

Гричанюк І.О.

студент;

Носовець О.К.

доцент,

Національний технічний університет України

«Київський політехнічний інститут імені Ігоря Сікорського»

НАВЧАННЯ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ СЕГМЕНТАЦІЇ СУДИН СІТКІВКИ ЗА ДОПОМОГОЮ ЗАШУМЛЕНИХ МІТОК

Глибоке навчання досягло чудових успіхів у багатьох областях за допомогою великих обсягів даних. Однак якість міток даних викликає занепокоєння через відсутність високоякісних міток у багатьох реальних зображеннях. Оскільки мітки з шумом значно погіршують продуктивність узагальнення глибоких нейронних мереж, навчання з зашумлених міток стає важливим завданням у сучасних програмах глибокого навчання. У цьому дослідженні ми спочатку описуємо проблему навчання з шумом етикетки з точки зору навчання зі вчителем.

Ефективне навчання мереж на мітках із шумом [1] важливе для багатьох існуючих задач. Попередні дослідницькі роботи здебільшого зосереджені на завданнях класифікації зображень і розробляють методології для упорядкування міток [2] або використовують активний вибір зразків [3] тощо. Однак тема міток зображення, особливо для завдань обробки та сегментації медичних зображень, не є добре дослідженою. Була запропонована LVC-Net [4] для регулювання неправильних піксельних міток за допомогою деформованого модуля просторового перетворення, керованого низькорівневими візуальними сигналами. Але даний метод не можна застосувати до зображень кровоносних судин сітківки ока, оскільки всі маленькі кровоносні судини можуть бути неправильно позначені і не можуть бути виправлені шляхом просторової трансформації. Однак через товщину кровоносних судин і меншу кількість навчальних даних порівняно з іншими даними медичних зображень, ні процедури синтезу міток, ні процедури відбору зразків не підходять для зображень кровоносних судин. Беручи до уваги характеристики зображень кровоносних судин, ми розглядаємо нову модель синтезу зашумлених міток для зображень судин сітківки для покращення надійності моделі на мітках із шумом.

У цій роботі ми в основному вивчаємо дві основні практичні проблеми для завдання сегментації судин сітківки. По-перше, ми досліджуємо покращення оригінальних зображень сітківки в порівнянні з традиційними методами регулювання контрасту, такими як CLAHE. По-друге, припустимо, що основні мітки сегментації анотованих даних є неповними і шумними, що лишає несегментованими анотації деяких елементів зображення судин, ми вивчаємо ефективну схему навчання для підвищення надійності моделі під час навчання на шумних мітках.

Такі завдання, як сегментація судин сітківки, стикаються з проблемою невеликого набору даних і неправильних або неповних анотацій судин. Ці дві практичні проблеми змусять глибоко навчену модель дуже легко досягати перенавчання мережі на навчальному наборі даних. Проблема перенавчання завдає шкоди здатності до узагальнення та стійкості моделі до невидимих даних тестування. До звичайних підходів, такі як збільшення даних, таких як трансформація зображення, випадкове деформування, зміна контрасту, ми пропонуємо чергувати схему навчання. За схемою перехресної перевірки K-fold та підходами дистиляції знань, ми пропонуємо для роботи з шумними мітками в невеликих наборах даних, особливо для завдання сегментації судин сітківки. Нарешті, ми навчаємо модель M з нуля шляхом спільної оптимізації наземних істинних міток посудини I з i отриманої псевдомітки.

Потім, ми навчаємо модель з нуля шляхом спільної оптимізації істинних анотованих міток судин сітківки та отриманої псевдомітки

Триканальна карта посилення I_e отримують із структури моделі. Даний метод натхненний схемою навчання перехресної перевірки та ідеєю дистиляції знань. Спочатку ми розбиваємо всю навчальну множину G на K підмножин $\{G_k\}$ і подаємо модель M_k G_k . Отримана оцінка I_c^k для G_k використовується як псевдомітки для спільної оптимізації (рис. 1).




Рис. 1. Схема перехресної перевірки K-Fold

Джерело: розроблено авторами

Остаточна модель M – це процес групового обговорення шляхом об'єднання та дистиляції знань з різних навчальних груп. Додавання псевдоміток можна розглядати як регуляризацию, щоб уникнути надмірного підгонки мережі під навчальні мітки, особливо коли дані мітки містять деякі шуми і, можливо, неправильні анотації. На рис. 2 показаний один приклад таких випадків. У цьому прикладі ми встановили $K = 2$, а висновки навчальних вибірок I з $M1$ і $M2$ показані в двох правих стовпцях, де I знаходиться в навчальному наборі $M1$, але не в навчальному розділі $M2$. $M1$ сильно переповерхує дані мітки I , ігноруючи кілька тонких і неоднозначних судин. Однак, якщо не навчений на I , $M2$ може визначити деякі з ігнорованих судин як псевдомітки. Поєднуючи ці дві мітки, остаточна модель M може інтуїтивно навчитися кращому представленню та стати більш узагальненим.




Рис. 2. Псевдомітки карти судин

Джерело: розроблено авторами

Ми оглянули модель сегментації судин сітківки на основі тренування з зашумленими мітками. Зокрема, ми дослідили, що синтез шумних міток та навчання з K -Fold підвищують продуктивність моделі, навченої з недосконалими мітками. Ми все ще виявили розрив між моделями, навченими з різними рівнями шумових міток, залишивши для подальшої роботи над покращенням чутливості моделі.

Наостанок, ми оцінили модель за допомогою відомих метрик, що використовуються для оцінки сегментації, та отримали такі результати (таблиця 1).

Отримані дані свідчать про добру роботу мережі на нових даних, а, особливо, на малих судинах, що є однією із головних проблем в задачах сегментації кровоносних судин сітківки.

При можливості отримання ще більшої кількості навчальних даних, та варіацій у виборі архітектур нейронної мережі, можна досягти дуже високих результатів в точності роботі даного алгоритму.

Таблиця 1

Оцінка моделі та порівняння з існуючими методами

Метод	Sensitivity	Specificity	DICE	Accuracy	AUC
LadderNet	0.7856	0.9810	0.8202	0.9561	0.9793
IterNet	0.7791	0.9831	0.8218	0.9574	0.9813
Наша модель	0.8341	0.9829	0.8259	0.9691	0.9867

Список використаних джерел:

1. Song, H., Kim, M., Park, D., Lee, J.G. (2020). Learning from noisy labels with deep neural networks: A survey. arXiv preprint arXiv:2007.08199.
2. Pereyra, G., Tucker, G., Chorowski, J., Kaiser, L., Hinton, G. (2017). Regularizing neural networks by penalizing confident output distributions. arXiv preprint arXiv:1701.06548.
3. Han, B., Yao, Q., Yu, X., Niu, G., Xu, M., Hu, W., Tsang, I., Sugiyama, M. (2018). Co-teaching: Robust training of deep neural networks with extremely noisy labels. arXiv preprint arXiv:1804.06872.
4. Shu, Y., Wu, X., Li, W. (2019). Lvc-net: Medical image segmentation with noisy label based on local visual cues. In: International Conference on Medical Image Computing and Computer-Assisted Intervention. pp. 558–566. Springer.