

УДК 629.

Горяинов Игорь Александрович,

ведущий инженер-программист, бакалавр, Московский государственный технический университет имени Н. Э. Баумана, ORCID: 0009-0008-7251-

5595,

e-mail: likeiigor@gmail.com

ПОВЕДЕНЧЕСКОЕ КЛОНИРОВАНИЕ ДЛЯ УПРАВЛЕНИЯ БЕСПИЛОТНЫМ АВТОМОБИЛЕМ: ПОДХОД НА ОСНОВЕ ГЛУБОКОГО ОБУЧЕНИЯ И ТЕХНИЧЕСКОГО ЗРЕНИЯ

Аннотация. Актуальность статьи обусловлена необходимостью создания надежных систем управления беспилотными автомобилями в сложной городской среде, где традиционные подходы часто неэффективны. Подход поведенческого клонирования с использованием глубокого обучения и технического зрения предлагает гибкое решение. В работе исследуется подход к управлению беспилотным автомобилем с использованием поведенческого клонирования, глубокого обучения и технического зрения. Разработана система, имеет модули визуального детектирования и систему принятия решений на базе нейронных сетей, обученную на данных имитационной среды.

Цель: разработка и оценка такой системы. Методы: применение симулятора CARLA для сбора обучающих данных и тестирования, разработку модулей распознавания объектов (YOLOv8s) и дорожной полосы (U-Net), создание и сравнение двух архитектур нейронной сети для принятия решений, а также реализацию параллельной архитектуры взаимодействия модулей и интеграцию ПИД-регуляторов.

Результаты показали высокую эффективность vision-модулей в симуляторе (YOLO precision 91%) и значительное превосходство архитектуры нейронной сети с многоканальным входом (снижение ошибки обучения, лучшие показатели в тестах по критериям безопасности).

Выводы подтверждают потенциал поведенческого клонирования с разработанными модулями в имитационной среде, подчеркивая необходимость дальнейших исследований для преодоления проблем данных и адаптации к реальным условиям.

Ключевые слова: беспилотный автомобиль, поведенческое клонирование, глубокое обучение, техническое зрение, CARLA, YOLO, U-Net, принятие решений.

BEHAVIORAL CLONING FOR SELF-DRIVING CAR CONTROL: AN APPROACH BASED ON DEEP LEARNING AND MACHINE VISION

Goriainov Igor Aleksandrovich

Leading Software Engineer, Bachelor's degree, Bauman Moscow State
Technical University, ORCID: 0009-0008-7251-5595,

e-mail: likeiigor@gmail.com

Abstract. The relevance of the article is due to the need to create reliable control systems for self-driving cars in a complex urban environment, where traditional approaches are often ineffective. The approach of behavioral cloning using deep learning and machine vision offers a flexible solution. The paper explores an approach to self-driving car control using behavioral cloning, deep learning and machine vision. A system has been developed that includes visual detection modules and a decision-making system based on neural networks trained on simulation data.

Goal: development and evaluation of such a system. Methods: use of the CARLA simulator for collecting training data and testing, development of object recognition (YOLOv8s) and road lane (U-Net) modules, creation and comparison of two neural network architectures for decision making, as well as implementation of a parallel architecture for module interaction and integration of PID controllers.

The results showed high efficiency of vision modules in the simulator (YOLO precision 91%) and significant superiority of the neural network architecture with

multi-channel input (reduced training error, better performance in tests on safety criteria).

The findings confirm the potential of behavioral cloning with the developed modules in a simulation environment, emphasizing the need for further research to overcome data issues and adapt to real conditions.

Keywords: self-driving car, behavioral cloning, deep learning, machine vision, CARLA, YOLO, U-Net, decision making.

Введение

Создание систем управления беспилотными автомобилями является актуальной и сложной задачей, имеющей значительное социальное и техническое значение [1]. Управление автономным транспортным средством требует точного восприятия окружающей среды, планирования траектории и принятия решений в условиях неопределенности [2]. Традиционные подходы, основанные на формальных правилах, часто сталкиваются с трудностями в сложном и динамичном городском трафике.

Альтернативным направлением является применение методов машинного обучения, в частности глубоких нейронных сетей, для извлечения сложных закономерностей из сенсорных данных и их прямого сопоставления с управляющими воздействиями [4]. Подход поведенческого клонирования предполагает обучение модели имитации поведения человека-водителя на основе собранных данных "наблюдение - действие". Данный метод потенциально может создавать системы, способные демонстрировать более гибкое и человекоподобное поведение в разнообразных дорожных сценариях.

Техническое зрение играет центральную роль в таких системах, поскольку визуальная информация с камер является основным источником данных о дорожной сцене [8]. Эффективное распознавание дорожных объектов (транспортных средств, светофоров, знаков) и определение положения дорожной полосы (U-Net) критически важно для безопасного управления [7].

Целью работы является разработка системы управления беспилотным автомобилем на основе поведенческого клонирования с использованием глубокого обучения и технического зрения.

Методы исследования

Разработка системы управления беспилотным автомобилем базировалась на подходе поведенческого клонирования с применением методов глубокого обучения и технического зрения. Общая архитектура системы имеет блоки визуального детектирования, планирования пути, принятия решений и управления. В качестве среды разработки и сбора обучающих данных выбран открытый имитатор CARLA. Моделирование проводилось на городской карте "Town02", используя модель автомобиля Tesla Model 3, оснащенную двумя камерами. Для сбора пар "наблюдение-действие" разработан Python-скрипт, синхронизирующий изображения с камеры с данными телеметрии и командами оператора. Модуль распознавания дорожных объектов реализован на основе архитектуры YOLOv8s, обученной на собранном датасете из 169 изображений, расширенном аугментацией до 455 снимков, детектирование светофоров, знаков и транспортных средств.

Результаты исследования

Поведенческое клонирование (BC) представляет собой парадигму обучения с учителем, где агент (в данном случае, система управления БА) обучается выполнять задачу путем имитации демонстраций, предоставленных экспертом (человеком-водителем) [14]. Основная идея заключается в том, чтобы выучить отображение $\pi(a_t|o_t)$ из пространства наблюдений o_t (например, изображения с бортовых камер, данные лидара) в пространство действий a_t (например, угол поворота руля, значения акселератора и тормоза). Обучение происходит на основе набора данных, состоящего из пар «наблюдение-действие», собранных во время управления автомобилем экспертом [13].

Преимуществом BC является его концептуальная простота и возможность прямого обучения сложным стратегиям управления без необходимости ручного проектирования функций вознаграждения, как в

обучении с подкреплением, или детального моделирования динамики среды [15]. Ранние успешные применения, такие как система ALVINN, продемонстрировали потенциал подхода для навигации транспортных средств. Однако, классический подход поведенческого клонирования имеет ряд существенных недостатков. Одной из главных проблем является ковариационный сдвиг: распределение наблюдений, с которыми агент сталкивается во время автономной работы, может отличаться от распределения в обучающем наборе данных [12]. Поскольку агент обучается только на тех состояниях, которые посещал эксперт, он может оказаться неспособным корректно отреагировать на новые, непредвиденные ситуации или исправить небольшие ошибки, которые постепенно накапливаются и уводят его с траектории эксперта. Еще одной проблемой является то, что агент учится имитировать действия эксперта, но не обязательно понимает причинно-следственные связи и цели этих действий.

Современные реализации поведенческого клонирования активно используют глубокие нейронные сети, особенно сверточные нейронные сети, для обработки высокоразмерных сенсорных данных, таких как изображения. Использование симуляторов, например, CARLA [6], чтобы генерировать большие объемы разнообразных данных для обучения и тестирования моделей ВС в контролируемой среде, что частично помогает смягчить проблему сбора данных и безопасности на начальных этапах разработки.

Разработанная система управления представлена как совокупность взаимодействующих блоков. Основной блок, получающий изображение с камеры и команду навигатора, выдает управляющие сигналы (рисунок 1).



Рисунок 1 – Обобщенная структурная схема системы

Детальная архитектура (рисунок 2) имеет систему визуального детектирования (объекты и полоса движения), планировщик пути (выдающий команды высокого уровня), систему принятия решений (на базе нейронной сети, обученной поведенческому клонированию) и систему управления (преобразующую желаемый вектор скорости в управляющие сигналы).

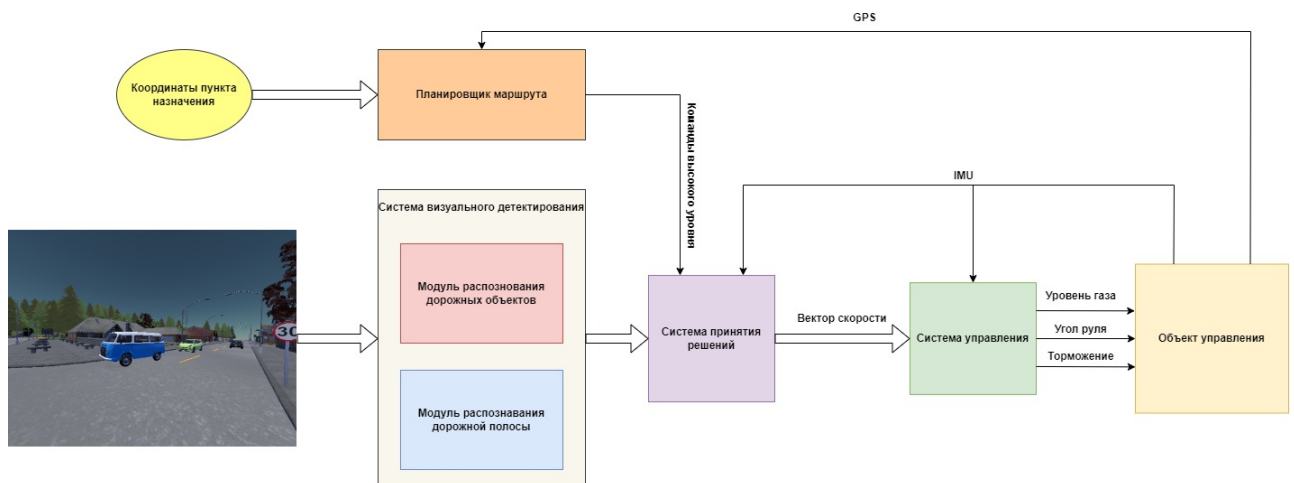


Рисунок 2 – Архитектура разрабатываемой системы

Обучение системы принятия решений требует сбора данных: синхронизированных изображений, данных детектирования, команд планировщика и телеметрии автомобиля с соответствующими управляющими действиями человека.

Для разработки и сбора обучающих данных необходима реалистичная имитационная среда. После анализа доступных симуляторов был выбран CARLA, разработанный Досовицким А. и соавт. [6]. CARLA предоставляет открытый доступ, гибкий API, реалистичное моделирование городской среды, датчиков и объектов.

Моделирование проводилось на карте "Town02" CARLA (рисунки 3) с автомобилем Tesla Model 3.




Рисунок 3 – Общий вид выбранной локации

Схема расположения камер представлена на рисунке 3.



Рисунок 4 – Выбранный объект управления и расположенные на нем камеры

Установлены две RGB-камеры: камера 1 (640x480, 10 Гц) для оператора и камера 2 (1024x512, 5 Гц) для сбора данных технического зрения.

Разработан Python-скрипт для параллельного взаимодействия с симулятором, получения команд оператора и синхронизированного сбора данных с камеры 2 и телеметрии (см. рис. 5).

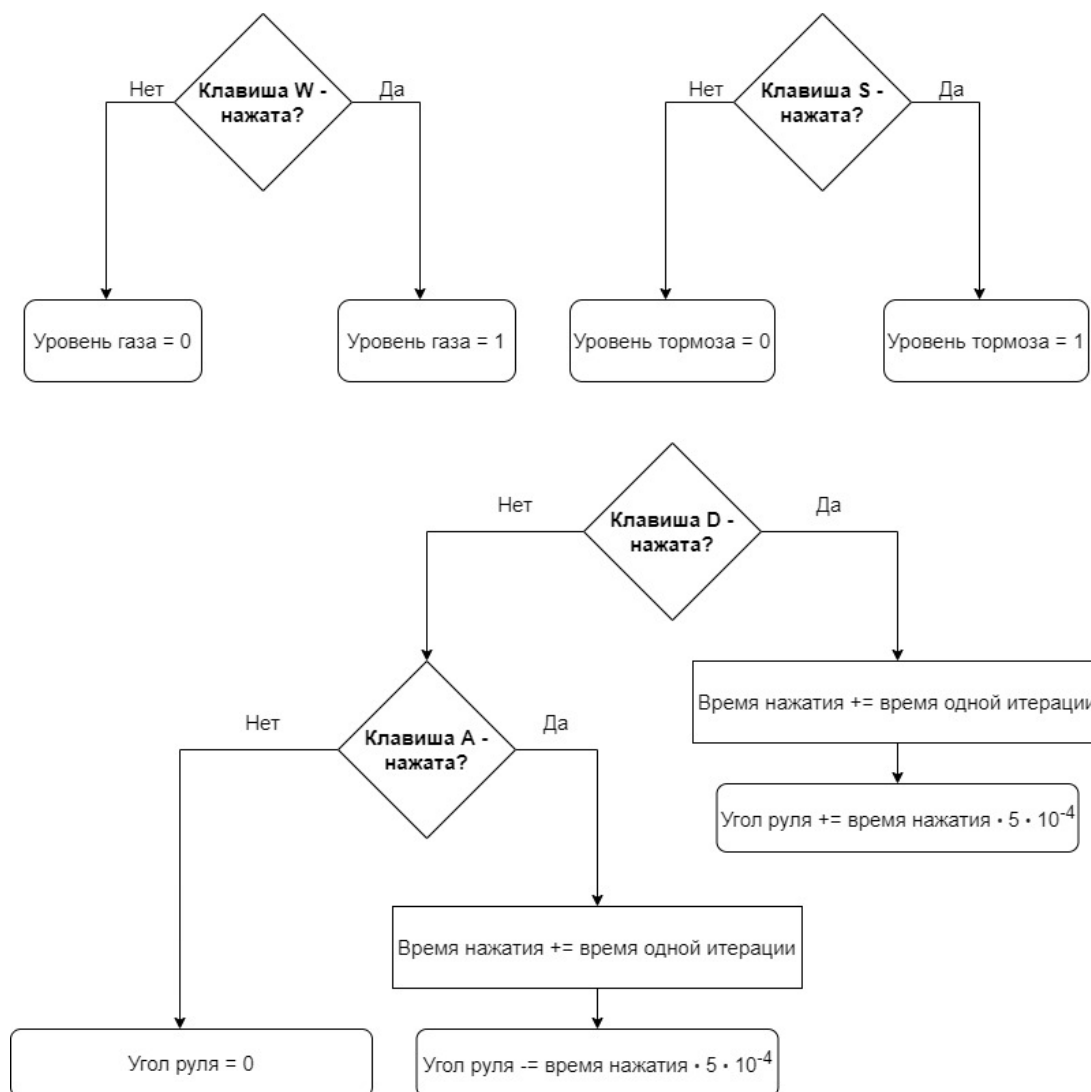


Рисунок 5 – Алгоритм представления управляющих команд

Задача модуля распознавания дорожных объектов – обнаружение и классификация объектов: светофоров (красный, желтый, зеленый), знаков скорости (30, 60, 90) и транспортных средств. Требуется высокая скорость. Выбран алгоритм YOLO как эффективное решение для детекции в реальном времени. Собрано 169 изображений (1024x512) в симуляторе. Размечены 442

объекта с помощью Roboflow. Для увеличения датасета (до 455 снимков) и предотвращения переобучения применена аугментация (поворот, яркость, шум, отражение) (рисунок 6).




Рисунок 6 – Пример аугментации обучающего датасета

Развертывание алгоритма YOLO и обучение YOLOv8s на Google Collaboratory (100 эпох) и результаты обучения показаны на рисунке 7 (loss).

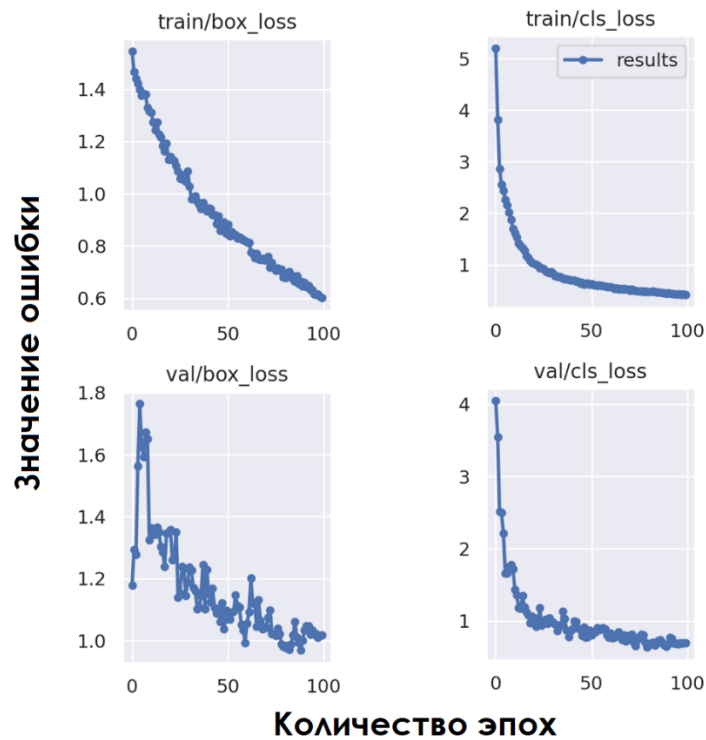


Рисунок 7 – Результаты обучения алгоритма YOLO

Достигнутая точность (precision) 91% на валидационной выборке. Матрица ошибок показала основные ошибки (пропуск объектов, путаница знаков). Пример работы алгоритма YOLO на записанном видеопотоке (рисунок 8) демонстрирует качественную детекцию.



Рисунок 8 – Пример работы алгоритма YOLO на записанном видеопотоке

Несмотря на достигнутый прогресс, создание полностью автономных систем управления на основе исключительно поведенческого клонирования остается сложной задачей, требующей дальнейших исследований в области повышения робастности, безопасности и способности к обобщению.

Обсуждение

Результаты применения поведенческого клонирования, основанного на глубоком обучении и компьютерном зрении, для управления беспилотными автомобилями демонстрируют как значительный потенциал, так и ряд серьезных вызовов. Способность моделей напрямую обучаться на данных экспертного вождения, используя мощные возможности глубоких нейронных сетей для извлечения признаков из сырых сенсорных данных, таких как изображения, является ключевым преимуществом.

Однако, как было отмечено, проблема ковариационного сдвига остается одной из главных преград. Модель, обученная на определенном распределении данных, может демонстрировать непредсказуемое и потенциально опасное поведение при столкновении с ситуациями, выходящими за рамки распределения. Особенно критично для систем, отвечающих за безопасность, таких как БА [2]. Методы, направленные на смягчение проблемы, составляют сбор разнообразных и репрезентативных наборов данных, использование техник аугментации данных, а также применение более продвинутых подходов имитационного обучения, таких как DAgger (Dataset Aggregation), где модель итеративно дообучается на данных, собранных во время ее собственной работы под наблюдением эксперта [11].

Другой важной проблемой является "причинная путаница", когда модель выучивает корреляции вместо реальных причинно-следственных связей. Например, модель может ассоциировать включение стоп-сигналов впереди идущего автомобиля с необходимостью торможения, но не понимать причину такого действия (например, препятствие впереди). Также

ограничивает способность модели к обобщению и адекватному реагированию в новых контекстах [5].

Интерпретируемость решений, принимаемых глубокими нейронными сетями, также является предметом активных исследований [1]. "Черный ящик" природы многих DL-моделей затрудняет анализ причин ошибок и их исправление, что является серьезным препятствием для сертификации и общественного принятия БА[4]. Интеграция модулей явного восприятия, таких как YOLO для обнаружения объектов или семантической сегментации для понимания сцены, может частично решить проблему, предоставляя более понятные промежуточные представления, на основе которых принимается решение об управлении[10]. Такие подходы также могут повысить общую надежность системы, чтобы реагировать на конкретные идентифицированные элементы дорожной обстановки.

Сравнение с другими подходами к управлению БА показывает, что поведенческое клонирование часто рассматривается как один из компонентов более крупной системы. В то время как модульные подходы, разделяющие задачи восприятия, планирования и управления [12], предлагают большую прозрачность и возможность независимой отладки компонентов, подходы, подобные ВС, могут выявлять нелинейные зависимости и оптимизировать систему в целом. Перспективным направлением является гибридизация этих подходов.

Важность качественных и объемных наборов данных для обучения нельзя недооценивать. Разработка эффективных симуляторов и методов сбора данных в реальном мире имеет решающее значение. Кроме того, вопросы, связанные с эффективностью передачи и обработки больших объемов данных, например, в контексте кооперативного восприятия или обновлений моделей через сети связи, также требуют внимания, хотя и выходят за рамки непосредственного фокуса на алгоритмах ВС [8]. Способность системы прогнозировать криволинейное движение или принимать решения о маневрах,

таких как смена полосы (U-Net) или движение в колонне, также может быть улучшена за счет качественного обучения на соответствующих данных [9].

Результаты исследования подтверждают эффективность глубокого обучения для модулей технического зрения (YOLOv8s) и применимость в системе поведенческого клонирования. Высокая точность распознавания объектов и сегментации полосы (U-Net) в имитационной среде являются важными достижениями.

Сравнение архитектур системы принятия решений выявило преимущество варианта с одним многоканальным входом. Этот подход, помогающий сверточной сети совместно обрабатывать пространственную и скалярную информацию, привел к значительному снижению ошибки обучения и улучшению показателей безопасности в симуляторе (таблица 1).

Таблица 1 – Оценка качества работы системы

Вариант системы	K1 k = 1.0	K2 k = 2.0	K3 k = 0.5	K4 k = 2.5	K5 k = 2.7	K6 k = 3.0	K7 k = 2.0	Σ
Первый	5	4	9	2	2	3	4	44.9
Второй	6	5	10	0	1	0	1	25.7

Имитационная среда CARLA показала свою ценность для разработки и сбора данных. Параллельная архитектура с TCP-сокетами является адекватным решением для реального времени. Интеграция с ПИД-регуляторами обеспечивает плавность управления.

Однако, существуют ограничения так как несбалансированность данных для YOLO влияет на точность распознавания редких объектов. Переход от симуляции к реальности остается вызовом. Качество обучающих данных для поведенческого клонирования критично.

Заключение

В данной работе представлен подход к управлению беспилотным автомобилем, основанный на поведенческом клонировании с использованием методов глубокого обучения и технического зрения. Разработана и реализована система, имеющая модули визуального восприятия дорожной среды на базе современных нейронных сетей YOLOv8s для детектирования объектов и U-Net для сегментации дорожной полосы. Показана эффективность этих модулей в условиях имитационной среды CARLA, которая также использовалась для сбора обширного обучающего датасета. Исследованы две архитектуры нейронной сети для системы принятия решений; вариант с единым многоканальным входом продемонстрировал более высокую точность обучения и значительно лучшие результаты в тестовых заездах в симуляторе, подтверждая эффективность совместной обработки визуальных и скалярных данных. Разработана параллельная архитектура взаимодействия модулей посредством TCP-сокетов, обеспечивающая работу системы в режиме, близком к реальному времени, а интеграция с ПИД-регуляторами помогла добиться плавного преобразования выхода нейронной сети в управляющие воздействия. Полученные результаты в имитационной среде демонстрируют потенциал поведенческого клонирования для решения задачи управления беспилотным автомобилем, однако дальнейшие исследования необходимы для устранения ограничений, связанных с качеством и разнообразием обучающих данных, адаптацией системы к реальным условиям и повышением ее общей робастности и безопасности.

Список литературы

1. Грунвальд А., Железняк В. Н., Середкина Е. В. Беспилотный автомобиль в свете социальной оценки техники //Технологос. – 2019. – №. 2. – С. 41-51.
2. Ендачев Д. В. Прогнозирование характеристик криволинейного движения беспилотного автомобиля //ДВ Ендачев: дисс. канд. техн. наук. – 2016. – Т. 5.

3. Калинин А. В., Малая А. Г. Разработка концепции алгоритма управления беспилотного колёсного тягача, движущегося в колонне за направляющим //StudNet. – 2021. – Т. 4. – №. 6. – С. 2110-2123.
4. Юзаева А. Г., Кукарцев В. В. Беспилотные автомобили: опасности и перспективы развития //Актуальные проблемы авиации и космонавтики. – 2016. – Т. 2. – №. 12. – С. 120-122.
5. Altman E. et al. Parallel TCP Sockets: Simple Model, Throughput and Validation //INFOCOM. – 2006. – Т. 2006. – С. 1-12.
6. Dosovitskiy A. et al. CARLA: An open urban driving simulator //Conference on robot learning. – PMLR, 2017. – С. 1-16.
7. Hacker T. J., Athey B. D., Noble B. The end-to-end performance effects of parallel TCP sockets on a lossy wide-area network //Proceedings 16th International Parallel and Distributed Processing Symposium. – IEEE, 2002. – p. 10.
8. Huu P. N., Pham Thi Q., Tong Thi Quynh P. Proposing Lane and Obstacle Detection Algorithm Using YOLO to Control Self-Driving Cars on Advanced Networks //Advances in Multimedia. – 2022. – Т. 2022.
9. Im Choi J., Tian Q. Adversarial attack and defense of YOLO detectors in autonomous driving scenarios //2022 IEEE Intelligent Vehicles Symposium (IV). – IEEE, 2022. – С. 1011-1017.
10. Kim S. W. et al. The impact of cooperative perception on decision making and planning of autonomous vehicles //IEEE Intelligent Transportation Systems Magazine. – 2015. – Т. 7. – №. 3. – С. 39-50.
11. Liu Y. et al. A novel lane change decision-making model of autonomous vehicle based on support vector machine //IEEE access. – 2019. – Т. 7. – С. 26543-26550.
12. Lu S. et al. A fast and robust lane detection method based on semantic segmentation and optical flow estimation //Sensors. – 2021. – Т. 21. – №. 2. – С. 400.

13. Mohr R., Triggs B. Projective geometry for image analysis //XVIIIth International Symposium on Photogrammetry & Remote Sensing (ISPRS'96). – 1996.

14. Schwarting W., Alonso-Mora J., Rus D. Planning and decision-making for autonomous vehicles //Annual Review of Control, Robotics, and Autonomous Systems. – 2018. – T. 1. – C. 187-210.

15. Tang J., Li S., Liu P. A review of lane detection methods based on deep learning //Pattern Recognition. – 2021. – T. 111. – C. 107623.