

4. Microsoft. The TypeScript Handbook. TypeScript Official Documentation. URL: <https://www.typescriptlang.org/docs/handbook/intro.html> (дата звернення: 08.04.2026).
5. Google. Angular Overview. Angular Official Documentation, 2023. URL: <https://angular.dev/overview> (дата звернення: 08.04.2026).
6. Microsoft. Cloud Design Patterns. Azure Architecture Center. URL: <https://learn.microsoft.com/en-us/azure/architecture/patterns/> (дата звернення: 08.04.2026).
7. ReactiveX. RxJS: Reactive Extensions Library for JS. URL: <https://rxjs.dev/guide/overview> (дата звернення: 08.04.2026).
8. Angular University. RxJs for Beginners: A Beginner Friendly Introduction (Functional Reactive Programming for Angular Developers). URL: <https://blog.angular-university.io/functional-reactive-programming-for-angular-2-developers-rxjs-and-observables/> (дата звернення: 08.04.2026).
9. Nrwl / Nx. Nx Architecture Concepts. URL: <https://nx.dev/concepts/more-concepts/applications-and-libraries> (дата звернення: 08.04.2026).
10. Jackson C. Micro Frontends. MartinFowler.com, 2019. URL: <https://martinfowler.com/articles/micro-frontends.html> (дата звернення: 08.04.2026).

УДК 004.415.2

ГІБРИДНА АРХІТЕКТУРА АДАПТИВНОГО ІНФЕРЕНСУ ДЛЯ АВТОМАТИЗОВАНОГО АНАЛІЗУ МЕДИЧНИХ ЗОБРАЖЕНЬ

*Кудінов М. А.
kudinov@gmail.com*

Черкаський державний фаховий бізнес-коледж

*Марченко С. В.
м. Черкаси, Україна*

Сучасні підходи до автоматизованого аналізу медичних зображень базуються на застосуванні глибоких нейронних мереж, які демонструють високі показники точності при виявленні патологічних змін у різних модальностях

діагностичних досліджень. Згідно з оглядовими дослідженнями, використання моделей глибокого навчання дозволило суттєво підвищити ефективність інтерпретації медичних зображень, проте водночас поставило нові вимоги до архітектурної організації програмних систем, у яких такі моделі експлуатуються [1].

Однією з ключових проблем практичного впровадження систем медичного аналізу зображень є необхідність досягнення компромісу між швидкістю обробки та точністю виявлення патологій. Багато сучасних моделей демонструють високі показники чутливості лише за умови значних обчислювальних витрат, що обмежує їх використання в сценаріях оперативного скринінгу або потокового аналізу зображень. У свою чергу, спрощені або оптимізовані архітектури забезпечують меншу затримку інференсу, але можуть втрачати здатність до виявлення малих або складних патологічних структур. Такі суперечності детально розглядаються у роботах, присвячених застосуванню глибокого навчання в медичному аналізі зображень, де підкреслюється залежність ефективності моделей від умов їх експлуатації та характеристик даних [2].

Додатковим фактором, що ускладнює використання однієї універсальної моделі, є неоднорідність медичних зображень, отриманих із різних діагностичних пристроїв або в різних клінічних умовах. Варіативність просторової роздільної здатності, рівня шуму, контрастності та структури патологій призводить до зниження узагальнювальної здатності моделей і потребує застосування адаптивних підходів до вибору алгоритмів обробки. У цьому контексті дослідження ефективних архітектур детекції об'єктів демонструють, що масштабовані моделі можуть бути оптимізовані під різні сценарії використання шляхом балансування точності та ресурсних витрат, що відкриває можливості для комбінування декількох режимів інференсу в межах однієї системи [3].

Окрім алгоритмічних аспектів, важливим є питання експлуатаційної надійності систем медичного аналізу. У реальних умовах використання можливе

поступове зниження якості прогнозів моделей через зміну розподілів даних, появу нових типів патологій або зміну параметрів діагностичного обладнання. Це обумовлює необхідність інтеграції механізмів моніторингу якості інференсу, збору телеметрії та повторної валідації моделей у процесі експлуатації, що розглядається в сучасних підходах до організації життєвого циклу машинного навчання [4].

Звідси, аналіз наявних підходів свідчить про доцільність переходу від використання статичних схем інференсу до адаптивних архітектур, здатних динамічно змінювати стратегію обробки залежно від складності клінічного випадку та характеристик вхідних даних. Одним із перспективних напрямів є побудова гібридних систем, у яких швидкі моделі первинного скринінгу поєднуються з більш точними моделями уточнювального аналізу. Це дозволяє забезпечити одночасно прийнятну затримку обробки та підвищену чутливість до складних патологічних ознак.

Розробити архітектуру програмної системи автоматизованого аналізу медичних зображень, що реалізує гібридний вибір моделі виявлення та забезпечує баланс між швидкістю інференсу, точністю локалізації патологій і керованістю системи в умовах реального експлуатаційного середовища.

На рис. 1 подано компонентну діаграму системи автоматизованого аналізу медичних зображень із гібридним вибором моделі виявлення патологій.

Взаємодія користувача із системою здійснюється через діагностичний інтерфейс, який забезпечує ініціацію аналізу медичних зображень та перегляд отриманих результатів. Джерело медичних зображень передає дані для обробки до компонента приймання, який виконує перевірку формату вхідних даних і передає їх до компонента попередньої обробки. На цьому етапі здійснюється нормалізація інтенсивностей, масштабування та інші операції підготовки зображення до інференсу, що дозволяє зменшити вплив неоднорідності діагностичних даних.




Рисунок 1 – Архітектура системи автоматизованого аналізу медичних зображень з гібридним вибором моделі виявлення

Центральним елементом запропонованої архітектури є компонент оркестрації інференсу, який координує послідовність виконання аналізу. Він взаємодіє з компонентом визначення політики вибору моделі, що формалізує критерії маршрутизації залежно від характеристик вхідних даних і результатів попереднього аналізу. На першому етапі застосовується компонент швидкого виявлення патологій, орієнтований на мінімальну затримку обробки. У разі недостатньої впевненості результатів або виявлення потенційно складних патологічних структур оркестратор ініціює запуск компонента уточнювального виявлення. Така каскадна схема дозволяє поєднати високу продуктивність первинного скринінгу з підвищеною точністю аналізу складних випадків.

Результати роботи моделей передаються до компонента узгодження результатів, який виконує їх інтеграцію, усунення конфліктних детекцій і формування узгодженого набору областей інтересу. Далі компонент формування результату забезпечує збереження отриманих даних у відповідному сховищі та передачу фінального результату користувачькому інтерфейсу.

Окрему допоміжну функцію виконує компонент контролю якості виконання, який отримує службову інформацію про перебіг інференсу та накопичує її для подальшого аналізу. Це дозволяє оцінювати ефективність роботи моделей у процесі експлуатації та своєчасно виявляти ознаки погіршення їх продуктивності.

Запропонована компонентна структура забезпечує слабе зв'язування між модулями обробки даних і прийняття рішень, що створює передумови для адаптації системи до різних клінічних сценаріїв використання та поступового розвитку її функціональності. У перспективі розвиток архітектури може передбачати інтеграцію системи з клінічними інформаційними середовищами, використання спеціалізованих сховищ метаданих і телеметрії, а також впровадження механізмів керування версіями моделей і повторної валідації. Такі розширення підвищуватимуть керованість життєвого циклу моделей і забезпечуватимуть масштабованість системи в умовах реального медичного середовища.

Список використаних джерел:

1. Litjens G., Kooi T., Bejnordi B. E., Setio A. A. A., Ciompi F., Ghafoorian M., van der Laak J. A. W. M., van Ginneken B., Sánchez C. I. A survey on deep learning in medical image analysis // *Medical Image Analysis*. 2017. Vol. 42. P. 60–88. DOI: 10.1016/j.media.2017.07.005.
2. Agneya D. A., Shekar M. S., Bharadwaj A., Vineeth N., Neelima M. L. Deep learning in medical image analysis: a survey // *Proceedings of the International Conference on Innovation and Novelty in Engineering and Technology (INNOVA)*. 2024. P. 1–5. DOI: 10.1109/INNOVA63080.2024.10847040.

3. Tan M., Pang R., Le Q. EfficientDet: scalable and efficient object detection // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Seattle, WA, USA, 2020. P. 10781–10790. DOI: 10.1109/CVPR42600.2020.01079
4. Kreuzberger D., Kühl N., Hirschl S. Machine learning operations (MLOps): overview, definition, and architecture. *IEEE Access*. 2023. Vol. 11. P. 31866–31879. DOI:10.1109/ACCESS.2023.3262138

УДК 004.67

ПРОГРАМА ПРОГНОЗУВАННЯ ЕМОЦІЙНОГО СТАНУ ЛЮДИНИ НА ОСНОВІ АКТИВНОСТІ У СМАРТФОНІ

Воробйов Д.С.

vorobiovdmtyro11@gmail.com

Черкаський державний фаховий бізнес-коледж

Люта М. В.

м. Черкаси, Україна

У сучасних умовах зростання соціально-економічних та інформаційних навантажень питання психологічного благополуччя набуває особливої актуальності. Такі явища, як тривожність, емоційне вигорання та хронічна перевтома, виходять за межі клінічної практики та стають поширеними у повсякденному житті значної частини населення.

Водночас розвиток цифрових технологій сприяє появі нових інструментів підтримки ментального здоров'я. Сучасні мобільні пристрої виконують не лише інформаційно-комунікаційну функцію, але й виступають засобом самодопомоги та психоемоційної регуляції.

Одним із прикладів сучасних цифрових рішень у сфері ментального здоров'я є застосунок FABU, розроблений компанією SUITSME (екосистема Genesis). Основною концепцією сервісу є поєднання технік саморегуляції з елементами гейміфікації.

На відміну від традиційних цифрових щоденників або трекерів настрою, FABU пропонує користувачам інноваційний підхід до вираження емоцій через