



© Видавець Інститут кібернетики імені В.М. Глушкова НАН України, 06.10.2026
Це – препринт відкритого доступу за ліцензією CC BY-NC-ND 4.0
<https://creativecommons.org/licenses/by-nc-nd/4.0/legalcode.uk>

Автор підтверджує, що даний препринт відповідає всім вимогам Договору приєднання
https://arxiv.nas.gov.ua/public/accession_agreement.html

Фактори продуктивності YOLO11 у реальному часі на Raspberry Pi 5 за обмеженого бюджету ресурсів: протокол даних і ключові результати

Лавренюк Алла¹ [0000-0002-5791-0377], Коломієць Олександр² [0009-0003-2542-8388], Лавренюк Сергій² [0000-0002-5181-7681]

¹ Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського», кафедра математичного моделювання та аналізу даних, просп. Берестейський, 37, Київ, 03056, Україна

² Інститут кібернетики імені В.М. Глушкова НАН України, відділ автоматизації програмування, просп. Академіка Глушкова, 40, Київ, 03187, Україна

[e-mail lsi@bigmir.net]

Анотація. Детектор об'єктів для малих розумних камер і мобільних роботів має вкладатися в ресурси бортового обчислювача, який він ділить з іншими задачами. На Raspberry Pi 5 з бюджетом у два потоки інференсу досліджено, як на частоту кадрів, затримку, точність і нагрів детектора YOLO11n впливають формат і точність моделі, роздільна здатність входу, мова реалізації конвеєра та нейропроцесор Nailo-8L. Окрему увагу приділено протоколу даних: формуванню тестової підмножини COCO val2017 і калібрувального набору, узгодженню еталонної розмітки з результатами детектування та оцінюванню точності для малих об'єктів. Повністю цілочисельна модель INT8 у TensorFlow Lite з конвеєром на C++ працює в 3,6 раза швидше за базовий варіант на Python з ONNX Runtime у FP32 (17,4 проти 4,8 кадр/с) ціною 4,3 в. п. mAP₅₀₋₉₅. Вхід 320 × 320 прискорює обробку ще в 4,1 раза, але mAP_s падає до 3,7 %, що пояснюється масштабуванням малих об'єктів до розмірів, сумірних із кроком найдрібнішої карти ознак. Nailo-8L дає 65,6 кадр/с при 640 × 640, зберігає mAP_s на рівні FP32 і не навантажує CPU.

Ключові слова: вбудовані системи, комп'ютерний зір, детекція об'єктів, YOLO11, Raspberry Pi 5, Nailo-8L, квантування INT8, COCO, протокол оцінювання, реальний час.

1 Вступ

Автономність малих апаратів і мобільних роботів дедалі більше залежить від бортового комп'ютерного зору. Обробка відео на наземній станції не завжди можлива: канал зв'язку обмежений і вносить затримку, а за радіоелектронної протидії зв'язку може не бути взагалі. Тому детектор має працювати безпосередньо на пристрої, на обчислювачі, обмеженому за розміром, масою, живленням і охолодженням.

Детектори сімейства YOLO [1], [2] добре підходять для таких задач, але модель, розгорнута «як є» (ONNX, Python, FP32), дає на одноплатному комп'ютері лише кілька кадрів за

секунду. Відомих способів прискорення чимало, проте для бортових систем важлива не лише частота кадрів, а й стабільність затримки, нагрів і ресурси, що лишаються іншим задачам. Тому внесок кожного чинника тут виміряно окремо за фіксованого бюджету ресурсів.

Порівняння конфігурацій має сенс лише тоді, коли всі вони оцінюються на тих самих даних за тим самим протоколом. Тому в препринті, крім ключових результатів, детально описано використаний набір даних і підготовку розмітки: відбір тестових і калібрувальних зображень, узгодження систем координат і ідентифікаторів класів, а також визначення метрик для малих об'єктів. Детальні абляції та особливості реалізації конвеєра на C++ буде викладено в повній статті. Робота продовжує серію досліджень авторів з оптимізації обчислень [3], [4].

2 Пов'язані роботи

Одноетапні детектори YOLO [1] поєднують локалізацію й класифікацію в одному проході мережі, що й робить їх основним вибором для вбудованих систем; YOLO11 [2] є одним з актуальних поколінь цього сімейства. Для пристроїв без графічного прискорювача ключовим засобом прискорення є цілочисельне квантування [5], ефект якого, однак, залежить від наявності оптимізованих ядер: у TensorFlow Lite (LiteRT) [6] для процесорів ARM їх надає бібліотека XNNPACK [7]. Альтернативою є спеціалізовані нейропроцесори, зокрема Nailo-8L з середовищем виконання NailoRT [8].

Еталоном для порівняння детекторів є набір COCO [9] з протоколом оцінювання, реалізованим у COCO API [10]; на ньому ж публікуються опорні результати моделей YOLO11 [2]. Саме тому COCO використано і в цій роботі, а його обмеження щодо цільової предметної області обговорено в п. 4.4.

3 Апаратна платформа та моделі

Як приклад малого обчислювача використано Raspberry Pi 5 (2 ГБ ОЗП, 4 ядра Cortex-A76) з активним кулером і модулем Raspberry Pi AI HAT+ із прискорювачем Nailo-8L (до 13 TOPS) на шині PCIe (рис. 1).




РИС. 1. Raspberry Pi 5 зі встановленим прискорювачем AI HAT+ (Nailo-8L).

На цільовому пристрої частину ядер займають зв'язок з контролером робота, телеметрія та передавання відео, тому інференсу на CPU виділено лише два потоки; власні пули потоків OpenCV та OpenMP/BLAS вимкнено, бо за 2 ГБ ОЗП вони можуть призводити до зависання системи. Таке обмеження до того ж зменшує нагрів, що для закритого корпусу не менш важливо, ніж швидкодія. Програмне забезпечення: TensorFlow Lite 2.18 з XNNPACK, HailoRT 4.20, ONNX Runtime 1.20, OpenCV 4.6.

Модель YOLO11n обрано як компроміс між YOLOv8n і YOLO26n: за швидкодією вона близька до YOLOv8n, а за якістю детектування — до YOLO26n, яка помітно повільніша. Модель експортовано засобами Ultralytics для входів 640×640 і 320×320 у ONNX (FP32, 10,6 МБ), у TensorFlow Lite (FP32, ваги FP16, динамічне та повністю цілочисельне INT8; повністю цілочисельна модель займає 2,9 МБ) і скомпільовано у формат HEF для Hailo-8L з придушенням немаксимумів (NMS) на прискорювачі.

4 Дані та підготовка розмітки

4.1 Тестова підмножина і калібрувальний набір

Для оцінювання точності використано загальновідомий набір COCO val2017 [9]: на ньому навчено публічні ваги YOLO11n і опубліковано їхні опорні результати [2], що дозволяє перевірити коректність власних конвеєрів без додаткової змінної — донавчання моделі. Повний прогін 5000 зображень для кожної з конфігурацій на Raspberry Pi 5 займав би непропорційно багато часу, тому точність оцінювали на підмножині з 500 зображень (10 % набору), відібраних з 5000 зображень val2017 випадковим чином. Випадковий відбір без урахування класів і розмірів об'єктів зберігає розподіл набору в середньому, не надаючи переваги жодній з конфігурацій. Відбір виконано один раз, після чого перелік ідентифікаторів зафіксовано: в усіх експериментах — для кожного формату й точності моделі, обох розмірів входу, реалізацій на Python і C++, а також для CPU і Hailo-8L — використано ті самі 500 зображень. Тому відмінності в точності між конфігураціями зумовлені лише досліджуваним чинником, а не вибіркою.

На цій підмножині FP32-модель має mAP_{50-95} 42,2 % проти 39,5 %, опублікованих для повного val2017 [2]. Отже, підмножина дещо «легша» за повний набір, і абсолютні значення точності не слід напряму порівнювати з опублікованими. Водночас для мети роботи — порівняння конфігурацій між собою — важливі різниці на спільній підмножині, а не абсолютні значення.

Для калібрування моделей INT8 використано окремий набір із 50 зображень, що не перетинається з тестовою підмножиною, — інакше оцінка точності квантованих моделей була б завищеною.

Калібрувальні зображення проходять ту саму попередню обробку (letterbox до $S \times S$ із заповненням сірим кольором, нормалізація), що й під час інференсу: діапазони активацій, за якими обираються масштаби квантування, залежать від розподілу вхідних даних, зокрема й від смуг заповнення.

4.2 Узгодження розмітки й результатів детектування

Модель працює з входом $S \times S$, тоді як еталонна розмітка задана в пікселях вихідного зображення $W \times H$, тож кожен конвеєр має коректно повернути рамки у вихідну систему координат. За letterbox-перетворення зображення масштабується зі збереженням пропорцій і доповнюється симетричними смугами:

$$s = \min(S / W, S / H), \quad p_x = (S - sW) / 2, \quad p_y = (S - sH) / 2, \quad (1)$$

а рамку детектора з лівим верхнім кутом (x', y') і розмірами $w' \times h'$ на вході переводять у координати зображення як

$$x = (x' - p_x) / s, \quad y = (y' - p_y) / s, \quad w = w' / s, \quad h = h' / s, \quad (2)$$

з подальшим обмеженням межами зображення. Для HEF з NMS на прискорювачі рамки надходять уже відфільтрованими в нормованих координатах входу, тому їх спершу масштабують на S , а далі застосовують (2).

Друга складова узгодження — ідентифікатори класів. Модель видає індекси 0–79, тоді як у розмітці COCO ідентифікатори категорій мають пропуски в діапазоні 1–90, тож для оцінювання індекси перетворюються фіксованою таблицею відповідності. Результати кожної конфігурації зберігаються у файл у форматі результатів COCO з порогом впевненості 0,001 і оцінюються одним і тим самим засобом (рис. 2). Однакова точність ONNX FP32 у Python і TFLite FP32 у C++ (42,2 %) слугує перевіркою того, що перетворення (1)–(2) і відповідність класів реалізовано в обох конвеєрах однаково.




РИС. 2. Підготовка даних і протокол оцінювання точності.

4.3 Метрики точності та малі об'єкти

Наводимо стандартні метрики COCO: mAP_{50} , mAP_{50-95} і mAP_s для малих об'єктів.

Малим у COCO вважається об'єкт з площею $area < 32^2$ пікселів, причому площу обчислюють за маскою сегментації у вихідному зображенні, а не за рамкою і не на вході мережі. Через це mAP_s чутлива до розміру входу: оскільки більшість зображень COCO мають довшу сторону 640 пікселів, для типового зображення 640×480 при $S = 640$ масштаб

$s = 1$, а при $S = 320$ — $s = 0,5$, і малий об'єкт на вході стає меншим за 16×16 пікселів, тобто займає не більше 2×2 комірок найдрібнішої карти ознак з кроком 8. Саме цим пояснюється різке падіння mAP_s на вході 320×320 (табл. 1). Для бортових камер, де цілі з висоти польоту здебільшого малі, mAP_s є найбільш показовою з наведених метрик.

4.4 Обмеження набору

COCO містить переважно наземні сцени, тому отримані значення точності характеризують відносний вплив чинників оптимізації, а не очікувану точність у цільовому застосуванні. Частково це компенсується акцентом на mAP_s , проте розподіл ракурсів, масштабів і класів на знімках з борту відрізняється.

5 Вимірювання швидкодії

Швидкодію вимірювали на 300 кадрах, що зчитувалися з пам'яті, після 20 кадрів прогріву з робочим порогом впевненості 0,25, фіксуючи для кожного кадру тривалість захоплення, попередньої обробки, інференсу та постобробки (декодування й NMS). Для контуру керування важлива найгірша затримка, тому, крім медіани, наводимо 95-й перцентиль. Перед кожним прогоном SoC охолоджувався до 55°C ; реєструвалися максимальна температура, частота CPU та пікове використання пам'яті.

6 Результати

ТАБЛИЦЯ 1. Швидкодія та точність основних конфігурацій (Raspberry Pi 5, 2 потоки)

Конфігурація	Вхід	Кадр/с	Затримка мед. / p95, мс	mAP_{50} , %	mAP_{50-95} , %	mAP_s , %	$T_{\max}$ °C
Python							
ONNX Runtime, FP32 (базовий)	640	4,8	203 / 205	57,4	42,2	17,7	55,1
TFLite, INT8	640	13,4	70,6 / 72,5	54,5	38,2	11,3	52,4
C++, TFLite + XNNPACK							
FP32	640	5,6	178 / 181	57,4	42,2	17,7	58,4
INT8	640	17,4	57,2 / 59,5	54,5	37,9	11,2	59,5
FP32	320	25,3	39,5 / 40,0	44,4	31,5	4,2	60,6
INT8	320	71,4	14,0 / 14,4	43,7	30,0	3,7	57,9
C++, HailoRT, Hailo-8L (NMS на прискорювачі)							
INT8	640	65,6	14,7 / 17,2	52,6	38,0	17,8	53,5
INT8	320	153,3	6,5 / 6,8	41,9	29,7	4,3	52,9

Примітка: затримка охоплює захоплення кадру з пам'яті, попередню обробку, інференс і постобробку; точність — на тестовій підмножині з 500 зображень COCO val2017 (п. 4.1).

Сам перехід з ONNX Runtime на TFLite у FP32 майже нічого не дає (5,6 проти 4,8 кадр/с). Повністю цілочисельна модель INT8 у конвеєрі на C++ дає 17,4 кадр/с (3,6×) ціною 4,3 в. п. mAP_{50-95} , причому найбільше страждають малі об'єкти: mAP_s 11,2 % проти 17,7 %. Виграш від квантування реалізується лише разом з оптимізованими ядрами: без делегата XNNPACK та сама модель INT8 дає 5,3 кадр/с. Та сама модель INT8 з Python дає 13,4 кадр/с: інференс

однаковий (55,6 мс), але попередня обробка й постобробка займають 21 % часу кадру проти 2,5 % у C++. Затримка стабільна: на CPU p95 перевищує медіану не більше ніж на 4 %.

Вхід 320×320 прискорює INT8-конфігурацію ще в 4,1 раза (71,4 кадр/с), але mAP_{50-95} падає до 30,0 %, а mAP_s — до 3,7 %, що узгоджується з аналізом п. 4.3: для малих цілей цей режим непридатний. Hailo-8L при 640×640 дає 65,6 кадр/с (13,6 $\times$) з тією самою mAP_{50-95} , що й TFLite INT8, але зберігає малі об'єкти на рівні FP32 (mAP_s 17,8 %), не навантажує CPU і нагріває SoC лише до 54 °C. Зменшення входу на NPU дає лише 2,3 $\times$, бо значну частку часу становлять фіксовані витрати синхронного виклику прискорювача, які не масштабуються з розміром входу [11]. Компроміс швидкодії й точності всіх конфігурацій показано на рис. 3.




РИС. 3. Компроміс швидкодії та точності конфігурацій; пунктир — фронт Парето.

7 Висновки

Без прискорювача найкращий компроміс для обчислювача з бюджетом у два потоки — повністю цілочисельна модель INT8 у TFLite з XNNPACK і конвеєром на C++: 17,4 кадр/с при 640×640 . Квантування дає вигравш лише разом з оптимізованими ядрами, а накладні витрати Python сягають п'ятої частини часу кадру. Вхід 320×320 доцільний лише за відсутності малих цілей: малі за протоколом COCO об'єкти на такому вході стають сумірними з кроком найдрібнішої карти ознак. Hailo-8L за частоти кадрів, близької до CPU на 320×320 , дає точність 640×640 зі збереженням малих об'єктів і звільняє CPU, тому для бортових систем є кращим вибором.

Для коректного порівняння конфігурацій важливими виявилися фіксована тестова підмножина, калібрувальний набір, що не перетинається з нею, і єдина процедура повернення рамок та ідентифікаторів класів до системи розмітки. У повній статті планується розширити оцінювання на повний val2017, дослідити чутливість квантування до

розміру й складу калібрувального набору, навести детальні абляції конвеєра на C++, асинхронний режим NailoRT, обчислення FP16 на Cortex-A76 та вимірювання енергії на кадр.

Наявність даних

Посилання на репозиторії: <http://images.cocodataset.org/zips/val2017.zip>

<https://github.com/ultralytics/yolov5/releases/download/v1.0/coco2017labels.zip> . Набір COCO 2017 є загальнодоступним [9]; ваги YOLO11n доступні в репозиторії Ultralytics [2].

Список посилань

1. Redmon J., Divvala S., Girshick R., Farhadi A. You only look once: unified, real-time object detection. *Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*. 2016. P. 779–788.
2. Jocher G., Qiu J. Ultralytics YOLO11. 2024. URL: <https://github.com/ultralytics/ultralytics> (дата звернення: 06.10.2026).
3. Лавренюк А.М., Лавренюк С.І., Тульчинський П.Г. Оптимізація архітектури програмного забезпечення для аналізу великих даних на базі мови програмування Python. *Системний аналіз та інформаційні технології*: матеріали 19-ї Міжнар. наук.-техн. конф. SAIT 2017 (Київ, 22–25 трав. 2017 р.). Київ: ННК «ІПСА» НТУУ «КПІ ім. Ігоря Сікорського», 2017. С. 291–292.
4. Лавренюк А.М., Лавренюк С.І., Тульчинський П.Г. Підхід до оптимізації програмного забезпечення для аналізу великих даних. *Компьютерная математика*. 2017. Вип. 1. С. 121–125.
5. Jacob B., Kligys S., Chen B. et al. Quantization and training of neural networks for efficient integer-arithmetic-only inference. *Proc. IEEE/CVF Conf. on Computer Vision and Pattern Recognition (CVPR)*. 2018. P. 2704–2713.
6. LiteRT (TensorFlow Lite) documentation. Google. URL: <https://ai.google.dev/edge/litert> (дата звернення: 06.10.2026).
7. XNNPACK: high-efficiency floating-point neural network inference operators. Google. URL: <https://github.com/google/XNNPACK> (дата звернення: 06.10.2026).
8. NailoRT user guide. Nailo Technologies. URL: <https://nailo.ai/developer-zone/> (дата звернення: 06.10.2026).
9. Lin T.-Y., Maire M., Belongie S. et al. Microsoft COCO: common objects in context. *Computer Vision – ECCV 2014*. Lecture Notes in Computer Science. Vol. 8693. Cham: Springer, 2014. P. 740–755.
10. COCO API (pycocotools). URL: <https://github.com/cocodataset/cocoapi> (дата звернення: 06.10.2026).
11. Amdahl G.M. Validity of the single processor approach to achieving large scale computing capabilities. *Proc. AFIPS Spring Joint Computer Conf.* 1967. P. 483–485.