

4. Кібербезпека в епоху блокчейну: нові виклики та рішення : монографія / за заг. ред. А. П. Петренка. Київ : Наукова думка, 2025. 245 с.
5. Методи виявлення аномальної активності в децентралізованих мережах : методичні рекомендації / уклад. В. Д. Коваль. Харків : ХНУРЕ, 2024. 32 с.

DOI 10.70286/ISU-15.04.2026.008

ПРОСТОРОВО-АДАПТИВНЕ ЗЛИТТЯ ПСЕВДОМІТОК З ПОПІКСЕЛЬНИМИ КАРТАМИ НЕВИЗНАЧЕНОСТІ ДЛЯ СЛАБОКОНТРОЛЬОВАНОЇ СЕМАНТИЧНОЇ СЕГМЕНТАЦІЇ

Зелений Владислав Євгенович

аспірант

Кафедра комп'ютерних наук

Козловський Андрій Володимирович

к.т.н., доцент

Кафедра комп'ютерних наук

Вінницький національний технічний університет, Україна

Постановка проблеми. Слабоконтрольоване навчання семантичної сегментації (Weakly Supervised Semantic Segmentation, WSSS) дозволяє суттєво зменшити витрати на піксельну розмітку зображень, проте якість псевдоміток, що генеруються лише з міток класів, залишається ключовим обмежуючим фактором. Класичні підходи на основі карт активації класів (CAM, GradCAM) забезпечують лише грубу локалізацію об'єктів і дають усереднену міру перекриття (mIoU) на рівні 30–35% на наборі Oxford-IIIT Pet. Поява моделі сегментації довільних об'єктів Segment Anything Model (SAM) відкрила нові можливості, однак вимагає точних просторових підказок у вигляді обмежувальних рамок, що в постановці зі слабким контролем недоступні. У попередній роботі авторів [1] було досягнуто 78.13% mIoU за рахунок використання еталонних рамок, проте у строгій постановці WSSS такі рамки необхідно отримувати автоматично, що значно ускладнює задачу.

Метою роботи є розробка та експериментальне дослідження методу просторово-адаптивного злиття псевдоміток SAUFusion (Spatially-Adaptive Uncertainty-weighted Fusion), який у строгій постановці WSSS об'єднує кілька незалежних джерел псевдоміток із попiксельними оцінками невизначеності для кожного з них.

Виклад основного матеріалу. Запропонований метод SAUFusion складається з п'яти взаємопов'язаних компонентів: автоматичної генерації просторових підказок для SAM з карти GradCAM; побудови трьох незалежних джерел псевдоміток; обчислення попiксельних карт невизначеності для кожного джерела;

просторово-адаптивного зваженого злиття з гамма-параметризацією; захисного блендування з SAM-маскою та ітеративного самонавчання моделі-студента.

Метод використовує три незалежні джерела псевдоміток: (1) M_CAM — м'яку маску GradCAM, побудовану на основі попередньо навченої мережі ResNet-50; (2) M_SAM — бінарну маску, отриману від моделі SAM (ViT-H) у режимі генерації кількох масок з автоматично згенерованої з CAM рамки; (3) M_stud — прогноз моделі-студента DeepLabV3-ResNet50 з шаром Dropout2d ($p = 0.15$) для оцінювання невизначеності методом MC-Dropout.

Для кожного джерела обчислюється попіксельна карта невизначеності $U_k(x,y) \in [0,1]$: для CAM — як нормована бінарна ентропія активації; для SAM — як нормована попіксельна дисперсія між трьома масками множинного виходу; для моделі-студента — як комбінація епістемічної (дисперсія за $N = 5$ проходками MC-Dropout) та алеаторної (ентропія усередненого передбачення) компонент невизначеності.

Ключова ідея методу — попіксельне злиття трьох джерел з вагами $w_k(x,y) = (1 - U_k(x,y))^\gamma$, де $\gamma \geq 0$ — параметр загострення. Остаточна псевдомітка обчислюється як нормоване зважене середнє $M_fused = \sum_k [w_k \cdot M_k] / \sum_k w_k$. Параметр γ лінійно зростає від 2.0 до 4.0 за п'ять ітерацій самонавчання, що реалізує принцип навчання за зростанням складності.

Для запобігання деградації нижче базового рівня SAM запроваджено механізм захисного блендування: у пікселях, де залишкова невизначеність злиття перевищує 75-й квантиль, результат лінійно притягується до SAM-маски з коефіцієнтом $\alpha = 0.3$. Додатково застосовується ентропійна фільтрація (10% псевдоміток з найвищою невизначеністю замінюються на попередню ітерацію) та фільтр якості на студенті.

Експериментальні результати. Експерименти проведено на повному наборі Oxford-III Pet (3680 зображень). Лише CAM дає 31.08% mIoU, SAM без донавчання з рамками з CAM — 46.01%, наївне злиття SAM+CAM без зважування невизначеністю — 37.09% (погіршення на 8.92%). Запропонований метод SAUFusion підвищує mIoU до 48.03% на третій ітерації самонавчання (+2.02% над SAM) та стабілізується на рівні 47.12% на п'ятій ітерації (+1.11%). Ключовий приріст відбувається саме на третій ітерації, коли у злиття вперше включається модель-студент, що демонструє синергію трьох джерел.




Рис. 1. Крива mIoU за ітераціями самонавчання SAUFusion проти базових рівнів




Рис. 2. Якісні результати: зображення / еталонна маска / GradCAM / злита псевдомітка

Висновки. Запропоновано метод просторово-адаптивного злиття псевдоміток SAUFusion для слабоконтрольованого навчання семантичної сегментації у строгій постановці з мітками класів на рівні зображення. Новизна полягає у переході від однострумковий ентропійного фільтрування до багатоджерельного просторово-адаптивного злиття з попиксельними картами невизначеності, що дозволяє локально-адаптивно поєднувати взаємодоповнювальні джерела: SAM дає чіткі межі, CAM — семантичну прив'язку до класу, а модель-студент — сигнал про протяжні структури об'єктів. Експериментально підтверджено стабільне перевищення базового рівня SAM на +1–2% mIoU без використання будь-яких просторових анотацій. Напрями подальших досліджень включають перевірку методу на наборах PASCAL VOC, COCO, Cityscapes, пошук оптимальної траєкторії параметра γ та розширення набору джерел за рахунок мовно-візуальних моделей (CLIP, GroundingDINO).

Список використаних джерел

1. Зелений В. Є., Козловський А. В. Підвищення точності локалізації в навчанні зі слабким контролем за допомогою базових моделей і уточнення псевдоміток з урахуванням невизначеності. Наука і техніка сьогодні. Серія «Техніка». 2025. № 5(46). URL: <https://perspectives.pp.ua/index.php/nts/article/view/24513>.
2. Selvaraju R. R., Cogswell M., Das A., Vedantam R., Parikh D., Batra D. Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. Proc. IEEE ICCV. Venice, 2017. P. 618–626.
3. Kirillov A., Mintun E., Ravi N., Mao H., Rolland C. et al. Segment Anything. Proc. IEEE/CVF ICCV. Paris, 2023. P. 4015–4026.
4. Gal Y., Ghahramani Z. Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning. Proc. 33rd ICML. New York, 2016. P. 1050–1059.

5. Kendall A., Gal Y. What Uncertainties Do We Need in Bayesian Deep Learning for Computer Vision? *Advances in NeurIPS*. 2017. P. 5574–5584.
6. Parkhi O. M., Vedaldi A., Zisserman A., Jawahar C. V. Cats and Dogs. *Proc. IEEE CVPR*. Providence, 2012. P. 3498–3505.

DIGITAL TRANSFORMATION OF THE HEALTHCARE SECTOR: THE ROLE OF HIS AND CRM SYSTEMS IN IMPROVING THE QUALITY OF MEDICAL SERVICES

Галайко Наталія Володимирівна

старший викладач

Кафедра інформаційних технологій

Львівський державний університет внутрішніх справ, Україна

In the contemporary context of digital transformation within the healthcare sector, effective patient relationship management has emerged as a key determinant of service quality, institutional competitiveness, and the optimisation of internal operational processes. The exponential growth of data volumes, the imperative for timely access to information, and the necessity of integrating heterogeneous functional subsystems are driving the widespread adoption of advanced IT solutions across the medical domain.

A Health Information System (HIS) constitutes the foundational management tool for healthcare facility resources, supporting clinical-diagnostic, administrative, financial, and service-related workflows. It represents a pivotal element of digitalisation, ensuring comprehensive data processing, accumulation, and analysis. The rapid proliferation of heterogeneous information and the growing complexity of clinical processes underscore the urgent demand for systems capable of delivering swift access to reliable data in support of evidence-based decision-making.

One of the principal functions of a HIS is the formation of a unified information environment in which patient data are available in real time. Contemporary platforms handle both structured and unstructured data – including medical imaging – thereby producing a more comprehensive clinical picture and enhancing diagnostic accuracy. A critical role in this regard is played by analytical modules, specifically decision-support systems built upon large-scale data arrays. With the maturation of artificial intelligence technologies, such systems are acquiring the capacity to forecast risks, determine disease probabilities, and predict complications – capabilities of particular significance in the context of personalised medicine.

A further essential dimension of HIS operation is the integration of data flows – consolidating diverse data sources into a unified environment through internationally recognised standards for medical information exchange. The classification of HIS is conducted according to scale, implementation level, degree of integration, and functional designation (Table 1).