

	ARM Cortex- M0+		(зовнішнє) / 264KB	зовнішні модулі	активний	простий, підтримка MicroPython
--	-----------------------	--	-----------------------	--------------------	----------	--------------------------------------

STM32U5 — буде найкращий вибір для критичних енергоефективних застосунків з високою безпекою.

ESP32-S3 — ідеальний для пристроїв з Wi-Fi/BLE та AI-обробкою.

Nordic nRF52 — лідер у BLE-пристроях з наднизьким споживанням.

RP2040 — бюджетний варіант для прототипування, не має вбудованого бездротового зв'язку.

У сучасних умовах стрімкого розвитку Інтернету дуже важливим є вибір мікроконтролерів, здатних забезпечити тривалу автономну роботу при мінімальному енергоспоживанні. Такі рішення, як STM32U5, ESP32-S3, Nordic nRF52 та RP2040, показують різні підходи до балансу між продуктивністю, бездротовими можливостями та енергоефективністю. Вибір мікроконтролера залежить від конкретних вимог до пристрою — тривалості роботи від батареї, типу бездротового зв'язку, обчислювальних потреб та інших. Рациональне використання енергозберігаючих режимів та правильне проектування системи дозволяє значно продовжити термін служби автономних IoT-рішень, що є ключовим фактором для сталого розвитку технологій майбутнього.

Література

1. Найкращі мікроконтролери для IoT-проектів URL: <https://www.dusuniot.com/uk/blog/best-microcontroller-for-iot-to-elevate-your-iot-development/>

2. Обговорення вибору мікроконтролерів для IoT та вбудованих систем URL: <https://dou.ua/forums/topic/52283/>

3. Брицький В. Архітектура IoT-рішень та принципи проектування систем. Кваліфікаційна робота магістра. Хмельницький. 2025. 100 с. URL: <https://elar.khmnu.edu.ua/server/api/core/bitstreams/f3666bfb-3470-4287-9f32-40fbf4c8ef6e/content>

УДК 004.93

І. І. Поліщук, Н.С. Луцик доктор філософії, доц.

(Тернопільський національний технічний університет імені Івана Пулюя, Україна)

АНАЛІЗ ІСНУЮЧИХ МЕТОДІВ ВИЯВЛЕННЯ ПЕРЕЛОМІВ НА МЕДИЧНИХ ЗОБРАЖЕННЯХ

I. I. Polishcuk, N. S. Lutsyk Ph.D., Assoc. Prof.

ANALYSIS OF EXISTING METHODS FOR FRACTURE DETECTION IN MEDICAL IMAGES

У сучасній медичній візуалізації значна увага приділяється автоматизованим методам виявлення патологій на рентгенограмах, зокрема переломів, що підвищує якість діагностики та зменшує навантаження на лікарів. Виявлення переломів на рентгенограмах є складним завданням через варіативність зображень, пов'язану з різними анатомічними областями, такими як кінцівки чи таз, а також через артефакти, спричинені імплантатами чи нерівномірним освітленням [1].

Традиційні методи цифрової обробки — порогова сегментація й детекція контурів (Собеля, Кенні) — дають змогу знаходити розриви кісткової структури, проте чутливі до шумів і потребують ручного налаштування параметрів. Дослідження показують, що такі методи досягають точності близько 70-80%, але їх ефективність знижується на складних випадках, як-от неповні переломи без чіткого зміщення фрагментів [2].

Подальший розвиток пов'язаний із використанням машинного навчання, зокрема SVM і випадкових лісів, що працюють з попередньо виділеними ознаками (текстурні дескриптори Haralick, LBP). Такі підходи покращують точність до 85–90%, але залежать від якості та репрезентативності ознак [3].

Револьюційні зрушення принесло глибоке навчання. Згорткові нейронні мережі, як-от ResNet чи EfficientNet, забезпечують обробку зображень у форматі end-to-end і демонструють точність понад 95% на задачах класифікації переломів. EfficientNet-B4 поєднує високу точність із помірними обчислювальними витратами, що робить її придатною для інтеграції у веб-сервіси медичної діагностики [4].

Для задач не лише класифікації, а й локалізації переломів, застосовуються об'єктно-детекційні моделі, такі як YOLOv8, які одночасно виконують сегментацію та класифікацію, генеруючи bounding boxes навколо патологій з метриками mAP@0.5 близько 93-94%. Це дозволяє візуалізувати точне місце перелому, що є цінним для клініцистів, хоча вимагає більших обчислювальних ресурсів через багатопарову архітектуру [5].

У сучасних системах застосовують гібридні підходи, де швидка бінарна класифікація (наприклад, EfficientNet) комбінується з локальним детектором (YOLOv8), що дозволяє оптимізувати час обробки та підвищити точність. Такі методи добре масштабуються у веб-сервісах і демонструють стабільність на різних анатомічних ділянках, хоча потребують вирішення проблеми дисбалансу класів через техніки аугментації [3].

Література

1. Іваненко С. М. Аналіз медичних зображень за допомогою глибокого навчання. *Вісник Національного технічного університету України "КПІ"*. Серія: Радіотехніка. Радіоапаратобудування. 2022. № 88. С. 45–52.
2. Кіт А. М. Методи обробки медичних зображень: монографія. Львів: Видавництво Львівської політехніки, 2021. 256 с.
3. Rahman T. et al. FracAtlas: A Dataset for Fracture Classification in Clinical X-Rays. *Scientific Data*. 2023. Vol. 10. Article 452.
4. Tan M., Le Q. V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the 36th International Conference on Machine Learning*. 2019. С. 6105–6114.
5. Jocher G., Chaurasia A., Borovec J. YOLOv8: Ultralytics for Object Detection and Segmentation. *Ultralytics Documentation*. 2023.