z_l^i) \quad (2)$$

$$L_2 = \frac{1}{|D_u|} \sum_{(x_u^i, P_2^i) \in D_u} l_{ce}(f_2(x_u^i; \theta), Z_l^i) \quad (3)$$

$$L_u = L_1 + L_2 \quad (4)$$

其中, Z_l^i 表示第 i 个无标注图像的最终伪标签。使用对比损失 L_c 来充分利用低置信度像素, 可由下式计算得到:

$$L_c = -\frac{1}{C \times M} \sum_{c=0}^{C-1} \sum_{i=1}^M \log \frac{e^{\langle a_{ci}, a_{ci}^+ \rangle / \tau}}{e^{\langle a_{ci}, a_{ci}^+ \rangle / \tau} + e^{\langle a_{ci}, a_{ci}^- \rangle / \tau}} \quad (5)$$

其中, M 表示低置信度像素集中像素的总数; C 表示低置信度像素集中像素属于的类别、即背景区域或病灶区域; a_{ci} 表示类别 c 的第 i 个像素; a_{ci}^+ 和 a_{ci}^- 分别表示第 i 个像素的正样本与负样本; $\langle \cdot, \cdot \rangle$ 表示像素特征之间的余弦相似性, 其范围限制在 -1 到 $+1$ 之间; τ 表示对比损失中的温度超参数, 本文设置 $\tau = 0.5$ 。

因此本文总体的损失函数计算公式具体如下:

$$L = L_s + L_u + L_c \quad (6)$$

1.2 伪标签像素分类及矫正策略

在传统的伪标签矫正方法中, 研究者们主要集中于高置信度像素, 而往往忽视了低置信度像素中蕴含的丰富语义信息。低置信度像素示例如图 2 所示, 由于乳腺超声图像中的噪声和阴影, 某些像素 (如十字标识的位置) 在归类为肿块或背景时存在不确定性, 即被视为低置信度。这些像素实际上对于精确地分割出病灶边缘极为关键。针对这一问题, 本文设计像素级分类及矫正策略 (Pixel Level Classification and Correction strategy, PLCC), 旨在更有效地挖掘和利用低置信度像素中的潜在信息。

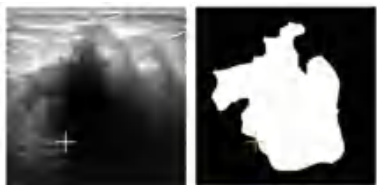


图 2 低置信度像素示例

Fig. 2 Example of low confidence pixel

本文将着重挖掘伪标签中低置信度像素对预测结果的影响。由 2 个分割模型 $f_1(\cdot)$ 、 $f_2(\cdot)$ 得到的预测输出 P_1^i 和 P_2^i , 即伪标签, 计算 2 个伪标签中每个像素的概率分布交叉熵对其进行像素级分类, 交

叉熵 $H(\cdot)$ 计算公式为:

$$H(p_1, p_2) = - \sum_{x \in P_1^i} p_1(x) \log(p_2(x)) \quad (7)$$

其中, x 表示伪标签中的像素, $p_1(x)$ 、 $p_2(x)$ 分别表示 P_1^i 和 P_2^i 中像素 x 的概率分布。

然后, 对交叉熵设置阈值 ∂_i 进行伪标签像素级分类, 将交叉熵小于阈值的像素归为高置信度像素集 A_{hc} , 反之则为低置信度像素集 A_{lc} , 计算公式如下:

$$y_{ij} = \begin{cases} y_{ij} \in A_{hc}, & \text{if } H(p_1, p_2) < \partial_i \\ y_{ij} \in A_{lc}, & \text{otherwise} \end{cases} \quad (8)$$

其中, y_{ij} 表示第 j 个伪标签在位置 i 处的像素。设置初始阈值 $\partial_0 = 0.3$, 并且在训练过程中, 伪标签逐渐趋于准确^[24], 因此本文使用线性策略来调整阈值的大小, 即:

$$\partial_t = \partial_0 \cdot \left(1 - \frac{E - t}{E}\right) \quad (9)$$

其中, E 表示当前迭代训练次数, t 表示迭代训练预设总次数。

通过上述过程, P_1^i 和 P_2^i 中的像素被分为 2 组, 即高置信度像素集与低置信度像素集。其中, 高置信度像素集包括 2 个预测输出中具有高度一致性的像素, 直接用作生成伪标签。相对地, 低置信度像素集则包括预测结果间差异显著的像素, 这一集合不仅包含了那些归属不明确的像素, 也包括了噪声引起的误差, 进而影响模型的分割性能^[31]。

在医学图像分割领域, 像素级噪声标签的处理尚未得到充分的研究和利用^[32]。应用噪声转移矩阵 (Noise Transfer Matrix, NTM)^[33-34] 是现有解决方案中的一种有效方法。NTM 的核心思想在于模拟标签噪声的传播模式建模, 并通过建立好的模型对像素级噪声标签进行矫正。该方法有助于提升分割模型的鲁棒性, 并增强了模型对目标区域的准确分割能力。

本文为了更有效地利用像素级分类后的低置信度像素集 A_{lc} , 使用 NTM 矩阵 $T_M(m, n)$ 对 A_{lc} 进行噪声建模及矫正。其建模过程可用下式来描述:

$$p(\hat{A}_{lc} = n) = \sum_{m=1}^M p(A_{lc} = m) \cdot T_M(m, n) \quad (10)$$

其中, $p(\hat{A}_{lc} = n)$ 表示 A_{lc} 中的像素 m 通过 NTM 从当前类别转换为另一个类别, 即转换为噪声 n 的预测概率; \hat{A}_{lc} 表示 A_{lc} 经过 NTM 进行建模得到的噪声分布; $p(A_{lc})$ 表示 A_{lc} 中像素 m 的概率分布。

接着, 利用建模好的噪声分布 \hat{A}_{lc} 对 A_{lc} 中的像

素 m 进行矫正,其矫正损失函数定义公式如下:

$$L_N = - \sum_m \hat{A}_{lc}(n) \log[p(A_{lc} = m) T_M] \quad (11)$$

经过上述过程得到矫正后的低置信度像素集

\hat{A}_{lc}' , 将 \hat{A}_{lc}' 与高置信度像素集 A_{hc} 级联融合得到 Z_t^i , 进行后续的伪标签自集成过程。

1.3 伪标签自集成策略

在传统的带有伪标签的半监督学习中,每次迭代后生成的伪标签在数据合并后通常立即被舍弃。然而这些伪标签往往蕴含着丰富的语义信息可供模型进一步学习^[26]。

指数平均移动 (Exponential Moving Average, EMA)^[35] 是一种可以给予最近数据更高权重的平均方法,能够更快速地反映数据最近的变化趋势,有助于减少训练过程中的噪声,提高模型的泛化能力。

因此,为了更深入地挖掘并利用被抛弃的潜在语义信息,本文提出一种基于 EMA 的伪标签自集成策略 (EMA - based Pseudo - label Self - integration strategy, EPS)。该策略将迭代过程中产生的伪标签通过指数平均移动机制进行整合,而非直接丢弃,实现对这些伪标签中蕴含的语义信息的充分利用,提高模型分割性能的目的。

首先,在第 t 次迭代训练中,通过 PLCC 得到伪标签 \hat{Z}_t^i , 然后将其与第 $t - 1$ 次迭代训练中的最终伪标签 Z_{t-1}^i 通过 EPS 策略进行加权融合,更新最终伪标签 Z_t^i , 其更新过程如下式所示:

$$Z_t^i = \omega Z_{t-1}^i + (1 - \tilde{\omega}) \hat{Z}_t^i \quad (12)$$

其中, ω 表示集成过程中伪标签的权重, Z_t^i 初始化为零矩阵。 ω 的值随着迭代训练次数的增加而动态地减小,直到接近常数 1。因此,随着训练过程的继续,靠后生成的伪标签所占权重逐渐加大,伪标签的准确度也随之不断增加。

在每次迭代中,将经过自集成策略优化的伪标签与原始超声图像数据合并,以此作为下一次迭代训练的输入。这一过程重复进行,直到满足预设的迭代次数或迭代停止条件。在最终迭代完成后,所产生的伪标签即为乳腺超声图像的分割结果。

2 实验结果与分析

2.1 实验设置

本文使用 3 个公开的乳腺超声图像数据集 Dataset BUSI^[36]、Dataset B^[37] 和 Dataset C^[38] 进行实

验验证。Dataset BUSI 收集了 600 名 25~75 岁的女性患者乳腺超声图像共 730 张,其中包括 487 张恶性病变图像、110 张良性病变图像以及 133 张正常超声图像,图像平均大小为 500×500 像素。Dataset B 包含不同患者的乳腺超声图像共 163 张,包括 110 张良性病变图像以及 53 张恶性病变图像,图像平均大小为 760×570 像素。Dataset C 包含乳腺超声图像共 320 张,其中包括 160 张良性病变图像以及 160 张恶性病变图像,图像平均大小为 128×128 像素。由于本文的目标是从乳腺超声图像中进行肿块区域的分割,因此将 Dataset BUSI 中 130 张正常的图像予以删除,最终 Dataset BUSI 共 647 张图像进行后续的实验。

在本实验中,对图像数据及其对应的真实掩码进行了尺寸调整,统一裁剪至 224×224 像素。此外,由于医学图像数据集规模较小,为增强模型的泛化能力,采用数据增广技术。具体而言,对每张图像数据施加了逆时针 90° 和 180° 的旋转操作,并对旋转后得到的图像及其原图执行了镜像翻转。通过这些方法,有效扩充了 3 个数据集的规模,为后续实验提供了更丰富的训练样本。

本文实验使用 Pytorch 1.11.0 为基本框架,使用一张型号为 NVIDIA GeForce RTX 4090 的显卡进行训练,使用 Adam 优化方法进行优化,实验中 batch size 设置为 16。初始学习率设置为 $\eta = 10^{-3}$,为节约模型收敛时间,学习率按照如下规则进行衰减:若实验中 10 次迭代训练后优化目标函数值未发生改善,则学习率下降 0.9 倍;若 20 次迭代训练后优化目标函数值未发生改善,则停止训练。实验采用 5 倍交叉验证进行,迭代训练最大值设置为 200 次。本文模型部署及后续对比实验与消融实验均在上述设置下进行。

为验证 P²CS-Net 的有效性,在与半监督算法和全监督算法的对比实验以及消融实验中使用骰子系数 (Dice) 以及杰卡德相似系数 (Jaccard Index, JI)^[39] 作为评价指标;在数据集定量测试中使用骰子系数 (Dice) 作为评价指标。其中, Dice 表示实际和预测分割结果重叠的程度,杰卡德相似系数表示实际和预测分割结果之间的相似性。所有的评价指标均以均值的形式进行表示,计算公式具体如下:

$$\text{Dice} = \frac{2(\text{pre} \cap \text{act})}{(\text{pre} \cup \text{act})} \quad (13)$$

$$\text{JI} = \left| \frac{\text{pre} \cap \text{act}}{\text{pre} \cup \text{act}} \right| \quad (14)$$

其中, pre 表示迭代训练停止时的最终伪标签、即分割结果, act 表示乳腺超声图像对应的真实标注。

2.2 与其他半监督方法对比实验

为说明本文提出的 P²CS-Net 在半监督乳腺超声图像分割任务中的优势, 本文选择 2 个半监督超声图像分割模型 SABR^[40] 以及 SCO-SSL 进行对比实验, 部分分割结果对比如图 3 所示。

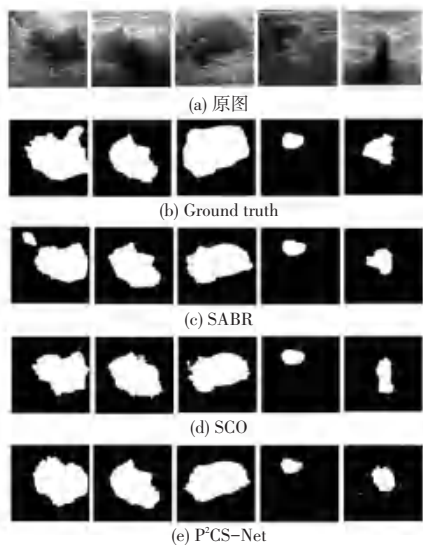


图 3 不同半监督方法分割结果对比

Fig. 3 Comparison of segmentation results of different semi-supervised learning algorithms

SCO-SSL 通过阴影增强与丢弃机制处理阴影伪影, 但因细节信息处理不足, 导致病灶区域边缘分割效果欠佳。SABR 结合 Transformer 设计阴影掩盖模块, 提升了模型对边缘信息的细化能力, 边缘分割更为清晰, 但阴影掩盖模块模拟超声图像阴影生成自适应掩码时, 易引入误分割问题。P²CS-Net 利用 2 个分割网络生成伪标签互相监督, 充分挖掘语义信息, 实现了更准确的边缘分割且避免了误分割。不过, 对于伪影严重的超声图像, P²CS-Net 生成的伪标签噪声较大, 影响了网络对边缘信息的准确提取, 进而影响分割精度和结果完整性。

P²CS-Net 与其他半监督模型在 3 个数据集上的定量对比结果见表 1。根据表 1 中结果可知, P²CS-Net 各评价指标在 Dataset C 上提升最为显著, 最多达到了 4.48% 和 2.50%。在 Dataset B 上, P²CS-Net 获得了 3 个数据集中最高的 Dice 和 JI, 分别为 85.32% 与 75.39%, 其提升效果同样显著, 分别最多提升了 3.04% 和 2.82%。在 Dataset BUSI 上, P²CS-Net 的 Dice 值和 JI 值分别达到 84.52% 和 75.19%, 最多提升了 3.9% 和 2.66%。

表 1 不同半监督方法在 3 个数据集上的结果

Table 1 Results of different semi-supervised algorithms on three datasets

Dataset	Method	Dice	JI
Dataset BUSI	SCO-SSL	80.62	72.53
	SABR	82.16	73.72
	P ² CS-Net	84.52	75.19
Dataset B	SCO-SSL	82.28	72.57
	SABR	83.53	73.83
	P ² CS-Net	85.32	75.39
Dataset C	SCO-SSL	79.31	70.71
	SABR	82.14	71.69
	P ² CS-Net	83.79	73.21

2.3 全监督方法对比实验

为进一步验证本文网络架构的有效性, 以及充分展示 P²CS-Net 的潜力, 本节将 P²CS-Net 与 5 种经典全监督医学图像分割网络进行对比分析, 其分割结果对比如图 4 所示。

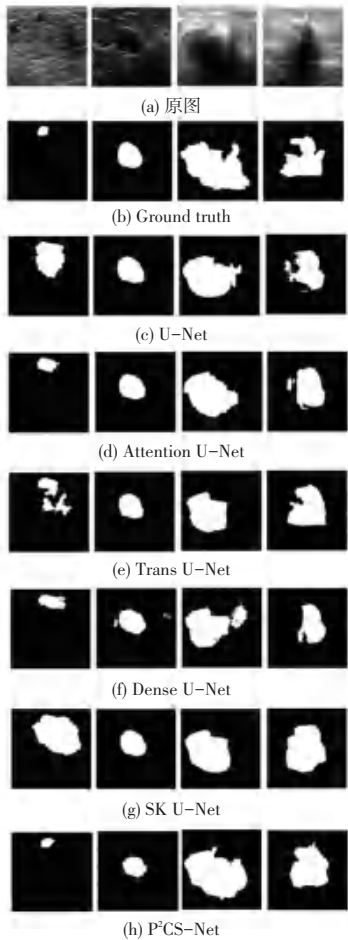


图 4 不同全监督方法分割结果对比

Fig. 4 Comparison of segmentation results of different fully supervised model

U-Net 通过跳跃连接融合浅层语义信息, 有效改善梯度消失和特征损失问题。Trans U-Net 结合

Transformer 和 U-Net 架构,利用自注意力机制增强特征提取能力,捕捉全局上下文信息,但细节信息丢失导致边缘分割精度不足。Attention U-Net 在跳跃连接中引入注意力机制,提升对目标区域的关注度,但在小目标和伪影区域分割效果有限。Dense U-Net 采用密集块代替传统卷积块,加强全局信息整合,但局部特征处理易产生冗余信息。SK U-Net 在编码器中添加挤压和激励残差模块,在解码器中引入选择性内核模块,有效抑制冗余特征,但在小目标分割中抑制不足。P²CS-Net 作为一种半监督学习方法,在乳腺超声图像分割任务中展现出了与全监督模型相当、甚至更佳的分割性能。然而,在 Dataset BUSI 和 Dataset B 中,由于超声图像分割目标大小不一,伪标签矫正过程未能充分消除噪声影响,导致 P²CS-Net 的分割结果不够完整。

P²CS-Net 与经典全监督模型在 3 个数据集上的定量对比结果见表 2。根据表 2 中结果可知,在 Dataset BUSI 上,尽管 P²CS-Net 的 Dice 略低于 Trans U-Net,但差距并不明显、仅为 0.28%,并且 JI 至少提升了 2.04%。在 Dataset C 上,相较其他全监督方法各评价指标至少提升了 3.08%和 1.89%,这一结果凸显了 P²CS-Net 在该数据集上的显著优势。在 Dataset B 上 P²CS-Net 相较大多数全监督算法表现出了显著优势,提升效果明显,尽管 Dice 较 Trans U-Net 低 0.59%,JI 低 0.23%,但差异并不明显。

表 2 不同全监督方法在 3 个数据集上的结果

Table 2 Results of different fully supervised algorithms on three datasets

Dataset	Method	Dice	JI
Dataset BUSI	U-Net	75.45	64.38
	Trans U-Net	84.80	73.15
	Attention U-Net	75.09	65.42
	Dense U-Net	71.15	64.05
	SK U-Net	76.35	66.64
	P ² CS-Net	84.52	75.19
Dataset B	U-Net	77.83	68.66
	Trans U-Net	85.91	76.52
	Attention U-Net	76.01	67.93
	Dense U-Net	71.37	62.37
	SK U-Net	78.15	70.63
	P ² CS-Net	85.32	75.39
Dataset C	U-Net	72.13	63.03
	Trans U-Net	80.71	71.32
	Attention U-Net	75.25	68.72
	Dense U-Net	74.42	65.79
	SK U-Net	75.63	67.91
	P ² CS-Net	83.79	73.21

2.4 消融实验

本节对 P²CS-Net 进行消融实验,来验证本文所提出的每个策略的有效性。消融实验包括以下 2 个对比方法。

(1) PC CPS:PC CPS 通过在交叉双监督网络结构 CPS 中增加像素级分类及矫正策略,充分利用并矫正低置信度像素,将级联融合后的像素集作为最终伪标签进入下一次迭代训练。

(2) SE CPS:SE CPS 直接级联融合 2 个模型生成的伪标签,并与前一次迭代的伪标签自集成,作为当前迭代的最终伪标签。

消融实验部分分割结果如图 5 所示。由图 5 可知,PS CPS 与 SE CPS 因对伪标签语义信息利用不足,分割结果不完整,SE CPS 甚至出现明显误分割。而 P2CS-Net 结合两者优势,充分利用伪标签中的有用信息,获得了更接近 Ground truth 的分割结果。

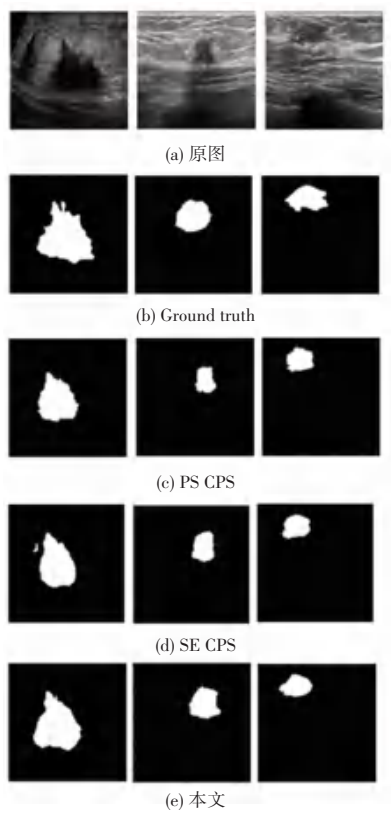


图 5 消融实验分割结果

Fig. 5 Segmentation results of ablation experiments

表 3 为 3 个数据集上的定量消融实验结果。由表 3 中结果可知,本文采用交叉双监督网络机制,结合伪标签像素分类及矫正策略与伪标签自集成策略所提出的分割方法 P²CS-Net,在 3 个数据集上相较另 2 个消融网络各指标均表现出了显著的性能提升,证明了本文所提出的 2 个策略的有效性。

表 3 3 个数据集上的消融实验结果

Table 3 Results of ablation experiments on three datasets %			
Dataset	Method	Dice	Jl
Dataset BUSI	PC CPS	82. 34	72. 98
	SE CPS	79. 65	70. 18
	P ² CS-Net	84. 52	75. 19
Dataset B	PC CPS	84. 15	74. 52
	SE CPS	80. 68	71. 61
	P ² CS-Net	85. 32	75. 39
Dataset C	PC CPS	80. 33	71. 67
	SE CPS	76. 59	66. 91
	P ² CS-Net	83. 79	73. 21

2.5 数据集定量测试

本节实验展示了本文模型在不同带标注数据样本量中的表现。根据 2. 2 节的介绍,本文在训练时需要有差异的伪标签来进行后续的操作,因此将带标注数据量设置在 50% 以下进行实验。具体而言,本文对数据集按以下 5 种比例划分,分别为 10 : 90, 20 : 80, 30 : 70, 40 : 60 及 50 : 50, 监督学习模型采用 ResNet50 作为基线网络,使用 Dice 损失作为评价指标,在 3 个数据集上的实验结果见表 4。

观察表 4 可知, P²CS-Net 在 Dataset BUSI 与 Dataset C 上,数据集中参与有监督学习模型训练的带标注数据占比 20% 时分割效果最佳。而 Dataset B 由于数据规模相对较小,在带标注数据占比 30% 时达到最佳的分割效果。并且可以看出带标注数据占比较大时, Dice 反而更小,这证实了 P²CS-Net 在无监督学习部分利用不准确的分割网络模型生成有差异的伪标签,并且通过 PLCC 与 EPS 对伪标签进行语义信息挖掘的有效性。

表 4 有监督学习数据参与量对比

Table 4 Comparison of supervised learning data participation %			
Dataset	Labeled	Unlabeled	Dice
Dataset BUSI	10	90	82. 61
	20	80	84. 52
	30	70	80. 63
	40	60	75. 68
	50	50	72. 86
Dataset B	10	90	81. 21
	20	80	81. 34
	30	70	85. 32
	40	60	76. 04
	50	50	71. 38
Dataset C	10	90	81. 06
	20	80	83. 79
	30	70	79. 47
	40	60	77. 72
	50	50	70. 41

3 结束语

本文提出了一种用于乳腺超声图像分割的伪标签像素级分类自集成网络 P²CS-Net。该网络聚焦于伪标签中的低置信度像素及迭代训练中被抛弃的伪标签,通过充分利用这些以往被忽视的语义信息,生成更准确的伪标签,从而训练出性能更佳的分割模型。与传统全监督方法相比, P²CS-Net 显著减少了数据标注的时间和人力成本,同时保持了与全监督方法相当的分割性能。此外, P²CS-Net 在与其他半监督方法的对比中展现出优势,通过深入挖掘低置信度像素中的语义信息,并有效利用迭代训练中产生的伪标签,分割性能也得到了明显提升。实验在 3 个公开数据集上验证了该方法的有效性。未来研究将致力于提高伪标签的置信度,以节省模型训练的计算成本并进一步提升分割准确性。

参考文献

[1] SUNG H, FERLAY J, SIEGEL R L, et al. Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. CA: A Cancer Journal for Clinicians, 2021, 71(3): 209-249.

[2] WU Gege, ZHOU Liqiang, XU Jianwei, et al. Artificial intelligence in breast ultrasound[J]. World Journal of Radiology, 2019, 11(2): 19-26.

[3] XIAN Min, ZHANG Yingtao, CHENG H D, et al. Automatic breast ultrasound image segmentation: A survey [J]. Pattern Recognition, 2018, 79: 340-355.

[4] CLEMENT G T, HYNYNEN K. A non-invasive method for focusing ultrasound through the human skull [J]. Physics in Medicine & Biology, 2002, 47(8): 1219-1236.

[5] SAMULSKI M R M, SNOEREN P R, PLATEL B, et al. Computer-aided detection as a decision assistant in chest radiography [C]//Proceedings of Medical Imaging 2011: Image Perception. San Francisco: SPIE, 2011: 338.

[6] AZAD R, AGHDAM E K, RAULAND A, et al. Medical image segmentation review: The success of U-Net [J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2024, 46: 10076-10095.

[7] 郭迎节, 李春树. 乳腺超声图像分割算法研究[J]. 宁夏工程技术, 2024, 23(1): 73-78.

[8] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI 2015). Cham: Springer, 2015: 234-241.

[9] ÇIÇEK Ö, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation [C]//Proceedings of the 19th International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI 2016). Cham: Springer, 2016: 424-432.

[10] 袁琳, 张雨, 丁炎, 等. 基于优化 U-Net 神经网络模型在乳腺肿

- 瘤超声图像分割中的应用[J]. 医学影像学杂志, 2023, 33(6): 1081–1085.
- [11] SHAREEF B, XIAN Min, VAKANSKI A. Stan; Small tumor-aware network for breast ultrasound image segmentation [C]// Proceedings of 2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI). Piscataway, NJ: IEEE, 2020: 1–5.
- [12] NING Zhenyuan, ZHONG Shengzhou, FENG Qianjin, et al. SMU-Net; Saliency-guided morphology-aware U-Net for breast lesion segmentation in ultrasound image [J]. IEEE Transactions on Medical Imaging, 2021, 41(2): 476–490.
- [13] 罗毅恒, 张俊华, 张剑青. 交换标签部分和交叉监督的半监督医学图像分割[J]. 计算机工程与应用, 2025, 61(4): 253–261.
- [14] 李飞翔, 降爱莲. MSMVT: 多尺度和多视图 Transformer 半监督医学图像分割框架[J]. 计算机工程与应用, 2025, 61(2): 273–282.
- [15] 李明漾, 王庆凤, 陈立伟, 等. 基于跨任务一致性的半监督肝脏 CT 图像分割[J]. 计算机技术与发展, 2024, 34(2): 65–70.
- [16] 李才子, 刘瑞强, 司伟鑫, 等. 面向心脏 MRI 分割的半监督空间一致性约束网络[J]. 计算机辅助设计与图形学学报, 2020, 32(7): 1145–1153.
- [17] HUANG Kuan, HUANG Jianhua, WANG Weichen, et al. A deep active learning framework with information guided label generation for medical image segmentation [C]// Proceedings of 2022 IEEE International Conference on Bioinformatics and Biomedicine. Piscataway, NJ: IEEE, 2022: 1562–1567.
- [18] XU Xuannang, SANFORD T, TURKBEBY B, et al. Shadow-consistent semi-supervised learning for prostate ultrasound segmentation[J]. IEEE Transactions on Medical Imaging, 2021, 41(6): 1331–1345.
- [19] 郭敏, 张涵涵, 李阳. 融合注意力的教师互一致性半监督医学图像分割[J]. 计算机工程, 2024, 50(9): 313–323.
- [20] JIAO Rushi, ZHANG Yichi, DING Le, et al. Learning with limited annotations: A survey on deep semi-supervised learning for medical image segmentation[J]. Computers in Biology and Medicine, 2023, 169: 107840.
- [21] LEE D H. Pseudo-label: the simple and efficient semi-supervised learning method for deep neural networks [C]// Proceedings of the Workshop on Challenges in Representation Learning. Cham: Springer, 2013: 896.
- [22] GUO Xiaoqing, YUAN Yixuan. Joint class-affinity loss correction for robust medical image segmentation with noisy labels [C]// Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2022: 588–598.
- [23] SHI Yinghuan, ZHANG Jian, LING Tong, et al. Inconsistency-aware uncertainty estimation for semi-supervised medical image segmentation[J]. IEEE Transactions on Medical Imaging, 2021, 41(3): 608–620.
- [24] WANG Yuchao, WANG Haochen, SHEN Yujun, et al. Semi-supervised semantic segmentation using unreliable pseudo-labels [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2022: 4238–4247.
- [25] YAO Huifeng, HU Xiaowei, LI Xiaomeng. Enhancing pseudo label quality for semi-supervised domain-generalized medical image segmentation [J]. arXiv preprint arXiv, 2201.08657, 2022.
- [26] LI Caizi, DONG Li, DOU Qi, et al. Self-ensembling co-training framework for semi-supervised COVID-19 CT segmentation [J]. IEEE Journal of Biomedical and Health Informatics, 2021, 25(11): 4140–4151.
- [27] ACHANTA R, SHAJI A, SMITH K, et al. SLIC super pixels compared to state-of-the-art super pixel methods [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(11): 2274–2282.
- [28] THOMPSON B H, DI CATERINA G, VOISEY J P. Pseudo-label refinement using super pixels for semi-supervised brain tumor segmentation [C]// Proceedings of 2022 IEEE 19th International Symposium on Biomedical Imaging. Piscataway, NJ: IEEE, 2022: 1–5.
- [29] WANG Xiaoyan, YUAN Yiwen, GUO Dongyan, et al. SSA-Net: Spatial self-attention network for Covid-19 pneumonia infection segmentation with semi-supervised few-shot learning [J]. Medical Image Analysis, 2022, 79: 102459.
- [30] CHEN Xiaokang, YUAN Yuhui, ZENG Gang, et al. Semi supervised semantic segmentation with cross pseudo supervision [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2021: 2613–2622.
- [31] KARIMI D, DOU H, WARFIELD S K, et al. Deep learning with noisy labels: exploring techniques and remedies in medical image analysis [J]. Medical Image Analysis, 2020, 65: 101759.
- [32] SHU Jun, XIE Qi, YI Lixuan, et al. Meta-Weight-Net: learning an explicit mapping for sample weighting [J]. Advances in Neural Information Processing Systems, 2019, 32: 1919–1930.
- [33] GUO Xiaoqing, LIU Jie, LIU Tongliang, et al. Simt; handling open-set noise for domain adaptive semantic segmentation [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2022: 7022–7031.
- [34] GUO Xiaoqing, YANG Chen, LI Baopu, et al. Metacorection; domain-aware meta loss correction for unsupervised domain adaptation in semantic segmentation [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2021: 3926–3935.
- [35] LAINE S, AILA T. Temporal ensembling for semi-supervised learning [J]. arXiv preprint arXiv, 1610.02242, 2016.
- [36] AL-DHABYANI W, GOMAA M, KHALED H, et al. Dataset of breast ultrasound images [J]. Data in Brief, 2020, 28: 104863.
- [37] YAP M H, PONS G, MARTI J, et al. Automated breast ultrasound lesions detection using convolutional neural networks [J]. IEEE Journal of Biomedical and Health Informatics, 2018, 22(4): 1218–1226.
- [38] HUANG Qinghua, HUANG Yonghao, LUO Yaozhong, et al. Segmentation of breast ultrasound image with semantic classification of super pixels [J]. Medical Image Analysis, 2020, 61: 101657.
- [39] BERTELS J, EELBODE T, BERMAN M, et al. Optimizing the dice score and jaccard index for medical image segmentation: theory and practice [C]// Proceedings of the 22nd International Conference on Medical Image Computing and Computer Assisted Intervention (MICCAI 2019). Cham: Springer, 2019: 92.
- [40] CHEN Fang, CHEN Lingyu, KONG Wentao, et al. Deep semi-supervised ultrasound image segmentation by using a shadow aware network with boundary refinement [J]. IEEE Transactions on Medical Imaging, 2023, 42(12): 3779–3793.