

М. С. Мамута¹, І. В. Кравченко², О. Д. Мамута³^{1,2}Національний технічний університет України "Київський політехнічний інститут імені Ігоря Сікорського", Україна

Берестейський проспект, 37, Київ, 03056

³Інститут фізики НАН України, Україна
проспект Науки, 46, Київ, 03028¹<https://ror.org/00syn5v21>²<https://ror.org/00syn5v21>¹rybalkomaryna@gmail.com²kravchenko.igor@iit.kpi.ua³mamuta@iop.kiev.ua¹<https://orcid.org/0000-0002-7674-4984>²<https://orcid.org/0000-0002-9223-057X>³<https://orcid.org/0000-0002-6404-5879>

ШТУЧНИЙ ІНТЕЛЕКТ В АВТОМОБІЛЬНІЙ ПРОМИСЛОВОСТІ

М. Mamuta¹, I. Kravchenko², O. Mamuta³^{1,2}National Technical University of Ukraine "Igor Sikorsky Kyiv Polytechnic Institute", Ukraine
Prospect Beresteyskiy, 37, Kyiv, 03056³Institute of Physics, National Academy of Sciences of Ukraine, Ukraine
Av. Nauki, 46, Kyiv 03028¹<https://ror.org/00syn5v21>²<https://ror.org/00syn5v21>¹rybalkomaryna@gmail.com²kravchenko.igor@iit.kpi.ua³mamuta@iop.kiev.ua¹<https://orcid.org/0000-0002-7674-4984>²<https://orcid.org/0000-0002-9223-057X>³<https://orcid.org/0000-0002-6404-5879>

ARTIFICIAL INTELLIGENCE IN AUTOMOTIVE INDUSTRY

Анотація. Штучний інтелект відіграє ключову роль в автомобільній промисловості. Він використовується у вигляді машинного навчання, глибокого навчання, нейронних мереж, обробки природної мови, комп'ютерного зору, нечіткої логіки та інших технологій для підвищення ефективності, швидкості та комфорту. Все більшої популярності в автомобільній галузі набуває використання моделі YOLO, яка демонструє високу продуктивність і точність. Однак аналіз ефективності для останніх версій серії YOLO, а саме YOLOv11 та YOLO26, відсутній. Ця стаття спрямована на заповнення цієї прогалини. Крім того, досліджується вплив методу заморожування шарів при "донавчанні" моделей YOLOv11 та YOLO26 для виявлення та сегментації різних частин автомобіля, що є надзвичайно важливим для таких застосувань, як автоматизоване виробництво, сервісне обслуговування та оцінка пошкоджень автомобіля. Експерименти проводилися в середовищі Google Colaboratory Pro з використанням графічного процесора NVIDIA A100 (40 ГБ пам'яті). Для досліджень використовувався набір даних Carparts Segmentation, який містить 3833 розмічені зображення, поділені на три підмножини: тренувальну, валідаційну та тестову. Моделі навчалися протягом 100 епох із застосуванням механізму ранньої зупинки у разі відсутності покращення протягом 20 епох для запобігання перенавчанню, з розміром пакета – 16 зразків та оптимізатором AdamW. Емпірично встановлено, що YOLOv11 перевершує попередні версії серії YOLO за метриками повноти, F1 та mAP50–95. Модель YOLOv11 без заморожування шарів демонструє найкращі результати за метриками F1 та mAP50–95. Заморожування шарів підвищує ефективність моделі YOLOv11, що підтверджують показники повноти та mAP50. Найефективнішою стратегією виявилось заморожування перших шести шарів архітектури YOLOv11. Новітня версія YOLO26 без заморожування шарів не досягає кращих результатів порівняно з попередніми версіями за всіма розглянутими метриками. Крім того, заморожування шарів не продемонструвало жодного покращення продуктивності моделі YOLO26 за жодною з метрик. Результати дослідження показали, що YOLOv11 із заморожуванням перших шести шарів архітектури виявляє з вищою впевненістю такі деталі автомобіля, як «задня фара» (back_light), «праві задні двері» (back_right_door), «права задня фара» (back_right_light), «передні двері» (front_door) та частину «колесо» (wheel) порівняно з YOLO26. В подальшому планується провести дослідження ефективності моделей по окремих деталях автомобілів, аналіз кореляції стандартних метрик зі змінами в детекції та ідентифікації деталей та перевірку роботи моделей на зображеннях тестової вибірки.

Ключові слова: штучний інтелект, YOLO, перенесення навчання, комп'ютерний зір.

Abstract. Nowadays, artificial intelligence plays a crucial role in the automotive industry. It is used as machine learning, deep learning, neural networks, natural language processing, computer vision, fuzzy logic and other techniques to improve efficiency, speed and comfort. More and more popularity gains YOLO in the automotive industry that demonstrates outstanding performance and accuracy. However, efficiency of the latest versions, namely YOLOv11 and YOLO26, is underexplored. This article addresses this gap. Moreover, the influence of layer freezing technique on YOLOv11 and YOLO26 during detection and segmentation of different car parts is investigated, that is very essential in applications such as safety analysis, damage assessment, insurance and automated production. Experiments were conducted in Google Colaboratory Pro environment with GPU NVIDIA A100 (40Gb). Carparts Segmentation Dataset was used for experiments, containing 3833 labeled images split into three subsets: training, validation and test. Models were trained for 100 epochs with an early stopping mechanism (patience 20) to avoid overfitting, batch size 16, optimizer AdamW. It was found empirically that YOLOv11 outperform previous versions of YOLO series according to such metrics as Recall, F1 and mAP50-95. YOLOv11 without layer freezing is the best in terms of the F1 and mAP50-95 metrics. Layer freezing is beneficial for YOLOv11 that confirm such metrics as recall and mAP50. The best strategy is to freeze first 6 layers of the YOLOv11 architecture for its performance improvement. The latest version YOLO26 without layer freezing does not achieve better results than the previous versions according all metrics. Layer freezing does not show any improvement of YOLO26 model performance for all metrics. Results revealed that YOLOv11 with 6 layers frozen detects with higher confidence such car parts as “back light”, “back right door”, “back right light”, “front door” and “wheel” in comparison with YOLO26. In the future, it is planned to conduct a study of the models’ effectiveness for individual car parts, analyze the correlation between standard metrics and changes in the detection and identification of parts, and evaluate the models’ performance on images from the test subset.

Keywords: artificial intelligence, YOLO, transfer learning, computer vision.

Постановка проблеми у загальному вигляді та її зв'язок із важливими науковими чи практичними завданнями

Штучний інтелект викликав революцію та фундаментальні зміни в багатьох сферах промисловості, зокрема в автомобільному секторі [1]. В автомобільній галузі штучний інтелект стає невід'ємною частиною кожної ланки від проєктування та виробництва до експлуатації та обслуговування транспортних засобів шляхом застосування машинного навчання, глибинного навчання, нейронних мереж, обробки природної мови, комп'ютерного зору, методів нечіткої логіки та інших підходів для автоматизації та підвищення ефективності кожного процесу та ланцюга в цілому [2]. Відбувається перехід до автономного транспорту, розширюється спектр мультимодальних інтерфейсів для забезпечення водія більш інтуїтивного та комфортного водіння [3, 4]. За рахунок застосування штучного інтелекту скорочується час та витрати на проєктування [5]. Сучасна діагностика орієнтується на прогнозування можливих відмов компонентів ще до їх виникнення [6]. Навіть сфера страхування та безпека на дорогах значною мірою спираються на штучний інтелект [2, 7].

Однією з важливих задач штучного

інтелекту в автомобільній промисловості є автоматизована ідентифікація окремих частин автомобіля, що відіграє ключову роль для таких напрямків як автоматизоване виробництво, сервісне обслуговування та оцінка пошкоджень автомобіля [8]. Для вирішення цієї задачі використовуються двоступеневі та одноступеневі методи детектування та сегментації [9]. Одноступеневі методи демонструють більшу ефективність. Серед застосовуваних моделей ШІ особливо виділяється модель YOLO [10].

Аналіз останніх досліджень та публікацій

В роботі [11] проведено детальний аналіз застосування моделей серії YOLO від YOLOv2 до YOLOv8 включно в автомобільній промисловості. В [8] проаналізовано ефективність YOLOv4, YOLOv5, YOLOv7 та YOLOv8, а також YOLO з додатковими блоками архітектури на наборі даних Carparts Segmentation для ідентифікації окремих частин автомобіля. В роботі [12] встановлено ефективність моделі YOLOv7 при виявленні дефектів автомобільних запчастин. В [13] досліджено ефективність застосування моделі YOLOv9 для ідентифікації окремих частин автомобіля. Однак аналіз ефективності ідентифікації окремих частин

автомобіля для останніх версій YOLO, зокрема для YOLOv11 та YOLO26, відсутній. В роботі [14] показано, що метод перенесення навчання дозволяє підвищити ефективність вилучення ознак і таким чином забезпечує покращення виявлення і локалізацію пошкоджень транспортних засобів. В [15] доведено ефективність методу заморожування шарів при перенесенні навчання для моделі YOLOv8. Проте не досліджене питання впливу заморожування шарів архітектури моделі YOLO на ефективність сегментації та детекції окремих частин автомобіля для останніх версій YOLOv11 та YOLO26.

Мета дослідження

Метою роботи є дослідження ефективності застосування моделей YOLOv11 та YOLO26 для ідентифікації окремих частин автомобіля, а також перевірка доцільності застосування методу заморожування шарів архітектури при перенесенні навчання для цих моделей.

Виклад основного матеріалу

Для тренувань використовувалась версія “nano”, оскільки вона легко інтегрується в системи, що працюють в режимі реального часу.

Для тренування моделі YOLO було обрано наступні гіперпараметри:

- розмір зображення 640×640

пікселів;

- розмір пакету 16 зображень;
- кількість епох – 100, з можливістю ранньої зупинки, якщо відсутні покращення характеристик протягом 20 епох;
- оптимізатор AdamW.

Тренування здійснювались в середовищі Google Colaboratory Pro на основі графічного процесора NVIDIA A100 (40Гб). Було використано набір даних Carparts Segmentation Dataset [16]. Набір даних розділений на три частини: навчальну, валідаційну та тестову вибірки. Навчальна вибірка містить 3156 зображень, валідаційна – 401 зображення, тестова – 276.

На рис. 1 показано розподіл класів (частин автомобіля), які детектувались на зображеннях використаного набору даних. По осі абсцис позначено категорії частин автомобіля, а по осі ординат їх кількість. Такі частини як «передня фара» (front_light) і «капот» (hood) найчастіше зустрічаються в наборі даних, такі частини як «колесо» (wheel) трапляються рідше, а такі як «задня ліва фара» (back_left_light) або «багажник» (trunk) – зовсім рідко. Таким чином набір даних є незбалансованим, а отже заморожування шарів архітектури має позитивно вплинути на ефективність, як показано в [17] для YOLOv5.




Рис. 1. Розподіл класів (частин автомобіля) в наборі даних

Згідно з рекомендаціями розробника моделі [18] було здійснено заморожування перших 10-ти шарів архітектури для обох моделей, а також перевірено доцільність заморожування більш ранніх шарів. Встановлено, що ефективним є заморожування перших 6-ти, як і показано в [19]. Для моделі YOLOv11 заморожування шару 'model.23.dfl.conv.weight' здійснюється автоматично.

Оцінювання ефективності здійснювалося за матрицям плутанини (Confusion matrix), графіками точності-впевненості (Precision-Confidence Curve), графіками повноти-впевненості (Recall-Confidence Curve): та стандартними

метриками. В якості метрик використовувалися параметри точності (Precision), повноти (Recall), F1 (метрики, що балансує значення точності і повноти), середньої точності за критерієм ступеня перекриття між передбаченим та реальним обмежуючим об'єкт детекції прямокутниками (Intersection over Union, IoU) для IoU не менше 0,5 (mAP50) та середньої точності для IoU від 0,5 до 0,95 (mAP50-95).

Результати ефективності навчання наведено в таблиці 1. Група стовпців «Box» показує значення відповідних метрик для обмежуючих прямокутників, група стовпців «Mask» – для маски сегментації.

Таблиця 1. Результати навчання

	Box					Mask				
	Precision	Recall	F1	mAP50	mAP50-95	Precision	Recall	F1	mAP50	mAP50-95
YOLOv8n	0.603	0.789	0.684	0.694	0.579	0.61	0.799	0.692	0.709	0.558
YOLOv11n	0.6	0.812	0.69	0.696	0.584	0.605	0.819	0.696	0.702	0.566
YOLOv11n, 10	0.549	0.764	0.639	0.645	0.518	0.553	0.771	0.644	0.661	0.483
YOLOv11n, 6	0.586	0.834	0.688	0.702	0.579	0.594	0.837	0.695	0.71	0.553
YOLO26n	0.562	0.781	0.654	0.651	0.544	0.573	0.792	0.665	0.666	0.533
YOLO26n, 10	0.541	0.719	0.617	0.61	0.487	0.545	0.729	0.624	0.612	0.479
YOLO26n, 6	0.545	0.734	0.626	0.633	0.526	0.555	0.737	0.633	0.647	0.517

Результати показують, що:

- модель попереднього покоління YOLOv8 має найкращий результат за метрикою точності для обох груп аналізу;
- модель YOLOv11 без заморожування має найкращий результат за метриками F1 та mAP50-95 для обох груп аналізу;
- найсучасніша модель YOLO26 без заморожування поступається за всіма метриками для обох груп аналізу;
- заморожування не підвищує показники метрик для моделі YOLO26;
- заморожування в моделі YOLOv11 знижує показники метрик точності, mAP50-95, практично не впливає на метрику F1 та покращує показники метрик повноти та mAP50;
- модель YOLOv11 із заморожуванням перших 6-ти шарів архітектури має найвищий результат за

метриками повноти та mAP50 як для маски сегментації, так і для обмежуючих прямокутників, та поступається кращому результату за метрикою повноти менше ніж на 0.5 %;

- модель YOLOv11 із заморожуванням перших 6-ти шарів архітектури демонструє найкращі збалансовані по всіх метриках показники та може вважатися найбільш ефективною.

На рис. 2 наведено криву F1-впевненості для моделі YOLOv11 із заморожуванням перших 6-ти шарів архітектури та моделі YOLO26. Синя лінія показує значення F1 для всіх класів. З графіків видно, що модель YOLOv11 із заморожуванням перших 6-ти шарів архітектури демонструє підвищення значення F1 для всіх класів порівняно з YOLO26, особливо в області вищих

значень впевненості, що свідчить про покращення метрики точності. Для YOLOv11 із заморожуванням перших 6-ти шарів архітектури крива F1 має значення 0,67 для всіх класів при впевненості 0,345,

в той час як YOLO26 досягає значення 0,63 при впевненості 0,280. Це підтверджує те, що YOLOv11 із заморожуванням перших 6-ти шарів архітектури має більше значення показника F1 для всіх класів.

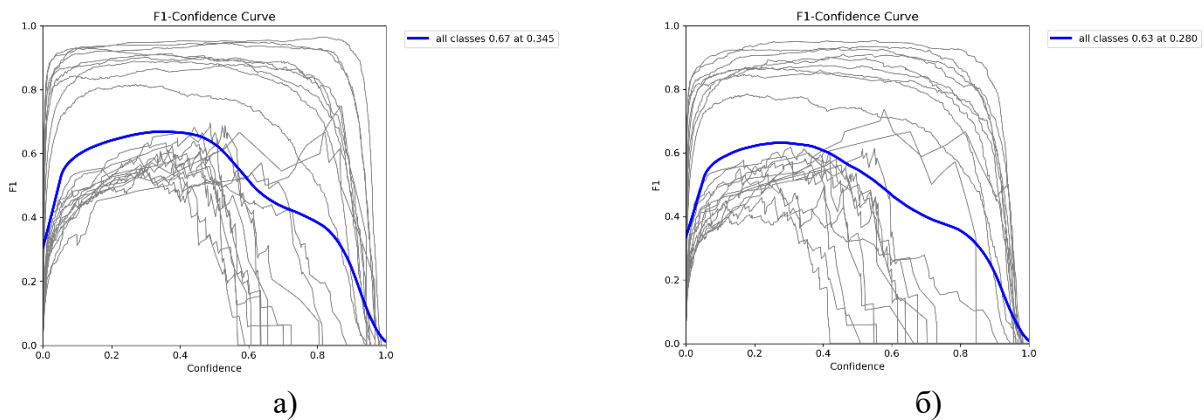


Рис. 2. Крива F1-впевненості (F1-Confidence Curve):
а) YOLOv11 при заморожуванні перших 6-ти шарів архітектури; б) YOLO26

На рис. 3 наведено криву точності-повноти для моделі YOLOv11 із заморожуванням перших 6-ти шарів архітектури та моделі YOLO26. Синя лінія показує криву точності-повноти для всіх класів. Модель YOLOv11 із заморожуванням перших 6-ти шарів

архітектури має значення mAP50 рівне 0,703 для всіх класів, а YOLO26 має значення mAP50 – 0,649 для всіх класів. Це свідчить про те, що модель YOLOv11 із заморожуванням перших 6-ти шарів архітектури демонструє кращий баланс метрик точності і повноти.

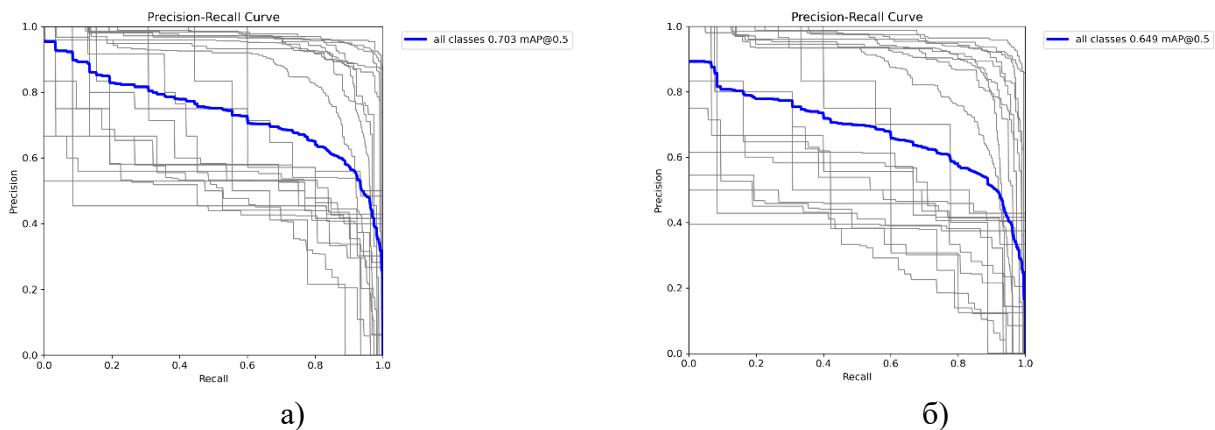


Рис. 3. Крива точності-повноти (Precision-Recall Curve):
а) YOLOv11 при заморожуванні перших 6-ти шарів архітектури; б) YOLO26

На рис. 4 наведено криву повноти-впевненості для моделі YOLOv11 із заморожуванням перших 6-ти шарів архітектури та моделі YOLO26. Синя лінія показує криву повноти-впевненості для всіх класів. Крива для моделі YOLOv11 із заморожуванням перших 6-ти шарів архітектури розпочинається з вищого

значення повноти рівного 0,94 при впевненості рівній 0,000. Крива для моделі YOLO26 розпочинається зі значення повноти 0,92 при впевненості 0,000 і спадає різкіше. Таким чином, при невеликих значеннях впевненості значення повноти зберігається високим для моделі YOLOv11 із заморожуванням перших 6-ти шарів

архітектури, що гарантує виявлення більшості класів.

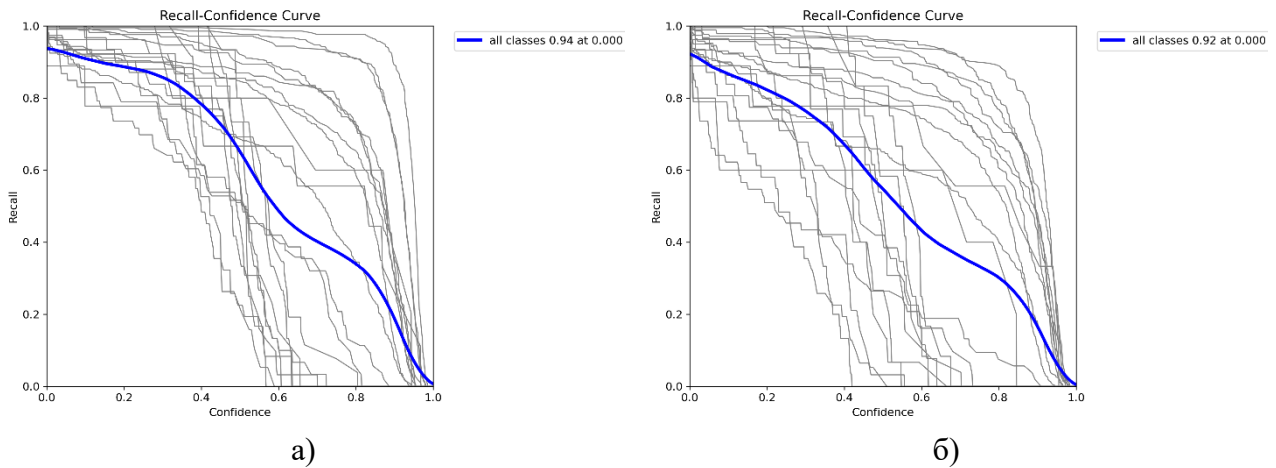


Рис. 4. Крива повноти-впевненості (Recall-Confidence Curve):
 а) YOLOv11 при заморожуванні перших 6-ти шарів архітектури; б) YOLO26

На рис. 5 наведено криву точності-впевненості для моделі YOLOv11 із заморожуванням перших 6-ти шарів архітектури та моделі YOLO26. Синя лінія показує криву точності-впевненості для всіх класів. Для обох моделей крива досягає

значення точності 0,96 при впевненості 1,00. Проте з характеру графіків видно, що модель YOLOv11 із заморожуванням перших 6-ти шарів архітектури демонструє більш стабільну точність при низьких значеннях впевненості.

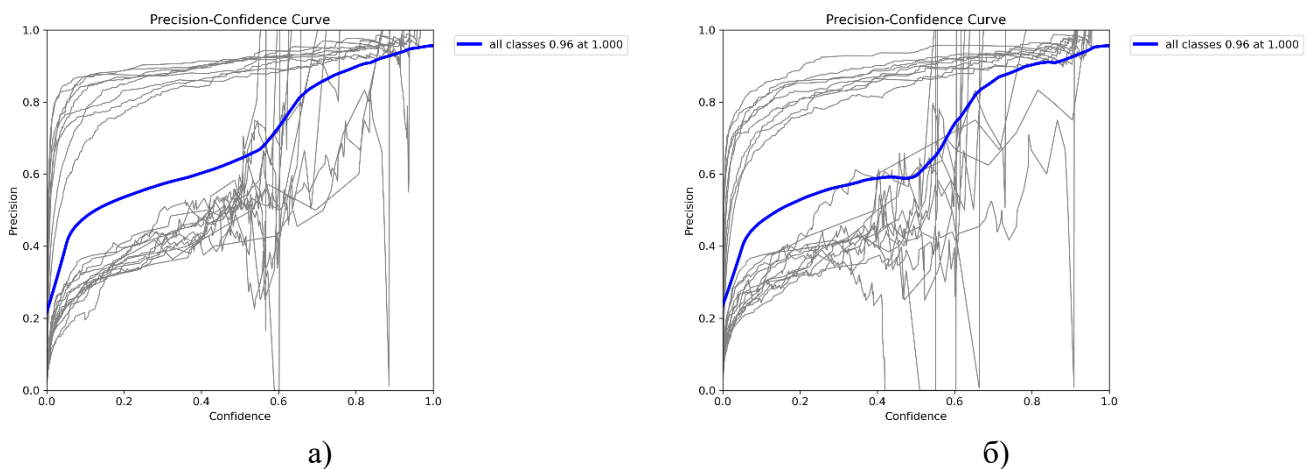


Рис. 5. Крива точності-впевненості (Precision-Confidence Curve):
 а) YOLOv11 при заморожуванні перших 6-ти шарів архітектури; б) YOLO26

На рис. 6 – 7 наведено матрицю плутанини для моделей YOLOv11 із заморожуванням перших 6-ти шарів архітектури та моделі YOLO26 відповідно. На осі абсцис позначені істинні значення, а на осі ординат – передбачені моделлю. Для моделі YOLOv11 із заморожуванням

перших 6-ти шарів архітектури помітне підвищення точності виявлення певних частин автомобіля, зокрема «задньої фари» (back_light), «правих задніх дверей» (back_right_door), «правій задньої фари» (back_right_light), «передніх дверей» (front_door) та частини «колесо» (wheel).

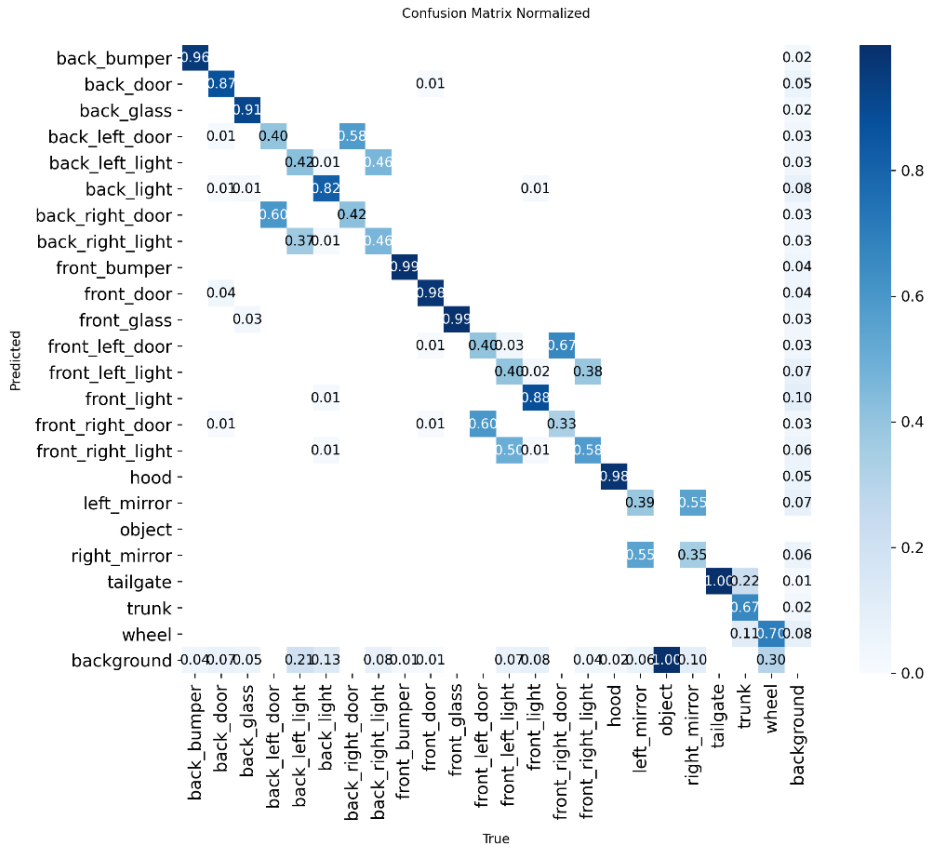


Рис. 6. Матриця плутанини (Confusion matrix) моделі YOLO v.11 при заморожуванні перших 6-ти шарів архітектури




Рис. 7. Матриця плутанини (Confusion matrix) моделі YOLO v.26

Висновки і перспективи досліджень у даному напрямку

Встановлено, що YOLOv8 порівняно з YOLOv11 та YOLO26 має найкращий показник метрики точності.

Експериментально показано, що модель YOLOv11 із заморожування перших шести шарів архітектури забезпечує найвищі значення метрик повноти та mAP50 порівняно з моделлю YOLO26 та попередніми версіями та значення метрик F1 та mAP50-95 гірших менше, ніж на 1 % найкращих значень.

Заморожування шарів архітектури YOLO26 згідно з метриками не дає покращення.

В подальшому планується провести дослідження ефективності моделей по окремих деталях автомобілів, аналіз кореляції стандартних метрик зі змінами в детекції та ідентифікації деталей та перевірку роботи моделей на зображеннях тестової вибірки.

Література

1. Shiza M. Artificial intelligence and industrial applications – A revolution in modern industries / M. Shiza, M. Khalid, W. Yasir // *Ain Shams Engineering Journal*. – 2024. – Volume 15, issue 9. – p.102886. – ISSN 2090-4479. – DOI: <https://doi.org/10.1016/j.asej.2024.102886>.
2. Hossain N. Artificial Intelligence Revolutionizing the Automotive Sector: A Comprehensive Review of Current Insights, Challenges, and Future Scope / N. Hossain, A. Rahim, M. Rahman, D. Ramasam // *Computers, Materials and Continua*. – 2025. – Volume 82, issue 3. – pp. 3643-3692. – ISSN 1546-2218. – DOI: <https://doi.org/10.32604/cmc.2025.061749>.
3. Handbook Assisted and Automated Driving. / Editors: H. Winner, K. C. J. Dietmayer, L. Eckstein et al. – Wiesbaden: Springer, 2026. – 1020 p. – ISBN 978-3-658-45276-6. – DOI: <https://doi.org/10.1007/978-3-658-45276-6>.
4. Bradler A. AI Methods for Driver Assistance Systems and Automated Driving Functions / A. Bradler., R. Rezaei, T. Scheibe et al. // *ATZ Worldwide*, 2025. – Vol. 127, pp. 16–19. – DOI: <https://doi.org/10.1007/s38311-025-2105-x>.
5. Mueller C., Mezhyuev V. AI Models and Methods in Automotive Manufacturing: A Systematic Literature Review / Mueller C., Mezhyuev V. // Al-Emran M., Shaalan K. (eds) *Recent Innovations in Artificial Intelligence and Smart Applications. Studies in Computational Intelligence*. – Cham: Springer, 2022. – Vol. 1061, pp. 1-25. –

DOI: https://doi.org/10.1007/978-3-031-14748-7_1.

6. Beecham M. The future of AI in the automotive industry / M. Beecham, A. Panday, S. Jayanthan. – <https://www.spglobal.com/automotive-insights/en/blogs/2025/07/ai-in-automotive-industry>.

7. Bhattacharya S. AI revolution in insurance: bridging research and reality / S. Bhattacharya, G. Castignani, L. Masello, B. Sheehan // *Frontiers in Artificial Intelligence*, 2025. – Vol 8:1568266. – DOI: 10.3389/frai.2025.1568266.

8. Chandaluri R. Optimized car parts detection with advanced feature fusion and attention modules / R. Chandaluri, P. Vasanthi, L. P. Kothala et al // *Scientific Reports*, 2025. – Vol. 15, no. 45418. – <https://doi.org/10.1038/s41598-025-29855-w>.

9. Yusuf S. A., Aldawsari A. A., Souissi R. Automotive Parts Assessment: Applying Real-time Instance-Segmentation Models to Identify Vehicle Parts / S. A. Yusuf, A. A. Aldawsari, R. Souissi. – 2022. – (arXiv preprint). – DOI: <https://doi.org/10.48550/arXiv.2202.00884>.

10. Susutti W. Real-time Car Part Instance Segmentation: the Comparison of the State-of-the-Art / W. Susutti, S. Laoprom, T. Sutthipanyo et al // 28th International Computer Science and Engineering Conference (ICSEC), Khon Kaen, Thailand. – 2024. – pp. 1-6. – DOI: 10.1109/ICSEC62781.2024.10770635.

11. Gheorghe C. Analyzing Real-Time Object Detection with YOLO Algorithm in Automotive Applications: A Review / C. Gheorghe, M. Duguleana, R. G. Boboc, C. C. Postelnicu // *CMES - Computer Modeling in Engineering and Sciences*. – 2024. – Volume 141, issue 3, - pp. 1939-1981. – ISSN 1526-1492. –

DOI: <https://doi.org/10.32604/cmes.2024.054735>.

12. Huang H. Automotive Parts Defect Detection Based on YOLOv7 / H. Huang, K. Zhu // *Electronics*. – 2024. – Vol. 13, no.10. – p.1817. – DOI: <https://doi.org/10.3390/electronics13101817>.

13. Shaik B. An efficient YOLOV9 model for car parts detection and segmentation / B. Shaik // *Telecommunications and Radio Engineering*. – 2026. – Volume 85, issue 1. – pp. 61-74. – DOI: 10.1615/TelecomRadEng.2025054287.

14. Dhieb N. A Very Deep Transfer Learning Model for Vehicle Damage Detection and Localization / N. Dhieb N., H. Ghazzai, H. Besbes, Y. Massoud // 31st International Conference on Microelectronics (ICM), Cairo, Egypt. – 2019. – pp. 158-161. – DOI: 10.1109/ICM48031.2019.9021687.

15. Gandhi V. Fine-Tuning Without Forgetting: Adaptation of YOLOv8 Preserves COCO Performance / V. Gandhi, S. Gandhi. – 2025. – arXiv preprint. – DOI: <https://doi.org/10.48550/arXiv.2505.01016>.

16. Carparts Segmentation Dataset. Режим доступу: <https://docs.ultralytics.com/datasets/segment/carparts-seg/>.

17. Yuma A. N. Improving Vehicle Detection in Challenging Datasets: YOLOv5s and Frozen Layers Analysis / A. N. Yuma. Rafi, M. Yusuf // *International Journal of Informatics and Computation*. – 2023. – Vol.

5, no. 2. – pp. 31–45. – DOI: 10.35842/ijicom.v5i2.64.

18. YOLO26 Training Recipe. Режим доступу: <https://docs.ultralytics.com/guides/yolo26-training-recipe/#start-simple>.

19. Мамута М. С. Підвищення ефективності виявлення об'єктів моделями YOLOv11 та YOLO26 внаслідок заморожування шарів / М. С. Мамута, І. В. Кравченко, О. Д. Мамута // Вісник Київського політехнічного інституту. Серія Приладобудування. – 2026. – № 71(1). – pp. 36–43.
DOI: 10.20535/1970.71(1).2026.361591

References

1. Shiza M. Artificial intelligence and industrial applications – A revolution in modern industries / M. Shiza, M. Khalid, W. Yasir // *Ain Shams Engineering Journal*. – 2024. – Volume 15, issue 9. – p.102886. – ISSN 2090-4479. –
DOI: <https://doi.org/10.1016/j.asej.2024.102886>.

2. Hossain N. Artificial Intelligence Revolutionizing the Automotive Sector: A Comprehensive Review of Current Insights, Challenges, and Future Scope / N. Hossain, A. Rahim, M. Rahman, D. Ramasam // *Computers, Materials and Continua*. – 2025. – Volume 82, issue 3. – pp. 3643-3692. – ISSN 1546-2218. –
DOI: <https://doi.org/10.32604/cmc.2025.061749>.

3. Handbook Assisted and Automated Driving. / Editors: H. Winner, K. C. J. Dietmayer, L. Eckstein et al. – Wiesbaden: Springer, 2026. – 1020 p. – ISBN 978-3-658-45276-6. – DOI: <https://doi.org/10.1007/978-3-658-45276-6>.

4. Bradler A. AI Methods for Driver Assistance Systems and Automated Driving Functions / A. Bradler., R. Rezaei, T. Scheibe et al. // *ATZ Worldwide*, 2025. – Vol. 127, pp. 16–19. –
DOI: <https://doi.org/10.1007/s38311-025-2105-x>.

5. Mueller C., Mezhyuev V. AI Models and Methods in Automotive Manufacturing: A Systematic Literature Review / Mueller C., Mezhyuev V. // Al-Emran M., Shaalan K. (eds) *Recent Innovations in Artificial Intelligence and Smart Applications. Studies in Computational Intelligence*. – Cham: Springer, 2022. – Vol. 1061, pp. 1-25. –
DOI: https://doi.org/10.1007/978-3-031-14748-7_1.

6. Beecham M. The future of AI in the automotive industry / M. Beecham, A. Panday, S. Jayanthan. – <https://www.spglobal.com/automotive-insights/en/blogs/2025/07/ai-in-automotive-industry>.

7. Bhattacharya S. AI revolution in insurance: bridging research and reality / S. Bhattacharya, G. Castignani, L. Masello, B. Sheehan // *Frontiers in Artificial Intelligence*, 2025. – Vol 8:1568266. –
DOI: 10.3389/frai.2025.1568266.

8. Chandaluri R. Optimized car parts detection with advanced feature fusion and attention modules / R. Chandaluri, P. Vasanthi, L. P. Kothala et al // *Scientific Reports*, 2025. – Vol. 15, no. 45418. –
<https://doi.org/10.1038/s41598-025-29855-w>.

9. Yusuf S. A., Aldawsari A. A., Souissi R. Automotive Parts Assessment: Applying Real-time

Instance-Segmentation Models to Identify Vehicle Parts / S. A. Yusuf, A. A. Aldawsari, R. Souissi. – 2022. – (arXiv preprint). –

DOI: <https://doi.org/10.48550/arXiv.2202.00884>.

10. Susutti W. Real-time Car Part Instance Segmentation: the Comparison of the State-of-the-Art / W. Susutti, S. Laoprom, T. Sutthipanyo et al // 28th International Computer Science and Engineering Conference (ICSEC), Khon Kaen, Thailand. – 2024. – pp. 1-6. – DOI: 10.1109/ICSEC62781.2024.10770635.

11. Gheorghe C. Analyzing Real-Time Object Detection with YOLO Algorithm in Automotive Applications: A Review / C. Gheorghe, M. Duguleana, R. G. Boboc, C. C. Postelnicu // *CMES - Computer Modeling in Engineering and Sciences*. – 2024. – Volume 141, issue 3, - pp. 1939-1981. – ISSN 1526-1492. –

DOI: <https://doi.org/10.32604/cmes.2024.054735>.

12. Huang H. Automotive Parts Defect Detection Based on YOLOv7 / H. Huang, K. Zhu // *Electronics*. – 2024. – Vol. 13, no.10. – p.1817. –

DOI: <https://doi.org/10.3390/electronics13101817>.

13. Shaik B. An efficient YOLOv9 model for car parts detection and segmentation / B. Shaik // *Telecommunications and Radio Engineering*. – 2026. – Volume 85, issue 1. – pp. 61-74. –

DOI: 10.1615/TelecomRadEng.2025054287.

14. Dhieb N. A Very Deep Transfer Learning Model for Vehicle Damage Detection and Localization / N. Dhieb N., H. Ghazzai, H. Besbes, Y. Massoud // 31st International Conference on Microelectronics (ICM), Cairo, Egypt. – 2019. – pp. 158-161. –

DOI: 10.1109/ICM48031.2019.9021687.

15. Gandhi V. Fine-Tuning Without Forgetting: Adaptation of YOLOv8 Preserves COCO Performance / V. Gandhi, S. Gandhi. – 2025. – arXiv preprint. –
DOI: <https://doi.org/10.48550/arXiv.2505.01016>.

16. Carparts Segmentation Dataset. Rezhym dostupu: <https://docs.ultralytics.com/datasets/segment/carparts-seg/>.

17. Yuma A. N. Improving Vehicle Detection in Challenging Datasets: YOLOv5s and Frozen Layers Analysis / A. N. Yuma. Rafi, M. Yusuf // *International Journal of Informatics and Computation*. – 2023. – Vol. 5, no. 2. – pp. 31–45. – DOI: 10.35842/ijicom.v5i2.64.

18. YOLO26 Training Recipe. Rezhym dostupu: <https://docs.ultralytics.com/guides/yolo26-training-recipe/#start-simple>.

19. Mamuta M. Object Detection Improvement with Freezing Layers of YOLOv11 AND YOLO26 / M. Mamuta, I. Kravchenko, O. Mamuta // *Bulletin of Kyiv Polytechnic Institute. Series Instrument Making*. – 2026. – № 71(1). – pp. 36–43.
DOI: 10.20535/1970.71(1).2026.361591.

The article has been sent to the editors 11.06.26.

After processing 21.06.26.

Submitted for printing 30.06.26

Copyright under license CCBY-SA4.0.