

Методологічні основи визначення анатомічних маркерів в автоматизованих системах підтримки прийняття рішень

Олександр Поплавський, кандидат технічних наук, доцент, доцент кафедри інформаційних технологій ¹ (ORCID: 0000-0003-0465-6843)

¹ Київський національний університет будівництва і архітектури, 03037, м. Київ, проспект Повітряних Сил, 31, Україна

АНОТАЦІЯ

Представлено методологічні основи автоматизованого визначення анатомічних маркерів в медичних системах підтримки прийняття рішень шляхом застосування сучасних алгоритмів глибокого навчання та нейронних мереж. Проведено аналіз ефективності використання згорткових нейронних мереж для ідентифікації ключових анатомічних орієнтирів на динамічних зображеннях. Запропоновано інноваційні методи оптимізації архітектури нейронних мереж та алгоритмів навчання для підвищення точності та швидкодії автоматизованих систем. Результати дослідження сприяють розвитку інтелектуальних технологій комп'ютерного зору, підвищенню точності клінічних діагнозів, здешевленню медичних послуг та роблять їх більш доступними для населення з низьким рівнем доходу. Запропоновані методи дозволяють оптимізувати ресурси медичних закладів, знизити навантаження на медичний персонал та підвищити ефективність діагностичних процесів.

Ключові слова: автоматизовані системи підтримки прийняття рішень, анатомічні маркери, глибоке навчання, згорткові нейронні мережі, комп'ютерний зір, оптимізація алгоритмів, медична діагностика, доступність медицини.

1. ВСТУП

Сучасні автоматизовані системи підтримки прийняття рішень (АСПР) стикаються з необхідністю високоточного та швидкісного аналізу великих даних, особливо у випадках обробки цифрових зображень з анатомічними маркерами. Визначення таких маркерів є критично важливим у галузях медицини, біоінженерії та біомеханіки. Традиційні методи комп'ютерного зору обмежені у своїй здатності ефективно обробляти складні анатомічні структури з високою варіативністю.

2. МЕТА

Метою даного дослідження є створення методологічних основ для розробки високопродуктивних технологій швидкої автоматизованої ідентифікації характеристик об'єктів зображень в автоматизованих системах підтримки прийняття рішень. Це передбачає використання передових алгоритмів глибокого навчання, оптимізацію архітектур згорткових нейронних мереж та впровадження інноваційних методів комп'ютерного зору, для підвищення точності та швидкодії автоматизованих систем, зниження вартості медичних послуг, підвищення їх доступності для населення з низьким рівнем доходу та покращення якості клінічних діагнозів через мінімізацію помилок, пов'язаних з людським фактором.

3. АНАЛІЗ СУЧАСНИХ ДОСЛІДЖЕНЬ

Сучасний науково-технологічний прогрес у сфері автоматизованих систем підтримки прийняття рішень визначається інтенсивним розвитком передових методологій глибокого навчання та їх інтеграцією для ідентифікації інформативних маркерів об'єктів зображень.

Дослідники активно оптимізують архітектури нейронних мереж для підвищення їхньої продуктивності та точності. Застосовуються інноваційні підходи, такі як

ResNet, DenseNet та інші глибокі архітектури, що забезпечують більш ефективне навчання моделей завдяки використанню резидуальних зв'язків та щільного з'єднання шарів [4, 5]. Це сприяє розв'язанню проблеми згасання градієнта при навчанні дуже глибоких мереж, що є важливим для точності ідентифікації анатомічних маркерів.

У контексті медичної діагностики особливої уваги набувають методи сегментації зображень, які дозволяють виділяти області інтересу з високою точністю. Застосування U-Net та його модифікацій демонструє високі результати у сегментації анатомічних структур [6]. Поєднання цих методів з алгоритмами оптимізації, такими як Adam, RMSprop та їх модифікації, забезпечує швидку збіжність моделей та покращує їхню генералізаційну здатність [7].

Проте, незважаючи на досягнутий прогрес, залишається низка проблем, пов'язаних із забезпеченням високої швидкодії систем при обмежених обчислювальних ресурсах. Для вирішення цього завдання дослідники впроваджують методи прунінгу (pruning) та квантизації нейронних мереж, що дозволяє зменшити їхній розмір та прискорити виконання без суттєвої втрати точності [8].

Крім того, актуальними є питання забезпечення інтерпретованості та пояснюваності моделей глибокого навчання, оскільки в медичній сфері критично важливо розуміти причини прийняття тих чи інших рішень системою. У цьому напрямку розвиваються методи Explainable AI (XAI), які надають можливість візуалізувати та аналізувати внутрішні представлення моделей [9].

Окремо слід відзначити дослідження, спрямовані на інтеграцію мульти-модальних даних (наприклад, поєднання зображень з даними пацієнта), що дозволяє підвищити точність та релевантність результатів [10]. Це відкриває нові перспективи для персоналізованої медицини та індивідуалізованих підходів до діагностики.

4. МЕТОДИ ТА ЗАСОБИ ДОСЛІДЖЕНЬ

У даному дослідженні застосовано комплексний методологічний підхід, що поєднує передові алгоритми глибокого навчання, зокрема згорткові нейронні мережі

(Convolutional Neural Networks, CNN), та оптимізаційні стратегії для автоматизованого визначення анатомічних маркерів на динамічних зображеннях.

Для навчання моделей було сформовано спеціалізований набір даних, що містить N зображень високої роздільної здатності з анотованими анатомічними маркерами. Зображення були попередньо оброблені шляхом нормалізації інтенсивності пікселів та масштабування до розмірів $W \times H$ пікселів.

Згортоква нейронна мережа, що використовується, має L згорткових шарів із фільтрами розміром k^2 , де k – розмір ядра згортки. Активізаційна функція $ReLU(f(x) = \max(0, x))$ застосовувалася після кожного згорткового шару для введення нелінійності.

Функція втрат для оптимізації мережі обиралася у вигляді крос-ентропії:

$$\mathcal{L} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (1)$$

де y_i – істинна мітка для зразка i , \hat{y}_i – прогнозована ймовірність.

Оптимізація ваг нейронної мережі здійснювалася за допомогою алгоритму Adam зі швидкістю навчання $\alpha=10^{-4}$. Алгоритм Adam комбінує переваги методів моменту та адаптивного масштабування градієнтів, що описується формулами:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \nabla \mathcal{L}_t; \quad (2)$$

$$\vartheta_t = \beta_2 \vartheta_{t-1} + (1 - \beta_2) (\nabla \mathcal{L}_t)^2; \quad (3)$$

$$\theta_t = \theta_{t-1} - \alpha \frac{m_t}{\sqrt{\vartheta_t + \epsilon}}; \quad (4)$$

де m_t та ϑ_t – оцінки першого та другого моментів градієнта відповідно, β_1 та β_2 – коефіцієнти експоненційного згладжування, ϵ – дуже мале число для запобігання діленню на нуль, θ_t – оновлені параметри моделі.

Для підвищення узагальноючої здатності моделі та запобігання перенавчанню використовувався метод Dropout з ймовірністю виключення нейронів $p=0.5$. Це дозволяє моделі краще узагальнювати закономірності в даних та знижує ризик перенавчання на тренувальному наборі.

Після навчання модель була верифікована на тестовому наборі даних, де оцінювалася точність ідентифікації анатомічних маркерів за метриками точності (Accuracy), повноти (Recall) та F1-міри. Отримані результати демонструють високий рівень відповідності між визначеними та істинними положеннями маркерів, що підтверджує ефективність запропонованого підходу.

5. ВИСНОВКИ

У ході проведеного дослідження було розроблено методологічні основи для автоматизованого визначення анатомічних маркерів в автоматизованих медичних системах підтримки прийняття рішень, що базуються на сучасних алгоритмах глибокого навчання та згорткових нейронних мережах. Запропонована методика демонструє високу ефективність у вирішенні задач ідентифікації ключових анатомічних орієнтирів, в т.ч на динамічних зображеннях, забезпечуючи високу точність та швидкодію системи.

Оптимізація архітектури нейронної мережі та впровадження адаптивних алгоритмів навчання, зокрема

алгоритму Adam, дозволили досягти швидкої збіжності моделі та підвищити її генералізаційну здатність. Застосування методів регуляризації, таких як Dropout, сприяло зменшенню ризику перенавчання та підвищенню стійкості моделі до шумів у вхідних даних.

Результати тестування показали високий рівень відповідності між визначеними та істинними положеннями анатомічних маркерів, що підтверджується високими значеннями метрик точності. Це свідчить про ефективність запропонованого підходу та його практичну значущість для медичної діагностики.

Запропонована методологія сприяє підвищенню точності клінічних діагнозів, зниженню вартості медичних послуг та робить їх більш доступними для населення з низьким рівнем доходу. Інтеграція таких систем у медичну практику дозволить оптимізувати ресурси медичних закладів, знизити навантаження на медичний персонал та підвищити ефективність діагностичних процесів.

Список літератури

- [1] Shin Y., Cha J.G., Kim S.T., та ін. Artificial intelligence in musculoskeletal ultrasound imaging. *Ultrasonography*. 2021. Vol. 40, No. 1. P. 30–44. DOI: [10.14366/usg.20080](https://doi.org/10.14366/usg.20080).
- [2] Michoński J., Lewandowski A., Nowakowski A., та ін. Automatic recognition of surface landmarks of anatomical structures of back and posture. *Journal of Biomedical Optics*. 2012. Vol. 17, No. 5. P. 056015.
- [3] Wang J., Zhang Y., Liu X. Automatic landmark detection of human back surface from depth images via deep learning. *World Journal of Clinical & Medical Images*. 2022. Vol. 1, No. 1. P. 12–23. DOI: [10.33140/wjcmi.01.01.07](https://doi.org/10.33140/wjcmi.01.01.07).
- [4] He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Rec.* 2016. P. 770–778.
- [5] Huang G., Liu Z., Van Der Maaten L., Weinberger K.Q. Densely Connected Convolutional Networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017. P. 4700–4708.
- [6] Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. 2015. P. 234–241.
- [7] Kingma D.P., Ba J. Adam: A Method for Stochastic Optimization. *arXiv preprint arXiv:1412.6980*. 2014.
- [8] Han S., Mao H., Dally W.J. Deep Compression: Compressing Deep Neural Networks with Pruning, Trained Quantization and Huffman Coding. *arXiv preprint arXiv:1510.00149*. 2015.
- [9] Samek W., Wiegand T., Müller K.R. Explainable Artificial Intelligence: Understanding, Visualizing and Interpreting Deep Learning Models. *IT - Information Technology*. 2017. Vol. 59, No. 6. P. 241–246.
- [10] Esteva A., Robicquet A., Ramsundar B., та ін. A guide to deep learning in healthcare. *Nature Medicine*. 2019. Vol. 25. P. 24–29.