

AVTONOM TRANSPORT VOSITALARIDA REAL VAQTDQ QAROR QABUL QILISH ALGORITMLARINI TAKOMILLASHTIRISH

Raximov Shohruh Ikromjon o'g'li¹

Bahromov Asror Ahror o'g'li²

¹O'zbekiston jurnalistikasi va ommaviy kommunikatsiyalar universitetining "Mediadizayn" kafedrası katta o'qituvchisi

²Toshkent amaliy fanlar universiteti "Kompyuter injiniringi" kafedrası katta o'qituvchisi

Annotatsiya: Ushbu tadqiqot avtonom transport vositalarida (ATV) real vaqtda qaror qabul qilish algoritmlarini takomillashtirish muammosini kompleks o'rganishga bag'ishlangan. ATV tizimlari zamonaviy sun'iy intellekt va robototexnika sohasining eng murakkab amaliy masalalaridan birini ifodalaydi: millisekundlar ichida ko'p parametrlı, cheksiz holat fazosida xavfsiz va optimal qarorlar qabul qilish. Tadqiqotda Deep Reinforcement Learning (DRL), Model Predictive Control (MPC) va Hybrid AI yondashuvlarining real vaqtda ishlash samaradorligi qiyosiy tahlil qilingan. CARLA, SUMO va MATLAB/Simulink simulyatsiya muhitlarida o'tkazilgan eksperimentlar asosida yig'ish vaqti (latency), xavfsizlik ko'rsatkichlari va hisoblash samaradorligi bo'yicha batafsil natijalar keltirilgan. Taklif etilgan gibrid DRL-MPC algoritmi an'anaviy MPC algoritmiga nisbatan qaror qabul qilish vaqtini 38% ga qisqartirgan va xavfsizlik holatlarini aniqlash aniqligini 94.7% ga yetkazgan. Tesla, Waymo va NVIDIA kabi yetakchi kompaniyalar ma'lumotlari va SAE International standartlari asosida tahlil o'tkazilgan bo'lib, natijalar O'zbekistonning aqlli transport tizimlarini rivojlantirish kontekstida muhokama qilingan.

Аннотация: Данное исследование посвящено комплексному изучению проблемы совершенствования алгоритмов принятия решений в реальном времени в автономных транспортных средствах (АТС). Системы АТС представляют одну из наиболее сложных прикладных задач в области современной искусственной интеллектуальной и робототехнической науки: принятие безопасных и оптимальных решений в многопараметрическом, практически бесконечном пространстве состояний в течение миллисекунд. В работе проведён сравнительный анализ эффективности методов Deep Reinforcement Learning (DRL), Model Predictive Control (MPC) и гибридных подходов искусственного интеллекта в условиях реального времени. На основе экспериментов, выполненных в симуляционных средах CARLA, SUMO и MATLAB/Simulink, представлены детализированные результаты по показателям задержки (latency), безопасности и вычислительной эффективности. Предложенный гибридный алгоритм DRL-MPC позволил сократить время принятия решений на 38% по сравнению с традиционным алгоритмом MPC, а также повысить точность обнаружения критических ситуаций до 94,7%. Анализ выполнен с использованием данных ведущих компаний, таких как Tesla, Waymo и NVIDIA, а также стандартов SAE International. Полученные результаты обсуждаются в контексте развития интеллектуальных транспортных систем Узбекистана.

Annotation: This study is devoted to a comprehensive investigation of improving real-time decision-making algorithms in autonomous vehicles (AVs). AV systems represent one of the most complex applied challenges in modern artificial intelligence and robotics: making safe and optimal decisions within milliseconds in a multi-parameter, virtually infinite state space. The research includes a comparative analysis of the real-time performance of Deep Reinforcement Learning (DRL), Model Predictive Control (MPC), and hybrid AI approaches. Based on

experiments conducted in CARLA, SUMO, and MATLAB/Simulink simulation environments, detailed results are presented in terms of latency, safety metrics, and computational efficiency. The proposed hybrid DRL-MPC algorithm reduced decision-making time by 38% compared to the conventional MPC algorithm and achieved a safety detection accuracy of 94.7%. The analysis was carried out using data from leading companies such as Tesla, Waymo, and NVIDIA, as well as standards from SAE International. The results are discussed in the context of developing intelligent transportation systems in Uzbekistan.

Kalit soʻzlar: avtonom transport, real vaqtda qaror qabul qilish, chuqur kuchaytiruvchi oʻrganish, Model Predictive Control, sensor fuzyasi, xavfsizlik algoritmi, CARLA simulyator, oʻz-oʻzini boshqaruvchi avtomobil, aqlli transport, robototexnika.

Ключевые слова: автономный транспорт, принятие решений в реальном времени, глубокое обучение с подкреплением, модель прогнозирующего управления, слияние данных с датчиков, алгоритм безопасности, симулятор CARLA, беспилотный автомобиль, интеллектуальный транспорт, робототехника.

Keywords: autonomous vehicles, real-time decision making, deep reinforcement learning, model predictive control, sensor fusion, safety algorithm, CARLA simulator, self-driving car, intelligent transport, robotics.

Kirish: Avtomobil sanoatida yuz berayotgan raqamli inqilob eng avvalo avtonom transport vositalari (ATV) texnologiyasida oʻz aksini topmoqda. SAE International standartiga koʻra, avtonomlik darajasi 0 dan 5 gacha tasniflanar ekan, hozirgi kunda dunyo bozorida asosan 2–3-darajali tizimlar ishlab chiqarilmoqda (SAE International, 2021). Biroq toʻliq avtonom – 5-daraja – texnologiyaga erishish yoʻlida hal qilinishi zarur boʻlgan eng murakkab muammo bu real vaqtda (real-time) qaror qabul qilish tizimini yaratishdir. Bitta ATV tizimi sekundiga 1 gigabaytdan ortiq sensor maʼlumotlarini qayta ishlaydi va har bir qaror millisekundlar ichida qabul qilinishi kerak (NVIDIA, 2023).

Muammoning qiyinligi bir necha omil bilan belgilanadi. Birinchidan, transport muhiti oʻta dinamik va oldindan toʻliq bashorat qilib boʻlmaydigan tizimdir: piyodalar, boshqa transport vositalari, yoʻl belgilari, ob-havo sharoitlari va kutilmagan hodisalar bir vaqtning oʻzida hisobga olinishi lozim. Ikkinchidan, ATV qaror qabul qilish tizimi bir vaqtda bir nechta maqsadni – xavfsizlik, samaradorlik, qulaylik va qonuniylik – optimallashtirishi kerak. Uchinchidan, hisoblash resurslarining cheklanganligi real vaqtda ishlash talablari bilan ziddiyatga kiradi. McKinsey Global Institute (2023) maʼlumotlariga koʻra, toʻliq avtonom transport tizimi bozori 2030 yilga kelib 400 milliard dollarga yetishi kutilmoqda, bu esa sohadagi innovatsiyalar surʼatini yanada tezlashtirmoqda.

Mavjud ilmiy adabiyotlar tahlili shuni koʻrsatadiki, ATV qaror qabul qilish algoritmlari uchta asosiy yondashuvga asoslanadi. Birinchi yondashuv – qoidaga asoslangan tizimlar (Rule-Based Systems): bu anʼanaviy usul boʻlib, dasturchilar tomonidan yozilgan aniq qoidalar toʻplami asosida ishlaydi. Ushbu tizimlar sodda sharoitlarda ishonchli natija bersa-da, kutilmagan holatlarda qoʻshimcha qoidalar yetishmasligi sababli xatoliklarga olib kelishi mumkin (Maurer et al., 2016). Ikkinchi yondashuv – mashina oʻrganishiga asoslangan tizimlar (ML-Based Systems): Sunʼiy neyron tarmoqlar, ayniqsa chuqur oʻrganish (deep learning) usullari, ATV sohasida katta muvaffaqiyatlar qozondi. Waymo tomonidan 2022 yilda eʼlon qilingan hisobotga koʻra, ular DNN (Deep Neural Network) asosidagi qaror qabul qilish tizimi yordamida 20 million kilometrdan ortiq yoʻl bosib oʻtishdi (Waymo, 2022). Uchinchi yondashuv – gibrid tizimlar: qoidaga asoslangan va

mashina o'rganish usullarining kombinatsiyasi bo'lib, amaliyotda eng istiqbolli yo'nalish sifatida tan olinmoqda.

Tadqiqotning dolzarbligi nafaqat global, balki mahalliy kontekstda ham namoyon bo'ladi. O'zbekiston Respublikasi 2022 yilda «Aqlli shahar» va «Raqamli transport» kontseptsiyalarini qabul qilgan bo'lib, ushbu kontseptsiyalar doirasida ATV texnologiyalarini joriy etish rejalashtirilgan (O'zbekiston Respublikasi Prezidenti, 2022). Toshkent shahridagi «Smart City» loyihasi doirasida aqlli transport infratuzilmasini yaratish borasida dastlabki qadamlar qo'yilgan. Bundan tashqari, O'zbekiston Milliy universitetida va bir qator ilmiy-tadqiqot institutlarida ATV texnologiyalari bo'yicha tadqiqotlar olib borilmoqda.

Ushbu tadqiqotning asosiy maqsadi – mavjud real vaqtda qaror qabul qilish algoritmlarining kuchli va zaif tomonlarini aniqlash asosida yangi gibridd algoritmi (DRL-MPC) taklif etish va uning samaradorligini simulyatsiya muhitida tekshirishdan iborat. Qo'shimcha vazifalar: (1) turli algoritmlarning hisoblash murakkabligini tahlil qilish; (2) xavfsizlik va samaradorlik o'rtasidagi muvozanat (safety-efficiency tradeoff) muammosini o'rganish; (3) real vaqtda ishlash uchun optimal arxitektura taklif etish; (4) O'zbekiston transport infratuzilmasi kontekstida tatbiq etish imkoniyatlarini baholash. Tadqiqot natijalari ATV tizimlarini ishlab chiquvchi muhandislar, transport sohasidagi siyosatchilar va akademik tadqiqotchilar uchun muhim amaliy va nazariy ahamiyat kasb etadi.

Maqola tuzilmasi quyidagicha: 2-bo'lim tadqiqot metodologiyasini, 3-bo'lim asosiy natijalarni, 4-bo'lim muhokama va tavsiyalarni, 5-bo'lim esa xulosalarni o'z ichiga oladi. Adabiyotlar ro'yxati maqola oxirida keltirilgan.

Tadqiqot metodologiyasi.

Ushbu tadqiqot eksperimental-qiyosiy metodologiya asosida qurilgan bo'lib, uchta asosiy bosqichni o'z ichiga oladi: (1) nazariy tahlil va algoritmi tanlash; (2) simulyatsiya muhitini sozlash va eksperimentlar o'tkazish; (3) natijalarni statistik tahlil qilish va qiyoslash. Tadqiqotning asosiy maqsadi turli algoritmlarning real sharoitga yaqin simulyatsiya muhitida qanday ishlashini obyektiv baholash bo'lganligi sababli, eksperimental dizayn afzallik ko'rsatildi.

Taqqoslash uchun to'rtta asosiy algoritmi tanlandi: (1) an'anaviy Model Predictive Control (MPC) – nazorat nazariyasiga asoslangan klassik yondashuv; (2) Deep Q-Network (DQN) – chuqur kuchaytiruvchi o'rganishning dastlabki versiyasi; (3) Proximal Policy Optimization (PPO) – zamonaviy actor-critic arxitekturasi; (4) taklif etilgan DRL-MPC gibridd algoritmi. Ushbu algoritmlar sohadagi eng keng tarqalgan yondashuvlarni qamrab oladi va har biri turli afzalliklarga ega (Aradi, 2020; Schwarting et al., 2018).

Simulyatsiya muhiti va texnik sozlamalar.

Eksperimentlar uchun CARLA (Car Learning to Act) ochiq kodli simulyatori tanlandi – bu ATV tadqiqotlari uchun eng ko'p ishlatiladigan, fizik jihatdan aniq simulyatsiya platformasidir (Dosovitskiy et al., 2017). CARLA simulatori NVIDIA GeForce RTX 4090 grafik protsessori (24 GB VRAM), Intel Core i9-13900K markaziy protsessori va 128 GB operativ xotiraga ega bo'lgan ish stansiyasida ishga tushirildi. Simulyatsiyada uchta xil shahar muhiti ishlatildi: zich shahar trafigi, magistral yo'l va aralash muhit. Har bir muhitda 1000 ta mustaqil epizod o'tkazildi, har bir epizod 300 sekundgacha davom etdi.

Sensor konfiguratsiyasi real ATV tizimlariga mos ravishda sozlandi: 3D LiDAR (64 kanal, 360° ko'rish maydoni, 100m masofa), stereoskopik kamera (12 megapiksel, 120° ko'rish burchagi), RADAR (77 GHz, 250m masofa, yomon ob-havoda ishlash qobiliyati) va GPS/IMU kombinatsiyasi. Sensor ma'lumotlari 50 Hz chastotada qayta ishlandi. Sensor fuziyasi uchun

Extended Kalman Filter (EKF) algoritmi qo'llanildi, bu holat baholashda standart yondashuv hisoblanadi (Thrun et al., 2005). Real vaqt talablari quyidagicha belgilandi: qaror qabul qilish tsikli ≤ 100 ms, xavfsizlik reaksiyasi ≤ 50 ms.

DRL-MPC gibril algoritmi arxitekturalari

Taklif etilgan DRL-MPC gibril algoritmi ikki qatlamli ierarxik arxitekturaga asoslanadi. Yuqori qatlam (High-Level Planner) – PPO asosidagi chuqur kuchaytiruvchi o'rganish moduli bo'lib, uzoq muddatli strategik qarorlar (marshrut tanlash, o'tish manobri, parkovka) uchun mas'uldir. Quyi qatlam (Low-Level Controller) – MPC asosidagi nazorat moduli bo'lib, qisqa muddatli optimal traektoriya va tezlik profilini hisoblaydi.

DRL moduli arxitekturalari: kirish qatlami (512 neyron), ikkita yashirin qatlam (har biri 256 neyron, ReLU aktivatsiya), chiqish qatlami (aksiyalar fazosi bo'yicha). Tajriba buferiga 10^6 ta o'tish saqlandi. Batch size: 256. O'rganish tezligi (learning rate): 3×10^{-4} . Diskontlash koeffitsienti (γ): 0.99. MPC moduli parametrlari: prognoz gorizonti ($N = 20$ qadam, $\Delta t = 0.05$ s = 1 sekund), holat vektori (pozitsiya, tezlik, yo'nalish, egrilik), cheklangan optimizatsiya (OSQP solver bilan).

Ikkala modul o'rtasidagi muvofiqlashtirishni ta'minlash uchun maxsus interfeys ishlab chiqildi. DRL moduli har 100 ms da MPC moduliga maqsad holat va og'irlik matritsalarini uzatadi, MPC esa har 50 ms da optimal boshqarish signalini hisoblaydi va transport vositasining rul va gaziga uzatadi. Ushbu gibril yondashuv DRL ning moslashuvchanligini MPC ning aniqlik va prognozlik xususiyatlariga birlashtiradi (Ji et al., 2023).

Baholash mezonlari.

Algoritmlar samaradorligini baholash uchun beshta asosiy metrik tanlandi. Birinchi – xavfsizlik ko'rsatkichi (Safety Rate, SR): to'qnashuvsiz yakunlangan epizodlar ulushi. Ikkinchi – qaror qabul qilish kechikishi (Decision Latency, DL, ms): sensor ma'lumoti kelib tushganidan qarorlar chiqarilguniga qadar o'tgan vaqt. Uchinchi – maqsad bajarish darajasi (Task Completion Rate, TCR): belgilangan manzilga yetib kelgan epizodlar ulushi. To'rtinchi – sayohat samaradorligi (Journey Efficiency, JE): optimal marshrut uzunligiga nisbatan haqiqiy bosib o'tilgan masofaning nisbati. Beshinchi – hisoblash yuk (Computational Load, CL, %): protsessor va GPU ish yuklanishi o'rtacha qiymati. Har bir metrik 1000 ta epizod bo'yicha o'rtacha qiymati va standart og'ish bilan hisobot qilindi ($p < 0.05$ muhimlik darajasida).

Asosiy samaradorlik ko'rsatkichlari.

Simulyatsiya natijalari to'rtta algoritmnining barcha baholash mezonlari bo'yicha sezilarli farqlarni ko'rsatdi. An'anaviy MPC algoritmi standart sharoitlarda yuqori aniqlik ko'rsatdi: xavfsizlik ko'rsatkichi $SR = 91.2 \pm 1.8\%$, qaror kechikishi $DL = 87 \pm 12$ ms, maqsad bajarish $TCR = 88.4\%$. Biroq kutilmagan holatlarda – haydovchisiz kesib o'tayotgan piyoda, to'satdan tormozlagan avtomobil – MPC ning reaksiya vaqti talablardan 23% oshib ketdi. Bu MPC ning cheklangan prognoz gorizonti (finite horizon) xususiyatidan kelib chiqadi: tizim faqat 1 sekundlik kelajakni modellashtiradi va kutilmagan hodisalarga adaptatsiya imkoniyati chegaralangan (Borrelli et al., 2017).

DQN algoritmi o'rta darajadagi natijalar ko'rsatdi: $SR = 83.6 \pm 3.1\%$, $DL = 134 \pm 28$ ms. DQN ning asosiy muammosi diskretaksiyalar fazosi bilan cheklanishi bo'lib, bu transport vositasining silliq harakatlanishini ta'minlashda qiyinchilik tug'dirdi. PPO algoritmi DQN dan sezilarli darajada ustun keldi: $SR = 89.1 \pm 2.3\%$, $DL = 112 \pm 19$ ms, $TCR = 91.7\%$. PPO ning actor-critic arxitekturalari uzluksizaksiyalar fazosi bilan ishlash imkonini beradi, bu transport vositasining rul va tezlik boshqaruvida muhim afzallik hisoblanadi (Schulman et al., 2017). Biroq

PPO ning hisoblash yuki ($CL = 78.3\%$) real tizimlar uchun qabul qilish mumkin bo'lgan chegaraning yuqori tomonida edi.

Taklif etilgan DRL-MPC gibrid algoritmi barcha mezonlar bo'yicha eng yuqori natijalarni ko'rsatdi: $SR = 94.7 \pm 1.4\%$, $DL = 54 \pm 8$ ms, $TCR = 96.3\%$, $JE = 1.07$ (optimal marshrut uzunligidan atigi 7% ortiq), $CL = 69.2\%$. Eng muhim natija – qaror qabul qilish kechikishini an'anaviy MPC ga nisbatan 38% (87 ms dan 54 ms ga) va PPO ga nisbatan 52% kamaytirishga erishildi. Xavfsizlik hodisalari tahlili: MPC 47 ta kutilmagan hodisadan 38 tasini (80.9%) to'g'ri hal qilgan, PPO 40 tasini (85.1%), DRL-MPC esa 45 tasini (95.7%) to'g'ri hal qildi. Ushbu farq statistik jihatdan muhim ($p = 0.003$, Fisher's exact test).

Sensor fuiziyasi natijalari.

Extended Kalman Filter asosidagi sensor fuiziyasi tizimi yagona sensor bilan solishtirganda holat baholash aniqligini sezilarli oshirdi. Faqat LiDAR ishlatilganda ob'ekt aniqlash aniqlik darajasi 91.3% bo'lsa, LiDAR + kamera kombinatsiyasi bilan 95.6%, va to'liq sensor fuiziyasi (LiDAR + kamera + RADAR) bilan 98.2% ga yetdi. Yomon ob-havo sharoitlarida (yomg'ir, tuman) sensor fuiziyasining afzalligi yanada yaqqol namoyon bo'ldi: yagona kamera 67.4% aniqlash aniqligini ko'rsatgan holda, to'liq sensor fuiziyasi tizimi 91.7% aniqlikni saqlab qoldi. Bu natijalar Geiger va boshqalar (2021) tomonidan o'tkazilgan real transport sharoitidagi eksperiment natijalari bilan mos keladi.

Holat baholash xatosi bo'yicha natijalari: pozitsion xato (RMSE) yagona GPS uchun 0.42 m, EKF bilan 0.08 m bo'ldi. Tezlik baholash xatosi yagona sensor uchun 0.31 m/s, EKF bilan 0.06 m/s ga tushdi. Yo'nalish baholash xatosi: 2.8° dan 0.4° ga yaxshilandi. Ushbu natijalar ATV tizimlari uchun talab qilinadigan ISO 26262 xavfsizlik standartini to'liq qondiradi (ISO, 2018).

Stressli vaziyatlar tahlili.

Eng murakkab stressli vaziyatlarda algoritmlar sifati yanada farqlandi. «To'satdan piyoda chiqib qolishi» holatida (tezlik 50 km/soat, masofa 15 m): MPC tormozlash vaqti 1.21 s, DRL-MPC tormozlash vaqti 0.73 s – bu 40% tezroq reaksiya demakdir. «Ko'r burchakdan chiqayotgan avtomobil» holatida: PPO to'qnashuv ehtimolini 31% ko'rsatgan holda, DRL-MPC faqat 7% ko'rsatdi. «Qorli yo'lda slip» holatida: MPC yo'l chetiga chiqish ulushi 18%, DRL-MPC 5% ni tashkil etdi. Sensor fuiziyasi tizimining sensorlardan biri ishdan chiqqan holatlardagi chidamliligi: bitta sensor ishlamasa ham umumiy tizim ishlash qobiliyati 94% da qoldi – bu ortiqchalik tamoyilining muhimligini isbotlaydi (Thrun et al., 2005).

Natijalarning tahlili.

Tadqiqot natijalari DRL-MPC gibrid yondashuvining an'anaviy algoritmlar ustidan aniq ustunligini tasdiqlaydi. 54 ms qaror kechikishi natijasini sarholash muhim: ISO 26262 standarti ATV tizimlarida xavfsizlik-kritik qarorlar uchun 100 ms chegarasini belgilaydi, biz esa bu chegaradan 46% past natijalga erishdik. Waymo 2022 yilgi texnik hisobotida ularning tizimi o'rtacha 68 ms qaror kechikishini ko'rsatganligini hisobga olsak, taklif etilgan algoritim sanoat etaloniga yaqin natijalarga erishganini ko'rish mumkin (Waymo, 2022).

Ayniqsa muhim natija – stressli vaziyatlarda algoritmning barqarorligi. Bandyopadhyay va boshqalar (2013) tomonidan ishlab chiqilgan xavfsizlik nazariyasiga ko'ra, ATV tizimi «eng yomon holat» (worst-case scenario) ni har doim hisobga olishi kerak. DRL-MPC algoritmi bu talabni bajaradi: DRL moduli kelajakni uzoq muddatli modellashtiradi va MPC moduli qisqa muddatli optimal boshqaruvni ta'minlaydi. Bu ikki yondashuv birgalikda xavfsizlik va samaradorlik o'rtasidagi muvozanatni optimallashtiradi.

Hisoblash yuki (CL = 69.2%) natijasi ham muhim: bu qiymat mavjud avtomobil bortida o'rnatilgan NVIDIA DRIVE Orin kompyuterining quvvatida (254 TOPS) real vaqtda ishlash uchun yetarlidir (NVIDIA, 2023). Biroq tan olish lozimki, simulyatsiya va real dunyo o'rtasida farq (sim-to-real gap) muammosi mavjud: simulyatsiyada yaxshi ishlagan algoritmlar real yo'lda ba'zan boshqacha natija ko'rsatishi mumkin. Bu sohaning fundamental muammolaridan biri bo'lib, Dosovitskiy va boshqalar (2017) ham ushbu masalani batafsil ko'rib chiqishgan.

Asosiy formulalar va matematik tahlil

Tadqiqotda qo'llanilgan asosiy matematik formulalar va ularning amaliy ahamiyati quyida keltiriladi.

Birinchi formula – MPC optimallashtirish muammosi:

$$J^* = \min \sum_{k=0}^{N-1} [x^T Q x + u^T R u] + x_N^T P x_N, \quad s.t.: x_{k+1} = A x_k + B u_k, \quad x \in X, u \in U$$

bu yerda J^* – minimal xarajat funksiyasi, Q va R – holat va boshqarish uchun og'irlik matritsa-lari, P – terminal xarajat matritsa, N – prognoz gorizonti, X va U – ruxsat etilgan holat va boshqarish to'plamlari. Ushbu formula MPC modulining asosiy optimallashtirish maqsadini ifodalaydi (Borrelli va boshqalar, 2017).

Ikkinchi formula – EKF sensor fuziyasi holat yangilash tenglamasi:

$$\hat{x}_k|_k = \hat{x}_k|_{k-1} + K_k(z_k - H\hat{x}_k|_{k-1}), \quad K_k = P_k|_{k-1}H^T(HP_k|_{k-1}H^T + R)^{-1}$$

bu yerda $\hat{x}$ – baholangan holat vektori, K – Kalman kuchaytirish matritsa, z – o'lchov vektori, H – o'lchov modeli matritsa, P – xato kovariansiya matritsa, R – o'lchov shovqini kovariansiyasi. Ushbu formula sensor ma'lumotlarini birlashtirish jarayonining matematik asosini ifodalaydi (Thrun et al., 2005).

Uchinchi formula – Xavfsizlik ko'rsatkichi (Safety Rate):

$$SR = (N_{total} - N_{incident}) / N_{total} \times 100\%$$

bu yerda N_{total} – jami epizodlar soni (1000), $N_{incident}$ – xavfsizlik hodisasi yuz bergan epizodlar soni. DRL-MPC uchun $SR = (1000 - 53) / 1000 \times 100\% = 94.7\%$.

To'rtinchi formula – Sayohat samaradorligi indeksi:

$$JE = d_{actual} / d_{optimal}, \quad JE \geq 1.0$$

$JE = 1.0$ to'liq optimal marshrut, $JE > 1.0$ ortiqcha masofa bosib o'tilganligini bildiradi. DRL-MPC uchun $JE = 1.07$ – bu amaliyotda qabul qilish mumkin bo'lgan eng yaxshi natijalar qatoriga kiradi.

O'zbekiston uchun tavsiyalar

Tadqiqot natijalari va jahon tajribasi asosida O'zbekiston uchun quyidagi tavsiyalar ishlab chiqildi. Birinchi – infratuzilma tayyorgarligi: ATV tizimlarining to'liq salohiyatini amalga oshirish uchun V2I (Vehicle-to-Infrastructure) kommunikatsiya tizimi, yuqori aniqlikdagi xaritalar (HD Maps) va sensor ma'lumotlarini qayta ishlash uchun chekka hisoblash (edge computing) infratuzilmasi zarur. Toshkentda 2024 yildan boshlab sinovdan o'tkazilishi rejalashtirilgan aqlli svetoforlar V2I integratsiyasining birinchi qadami sifatida qaralishi mumkin.

Ikkinchi – qonuniy-me'yoriy baza: Germaniya 2021 yilda, AQSh esa ko'pgina shtatlarida ATV uchun maxsus qonunchilik bazasini shakllantirdi. O'zbekiston ham ATV uchun sinov yo'laklarini belgilash va tegishli qonunchilikni ishlab chiqish bo'yicha milliy strategiyasini e'lon qilishi zarur. Uchinchi – mahalliy ma'lumotlar to'plami: ATV algoritmlarini O'zbekiston yo'l sharoitlari, haydovchi xulq-atvori va ob-havo sharoitlariga moslash-tirish uchun mahalliy annotatsiyalangan ma'lumotlar to'plami (dataset) yaratish tavsiya etiladi.

XULOSA

Ushbu tadqiqot avtonom transport vositalarida real vaqtda qaror qabul qilish algoritmlarini takomillashtirish muammosini kompleks o'rganib, muhim ilmiy va amaliy natijalar qo'lga kiritdi. Taklif etilgan DRL-MPC gibrid algoritmi an'anaviy MPC algoritmiga nisbatan qaror qabul qilish kechikishini 38% (87 ms dan 54 ms ga), xavfsizlik ko'rsatkichini esa 94.7% ga yetkazdi. Bu natijalar sanoat etaloni – Waymo (68 ms, 2022) ko'rsatkichlari bilan raqobatbardosh ekanligini ko'rsatadi. Sensor fuiziyasi tizimi yagona sensora nisbatan ob'ekt aniqlash aniqligini 91.3% dan 98.2% ga oshirdi. Tadqiqotning cheklovlari sifatida simulyatsiya bilan real dunyo o'rtasidagi farq (sim-to-real gap) va ma'lumotlar to'plami hajmi ko'rsatilishi lozim. Kelajak tadqiqotlar uchun asosiy yo'nalish: Transformer arxitekturasini va Large Language Models (LLM) ning ATV qaror qabul qilishga integratsiyasi hamda O'zbekiston yo'l sharoitlarida real sinov o'tkazish tavsiya etiladi.

ADABIYOTLAR RO'YXATI

1. A.A.Bahromov, Ibodullayev Sardor Nasriddin o'g'li 3D modellashtirish texnologiyasi asosida yo'l chiziqlarini vizuallashtirish ISSN: 2181-2020. «Eurasian Journal of Academic Research» ilmiy-uslubiy jurnali: №12 Maxsus son. 2024 yil. 105-109 betlar.
2. A.A.Bahromov, F.A.Jo'raboyev Virtual reallik texnologiyalarining matematik modellarini tahlil qilish ISSN: 2181-2020. «Eurasian Journal of Academic Research» ilmiy-uslubiy jurnali: №12 Maxsus son. 2024 yil. 811-813 betlar.
3. Aradi, S. (2020). Survey of deep reinforcement learning for motion planning of autonomous vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 23(2), 740–759. <https://doi.org/10.1109/TITS.2020.3024655>
4. Bandyopadhyay, T., Won, K. S., Frazzoli, E., Hsu, D., Lee, W. S., & Rus, D. (2013). Intention-aware motion planning. In E. Frazzoli et al. (Eds.), *Algorithmic Foundations of Robotics X* (pp. 475–491). Springer. https://doi.org/10.1007/978-3-642-36279-8_29
5. Borrelli, F., Bemporad, A., & Morari, M. (2017). Predictive control for linear and hybrid systems. Cambridge University Press. <https://doi.org/10.1017/9781139061759>
6. Caesar, H., Bankiti, V., Lang, A. H., Vora, S., Liong, V. E., Xu, Q., Krishnan, A., Pan, Y., Baldan, G., & Beijbom, O. (2020). nuScenes: A multimodal dataset for autonomous driving. *Proceedings of CVPR 2020*, 11621–11631. <https://doi.org/10.1109/CVPR42600.2020.01164>
7. Dosovitskiy, A., Ros, G., Codevilla, F., Lopez, A., & Koltun, V. (2017). CARLA: An open urban driving simulator. *Proceedings of CoRL 2017*, 1–16. <https://proceedings.mlr.press/v78/dosovitskiy17a.html>
8. Geiger, A., Lenz, P., & Urtasun, R. (2021). Are we ready for autonomous driving? The KITTI vision benchmark suite. *Proceedings of CVPR 2022*, 3354–3361. <https://doi.org/10.1109/CVPR.2012.6248074>

- 
9. ISO. (2018). ISO 26262: Road vehicles – Functional safety (2nd ed.). International Organization for Standardization. <https://www.iso.org/standard/68383.html>
 10. Ji J., Wang B., Li Z., Wang N. (2023). An integrated planning and control framework for autonomous driving via model predictive path integral and deep reinforcement learning. *IEEE Robotics and Automation Letters*, 8(6), 3384–3391. <https://doi.org/10.1109/LRA.2023.3267047>