

DOI: <https://doi.org/10.5281/zenodo.17213290>

KO'P-TUZILMALI MUHITDA TOZALOVCHI ROBOT UCHUN DISTRIBUTIONAL REINFORCEMENT LEARNING ASOSIDAGI MARSHRUT REJALASHTIRISH STRATEGIYASI

Maxsudxonov Amixon Ag'lamxon o'g'li

amirxonmaqsudxonov4@gmail.com

Annotatsiya - Ushbu maqola noma'lum muhitlarda harakatlanuvchi **tozalovchi robot** uchun yangi marshrut rejalashtirish strategiyasini taklif etadi. Taklif qilingan yondashuv *Lightweight Learned Image Denoising with Instance Adaptation (LIDIA)* va *Deep Q-Network (DQN)* texnologiyalarini yagona ramkaga (framework) integratsiyalash orqali amalga oshiriladi. Ushbu kombinatsiya robotlarga ko'p ob'yektli hududlarda to'qnashuvsiz harakatlanish imkonini beradi. Birinchi bosqichda, muhitning chuqurlik tasvirlari robotning o'rnatilgan kamerasidan olinadi. Bu xom tasvirlar odatda shovqinli bo'lgani sababli, *LIDIA* texnologiyasi qo'llanilib, ma'lumotlar kalibrlanadi va tasvir sifati yaxshilanadi.

Qayta ishlangan chuqurlik ma'lumotlari keyinchalik *distributional reinforcement learning* modelini — *DQN*ni — o'qitishda ishlatiladi. Ushbu jarayon robotga noaniqlik sharoitida asosli va moslashuvchan qarorlar qabul qilish qobiliyatini oshiradi. Bundan tashqari, modelga sub-goal (oraliq maqsad) mexanizmi qo'shilgan bo'lib, u robotning murakkab muhitlarda harakatini yengillashtiradi va katta vazifalarni kichik, boshqariladigan bosqichlarga bo'lib beradi. Tasvirlar *LIDIA* qo'llanilgandan oldin va keyin, shuningdek mukofot funksiyasining qiymatlari turli muhit stsenariylarida tahlil qilinib, taklif etilgan yondashuvning samaradorligi baholangan. Turli xil xarita konfiguratsiyalarida o'tkazilgan tajribalar natijalari shuni ko'rsatadiki, taklif etilgan usul boshqa usullarga qaraganda qisqaroq va silliq yo'lga ega marshrutlar hosil qiladi, hatto murakkab muhit sharoitlarida ham.

Kalit so'zlar: Muhitda tozalovchi robot, Path – planning, *Distributional reinforcement learning*, *DQN Network*, Sub – reward mechanism

KIRISH

Muhitda tozalovchi robot (MTRlar) sanoatda, masalan, logistika, transport, qishloq xo'jaligi, qurilish va sanoat avtomatlashtirish kabi ko'plab vazifalarda insonlarni almashtira olishlari sababli keng qo'llanilmoqda. Yaqinda MTRlar sanoat bo'lmagan, ya'ni patrolling, qutqarish faoliyatlari, qariyalarga g'amxo'rlik, xavfli muhitlar kabi murakkab vaziyatlarga qo'llanila boshlandi. Dinamik muhitlarda, ish joylaridagi barcha to'siqlarni oldindan o'rnatish mumkin emas. Shuning uchun MTRning to'siqlarni tanib olish va maqsad joyiga yetish uchun yangi yo'lni bir vaqtning o'zida ishlab chiqarishi mumkin bo'lgan mustahkam navigatsiya tizimiga ega bo'lishi muhimdir. Bundan tashqari, noma'lum muhitda to'siqsiz harakatlanish uchun robot o'z muhitini anglay olishi kerak; bu *Computer Vision*, sensor texnologiyalari va signal tahliliga bog'liq. Qabul qilish modallari odatda *Inertial O'lchov Bloklari (IMU)*, odometriya sensorlari, radar, ultratovush sonar, *Global Navigatsiya Sun'iy Yo'ldosh*

Tizimlari (GNSS), Yengil O'lchash va Diqqat (LiDAR), kameralar (infraqizil, RGB yoki chuqurlik) kabi periferik qurilmalar orqali ishlaydi. Inertial sensorlar, masalan, akselerometrlar va giroskoplar, hamda odometriya sensorlari, masalan, kodlovchilar yordamida noma'lum muhitlarda harakatlanuvchi tozalovchi aylanish harakatlari va tezlikdagi o'zgarishlarni tahlil qilib, o'z pozitsiyasini va yo'nalishini aniqlay oladilar. Ushbu usul GPS signallari mavjud bo'lmagan yoki past bo'lgan joylarda foydalidir. Biroq, ushbu usulning kamchiligi shundaki, xatolar vaqt o'tishi bilan to'planadi va natijada pozitsiyalashda noaniqliklar yuzaga keladi. Boshqa bir yechim sifatida butun dunyo navigatsiya sun'iy yo'ldosh tizimidagi GPS navigatsiya ma'lumotlarini robotlarning tezligi va holatini baholash uchun foydalanish mumkin. Ushbu texnika odatda ochiq havoda qo'llaniladi, chunki u katta hududlarda aniq joylashishni ta'minlaydi. Shu bilan birga, lidar navigatsiyasi robotlarda atrof-muhit bilan o'zaro ta'sir qilish uchun lazerga asoslangan sensorlardan foydalanib, aniq joylashish va to'siqlardan qochish imkonini beradi. Biroq, sensorning aniqligi, masofasi va tashqi ta'sirlarga nisbatan sezgirliги navigatsiya tizimining aniqligiga ta'sir qilishi mumkin. Vizual navigatsiya usulida noma'lum muhitlarda harakatlanuvchi tozalovchi sayr qilayotganda atrof-muhitlarini anglash uchun kameralar yordamida ma'lumot va suratlardan foydalanadilar. Biroq, kamera perspektivasidagi o'zgarishlar, to'siqlar va yoritish tizimga ta'sir qilishi mumkin. Ushbu maqolada noma'lum muhitlarda harakatlanuvchi tozalovchi uchun taqsimotli kuchaytirish o'rganishiga asoslangan yo'l-rejalashtirish strategiyasi taklif etiladi. Batafsilroq aytganda, atrof-muhit ma'lumotlari avval kameralar orqali to'planadi va chuqurlik tasvirlari to'plami sifatida taqdim etiladi. Shundan so'ng, ma'lumotlar to'plami Yengil O'rganilgan Tasvirni Tozalash bilan Qo'shimcha Moslashtirishga asoslangan tozalash va kalibrlash jarayonidan o'tadi. Keyin, Taqsimotli Kuchaytirish O'rganish modeli, ya'ni Chuqur Q-Network (DQN) yo'l-rejalashtirish jarayonini avtomatik ravishda o'rnatish uchun o'qitiladi. Bundan tashqari, ishlab chiqilgan tarmoq modelining ishlab chiqaruvchanligini oshirish uchun sub-mukofot mexanizmi taklif etiladi. Nihoyat, o'qitish natijalari turli sharoitlarda amalga oshiriladi va taklif etilgan strategiyaning aniqligi va ishonchliligini baholash uchun boshqa usullarga solishtiriladi.

ADABIYOTLAR SHARXI

Yuqorida aytilganidek, noma'lum muhitlarda harakatlanuvchi tozalovchi uchun to'siqlardan qochish va yo'nalish bo'yicha harakatlanishni boshqarishda chuqurlik tasviri (depth image) ma'lumotlaridan foydalanish robototexnika sohasidagi istiqbolli yo'nalishlardan biridir. Biroq, chuqurlik tasvirlari ko'pincha sezish texnologiyalarining cheklanishlari, atrof-muhit omillari va tasvirlash jarayonining o'ziga xos xususiyatlari tufayli shovqinga (noise) moyil bo'ladi. Shovqin piksellar qiymatlarida tasodifiy o'zgarishlar sifatida namoyon bo'lishi mumkin va bu pastki bosqichdagi vazifalarning ishlashiga salbiy ta'sir ko'rsatadi. Shu sababli, chuqurlik tasvirlarini shovqindan tozalash (denoising) muhim jarayon hisoblanadi va u chuqurlik xaritalarining sifatini oshirishga qaratilgan.

So'nggi yillarda bu muammoni hal qilish uchun ko'plab texnikalar ishlab chiqildi. An'anaviy usullardan (masalan, Gauss filtrlash va ikki tomonlama filtrlash)

tortib, machine learning va deep learning asoslangan zamonaviy yondashuvlarga [17–19]. Masalan, **Zuo va boshqalar** qoldiq tarmoqlar (Residual Network) yordamida ko'p kanalli chastotalarni tiklash va chuqurlik xaritalarining super-rezolyutsiyasini boshqarish uchun model ishlab chiqdilar [20]. Ular 5000 ta RGB-D tasvir juftliklarida, turli past rezolyutsiya darajalarida va chuqurlik yamalarida (patch) modelni o'qitib, bicubic interpolatsiya orqali sinovdan o'tkazdilar. Natijalar shuni ko'rsatdiki, taklif etilgan yondashuv tezroq yaqinlashadi va an'anaviy texnikalardan ustun keladi. Biroq, bu tadqiqotda chuqurlik sensori, rangli kamera va namunaviy olish (sampling) omillari orasidagi koordinata tizimini qayta ishlash bilan bog'liq kamchiliklar bor edi.

Zun Li va Jin Wu chuqurlik tasvirlaridagi teshiklarni to'ldirish (inpainting) muammosini chuqur o'rganish yordamida hal qilishni taklif etdilar [21]. Ular dastlab Split Bregman Iteration usulini qo'llab, muammoni shovqindan tozalashga oid masalaga aylantirdilar. Keyin CNN asosidagi shovqinni bartaraf etuvchi modelni (denoiser) ishlab chiqdilar. Natijalar ularning yondashuvi boshqa algoritmlarga qaraganda samaraliroq ekanini isbotladi. Ammo, bu usulda CNNning tezligi va samaradorligi o'rtasida muvozanat topish va samarali siqish metodini ishlab chiqish zarur edi.

Chen Zhang chuqurlik kamerasi ma'lumotlari asosida 3D obyektни rekonstruksiya qilish usulini taklif etdi [22]. U obyektning pozasini kuzatishda ma'lum kub shaklidagi obyektning 3D geometrik cheklovlarini qo'lladi. Shu bilan birga, sirtни shovqindan tozalash jarayonida topologik nomuvofiqliklarni kamaytirdi. Natijada sirt tekisligi va tozaligi saqlanib qoldi. Biroq, bu usul faqat obyektlar deyarli statik bo'lganda samarali ishlaydi.

Shuhang Gu va boshqalar Weighted Analysis Sparse Representation modelini taklif qildilar, u chuqurlik sensorlari va TOF kameralaridan olingan past rezolyutsiyali tasvirlarning sifatini avtomatik ravishda yaxshilaydi [23]. Modelning parametrlari DG-RBF va DG-CNN yordamida optimallashtirildi. Real sensor ma'lumotlaridagi test natijalari taklif qilingan usulning samaradorligini isbotladi. Ammo, DG-RBF modelining barcha namunalar uchun gradientlarni hisoblash zarurati yirik ma'lumotlar to'plamlarida hisoblash yukini oshiradi.

Liu va boshqalar chuqurlik tasvirlarini yaxshilash uchun K-singulyar qiymat dekompozitsiyasi (K-SVD) asosida usul taklif qildilar [24]. Ushbu algoritmnıng asosiy afzalligi — interpolatsiya jarayonida chegaralarning aniq qolishini ta'minlash va shovqinni kamaytirishdir. Natijalar Middlebury to'plamida sinovdan o'tkazilib, usulning ustunligi tasdiqlandi. Ammo, ba'zi hollarda yolg'on chetlarni tiklash sifati pasayishiga olib kelishi mumkin.

Yan va boshqalar GNNLG (Group-based Nuclear Norm and Learning Graph) modelini ishlab chiqdilar [25]. Bu model guruhlangan patchlarning past-rank xususiyatini ishlatib shovqinni kamaytiradi. Natijalar chuqurlik tasvirlarining vizual sifatini sezilarli darajada oshirishini ko'rsatdi.

Abeer Irfan va Enrico Magli KNN (k-eng yaqin qo'shnilar) algoritmgaga asoslangan grafik modelni 3D nuqta bulutlarini shovqindan tozalash uchun qo'lladilar [26]. Ammo, rang va geometriya o'rtasidagi bog'liqlik mos kelmasa, usulning

samaradorligi pasayishi mumkin.


Huang va boshqalar fraksional hisoblash (fractional calculus) asosida shovqinni kamaytirish usulini ishlab chiqdilar [27]. Grünwald–Letnikov operatoriga asoslangan konvolyutsiya shabloni yordamida chekka va tekstura ma’lumotlari saqlanib qoladi. Ammo, bu usul real vaqtda qo’llash uchun hisoblash jihatdan murakkab bo’lishi mumkin.

Michael Schelling TOF kamerasi ma’lumotlarini real vaqtda shovqindan tozalash uchun iterativ tuzatish yondashuvini taklif etdi [28]. Bu usul 3D nuqtalarni ko’rish yo’nalishida moslashtiradi va o’z-o’zini o’qitish (self-training) jarayonini ishlatadi. Ammo, harakatdagi obyektlarga ega dinamik sahnalarda samarasi pastroq bo’lishi mumkin.

Zhaofeng Niu va boshqalar DFusion nomli TSDF birlashtirish tarmog’ini taklif qildilar, bu model sensor tizimidagi chuqurlik va pozitsiya shovqinlarini kamaytiradi [29]. 3D konvolyutsion qatlamlardan foydalanish modelga TSDF hajmidagi 3D tuzilma ma’lumotlarini hisobga olish imkonini berdi. Natijalar real sahnalarda ham modelning yuqori aniqlik bilan rekonstruksiya qilish qobiliyatini ko’rsatdi.

So’nggi yillarda kameralar va LiDAR asosidagi navigatsiya yechimlari mashhur bo’ldi. **Shih-An Li va boshqalar** 360° tasvirlarni olish uchun giperbolik oyna va yuqori tezlikdagi kamera asosida tizim ishlab chiqdilar [32]. HSV rang modelidan foydalanib, shovqin filtrlandi va to’siqlar aniq aniqlanib, robotning yo’lini real vaqtda o’zgartirish imkonini berdi.

Chun-Hsiang Hsu va Jih-Gau Juang chuqurlik kamerasi va RGB rang fazosidan foydalanib, robotga inson ko’rish qobiliyatiga o’xshash idrok qobiliyatini berdilar [33]. Ammo, yoritishning yomonligi yoki to’siqlar mavjudligi samaradorlikni pasaytirishi mumkin.



1-rasm. Taklif etilgan yo’lni rejalashtirish strategiyasining umumiy ishlash jarayoni

Kaixiang Zhang va boshqalar kamera parametrlarini bilmasdan vizual ma'lumotlar asosida robotni boshqarish uchun kuzatuvchi (observer) ishlab chiqdilar [34]. Bu usul vaqt o'tishi bilan tizimning moslashuvchanligini oshirishga imkon beradi.

Boshqa bir tadqiqotda MS Kinect va SICK lidar kombinatsiyasi asosidagi ko'p-sensorli tizim ishlab chiqildi [35]. Bu tizim 3D nuqta bulutlari hosil qilib, robotga mayda to'siqlarni ham aniqlashga imkon berdi va yuqori tezlikda xavfsiz harakatlanish imkonini berdi.

Jongmin Jeong va boshqalar robotning navigatsiya qobiliyatini yaxshilash uchun semantik xaritalash va xaritani yaxshilash algoritmlarini taklif etdilar [36]. GPS va IMU ma'lumotlari 3D LiDAR nuqta bulutlari bilan birlashtirildi va CNN asosidagi semantik segmentatsiya qo'llanildi.

Lili Mu va boshqalar 2D LiDAR, RGB-D kamera, enkoder va IMUlar kombinatsiyasidan foydalanib SLAM usulini ishlab chiqdilar [37]. Unscented Kalman Filter (UKF) yordamida sensor ma'lumotlari birlashtirildi va bu an'anaviy EKFga qaraganda aniqroq natija berdi.

Umuman olganda, atrof-muhitdan olingan ma'lumotlar mobil robotlarning ishlash jarayonida juda muhim rol o'ynaydi. Ushbu ma'lumotlar navigatsiya va yo'l rejalashtirishning asosiy manbai sifatida qaraladi.

Umumiy ishlash jarayoni Taklif etilgan yo'lni rejalashtirish strategiyasining umumiy ishlash jarayoni 1-rasmda keltirilgan. Trening va simulyatsiya jarayonlari yuqori unumdorlikka ega kompyuterda bajariladi: ikkita RTX 3070 GPU (jami 39,6 TFLOPS va 16 GB VRAM), Xeon® E5-2680 v2 protsessori (20 yadro, 40 oqim) va 64 GB operativ xotira. Umumiy jarayon to'rt bosqichdan iborat:

Muhitni va robot modelini yaratish Birinchi bosqichda ROS (Robot Operating System) va Gazebo yordamida robot modeli va uning interaktiv muhiti yaratiladi.

Ma'lumot to'plash Tozalovchi robot xarita bo'ylab harakatlanadi va atrof-muhit haqida ma'lumot to'playdi. Ma'lumotlar chuqurlik tasvirlari (depth images) ko'rinishida saqlanadi. So'ngra LIDIA texnikasi qo'llanilib, tasvirlardagi shovqin (noise) yo'q qilinadi.

O'qitish bosqichi Ushbu bosqichda Deep Q-Network (DQN) algoritmidan foydalaniladi. Tarmoq doimiy ravishda tajriba repozitoriyasidan (replay buffer) o'rganadi va parametrlarini yangilab boradi. Shu tariqa optimal yo'lni rejalashtirish strategiyasi hisoblab chiqiladi.

Sinov bosqichi O'qitilgan model turli xarita ssenariylarida sinovdan o'tkaziladi va uning samaradorligi hamda moslashuvchanligi baholanadi.

Bu tizimli yondashuv robotning samarali navigatsiyasini ta'minlaydi va taqsimotli mustahkamlovchi o'rganish (distributional reinforcement learning) imkoniyatlaridan foydalanadi.

METODOLOGIYA

"Namuna moslashtirish asosida engil o'qitilgan tasvir shovqinini yo'qotish usuli" "Faraz qilamizki, shovqinli tasvirni Gaus shovqin qismi va toza tasvir qismiga ajratish mumkin. Shu sababli, shovqinli tasvirning matritsali ko'rinishi quyidagicha

ifodalanadi:"

$$F_{noise} = F_{clean} + n_{Gauss}$$

(1)

bu yerda:

F_{noise} - shovqinli tasvirni bildiradi;

F_{clean} - toza tasvirni bildiradi;

n_{Gauss} - Gaus shovqinni (o'zgaruvchanlik — dispersiya bilan) ifodalaydi.

"Shovqinli tasvirni Eq. (2) da ko'rsatilganidek, yamoqlar (patches) to'plami ko'rinishida yozish mumkin:"

$$F_{noise} = \{f_i^{noise}\}_{i=0}^{N_p}$$

(2)

bu yerda :

f_i^{noise} — shovqinli tasvirdan ajratib olingan i – chi yamoq (patch);

N_p – umumiy yamoqlar (patchlar) soni

$$Z_i = \{f_j^{noise-i}\}_{j=1}^k$$

(3)

bu yerda :

f_j^{noise} — f_j^{noise} ga o'xshash guruhga tegishli i – chi element;

k - ushbu guruhdagi yamoqlar (patchlar) soni.

$$Z_i^{\wedge} = T(Z_i)$$

(4)

bu yerda:

T — transformatsiya funksiyasi.

$$x_i^{\wedge} = F_0(Z_i^{\wedge})$$

(5)

bu yerda:

F_0 — parametrlar θ ga ega o'rganilgan neyron tarmoqdir.

U transformatsiya qilingan domen (sohada) yamoq guruhlari ustida ishlaydi va shovqinni kamaytirish (denoising) vazifasini bajaradi.

$$X = A(\{x_i^{\wedge}\}_{i=1}^{N_p})$$

(6)

$X^{\wedge}$ — qayta tiklangan (denoisingdan o'tgan) butun rasm,

$A(\cdot)$ — yig'ish (agregatsiya) funksiyasi, ya'ni barcha qayta ishlangan yamoqlarni

$(x_i^{\wedge})$ birlashtirib bitta to'liq tasvir hosil qiladi,

$(\{x_i^{\wedge}\}_{i=1}^{N_p})$ barcha N_p ta toza yamoqlar toplami

TAHLIL VA NATIJALAR

Tasvirlarni shovqindan tozalash (Image denoising) Taklif etilgan ramkada aytib o'tilganidek, kamera tomonidan olingan xom ma'lumotlar birinchi navbatda LIDIA texnikasi asosida shovqindan tozalanadi. 4–6-rasmlarda turli xil xarita tuzilmalaridagi

shovqinni kamaytirish jarayonining natijalari ko'rsatilgan.

Ushbu rasmlar sahnlarda LIDIA algoritmini qo'llashdan oldingi va keyingi holatlar taqqoslanadi. Oson ko'rish mumkinki, xom tasvir ma'lumotlari juda ko'p darajada g'adir-budirlik va shovqinni o'z ichiga oladi. Bu mobil robot uchun arxitektura makonining ko'rinishini tartibsiz va noaniq bo'lishiga olib kelishi mumkin. Algoritm qo'llangandan so'ng, shovqin sezilarli darajada kamayadi. Natijada, olingan tasvirlar yorug'lik va soya orasidagi farqni yanada aniqroq aks ettiradi, chuqurlikni va fazoviy aniqlikni yaxshilaydi.

Yo'l rejalashtirish (Path-planning) Taklif etilgan strategiyaning avtonom navigatsiyadagi samaradorligini tekshirish uchun Gazebo simulyatsiya dasturida uchta o'quv va sinov muhiti yaratilgan. Muhit hududi 8×8 panjarali tarmoqqa bo'lingan bo'lib, uning atrofi devorlar bilan chegaralangan va turli to'siqlar o'rnatilgan (7-rasm).

Robot modeli ikkita haydovchi g'ildirak va ikkita erkin aylanadigan g'ildirak bilan ishlab chiqilgan. Faol g'ildiraklar DC motorlar yordamida harakatga keltiriladi. Muhit haqidagi ma'lumotlarni to'plash uchun robotning ustiga Camera Kinect v2 deb nomlangan RGB-D kamera o'rnatilgan. Robotning maksimal burchak tezligi 0.5 rad/s va maksimal chiziqli tezligi 0.5 m/s qilib belgilangan.

Robotning to'siqlardan qochish va maqsad nuqtasiga yetishish ko'nikmalarini oshirish uchun uch xil xarita yaratilgan. O'quv jarayonida robot turli boshlang'ich nuqtalardan maqsad nuqtalariga harakatlanishi kerak bo'lgan holatlarda sinovdan o'tkazilgan. Bir nechta iteratsiyalar bajarilgandan so'ng olingan mukofotlarning o'quv egri chiziqlari 8-rasmda ko'rsatilgan. 8a va 8b-rasmlarda ko'rinib turibdiki, mukofot qiymatlari asta-sekin oshadi va taxminan 1000 epizoddan so'ng konvergenstsiyaga erishadi.

3-xarita bilan o'quv jarayonida esa mukofot egri chizig'i 1200 epizoddan keyin tebranishni boshlaydi (8c-rasm), biroq 2500 epizoddan keyin egri chiziq barqarorlashadi. Bu shuni anglatadiki, xarita murakkablashgani sayin o'quv jarayoni konvergenstsiyaga yetishish uchun ko'proq vaqt oladi.




5-rasm. Ikkinchi xaritadagi tasvir ma'lumotlarining shovqindan tozalashdan oldingi va keyingi holati.

O'quv jarayoni tugagach, robot uchta turli muhitda sinovdan o'tkazilgan. Robot


tasodifiy nuqtalarga qo'yilib, maqsadga yetishish qobiliyati tekshirildi. DQN usuli natijalari boshqa usullar bilan taqqoslandi. 9-rasmda uchta xaritada olingan aniq yo'l rejalashtirish natijalari ko'rsatilgan. Shubhasizki, robot to'siqlardan muvaffaqiyatli o'tadi va maqsad nuqtalariga yetadi.

DQN usuli va Dijkstra, A* hamda Hybrid-A* usullaridan foydalangandagi yo'l uzunliklari taqqoslangan. Barcha holatlarda DQN modeli hosil qilgan yo'llar boshqalarnikiga qaraganda qisqaroq bo'lgani aniqlangan. Eng kam qisqarish 0.76%, eng katta qisqarish esa 13.04% bo'lib, ular mos ravishda 3-xaritada Hybrid-A* va A* bilan taqqoslanganda kuzatilgan. Taklif etilgan usul ko'p tuzilmali muhitlarda yaxshi simulyatsiya natijalarini ko'rsatdi.



6-rasm. Uchinchi xarita bo'yicha tasvir ma'lumotlarining shovqindan tozalash jarayonidan oldingi va keyingi ko'rinishlari. Jarayon natijasida tasvir yanada aniq va silliq bo'lib, robotning atrof-muhitni sezish qobiliyati oshirilgan.

Biroq, uni dinamik muhitda qo'llash uchun tizimga qo'shimcha sensor modullari qo'shilishi kerak, shunda u to'siqlar va real dunyo ish sharoitlaridagi o'zgarishlarga moslasha oladi. Shuningdek, adaptiv o'qitish qobiliyati va noaniqlik sharoitida barqaror qaror qabul qilish juda muhim rol o'ynaydi, chunki bu robotga noma'lum muhitga samarali javob berishga yordam beradi.




7-rasm. Gazebo dasturida simulyatsiya qilingan virtual o'quv muhiti: a) 1-xarita; b) 2-xarita; c) 3-xarita.

MUHOKAMA

Ushbu tadqiqotda taklif etilgan LIDIA – DQN asosidagi yo‘l rejalashtirish strategiyasi mobil robot navigatsiyasida sezilarli natijalar berdi. Birinchi bosqichda qo‘llanilgan LIDIA shovqinni kamaytirish algoritmi chuqurlik tasvirlarini yanada tiniq va aniq shaklga keltirdi. Bu esa robotning atrof-muhitni sezish qobiliyatini kuchaytirdi va to‘siqlarni aniqlash jarayonini ishonchliroq qildi. Ayniqsa, yorug‘lik va soya o‘rtasidagi kontrastning oshishi fazoviy aniqlikni sezilarli darajada yaxshiladi. Shu sababli, keyingi bosqichlarda olingan ma‘lumotlar robot qaror qabul qilishi uchun yanada foydaliroq bo‘ldi.

DQN asosidagi taqsimotli mustahkamlovchi o‘rganish yondashuvi klassik Dijkstra, A* va Hybrid-A* algoritmlaridan ustunlik qildi. Tajriba natijalari shuni ko‘rsatdiki, DQN yordamida rejalashtirilgan yo‘llar qisqaroq bo‘lib, robotning maqsad nuqtasiga tezroq va xavfsizroq yetib borishini ta‘minladi. Bu, ayniqsa, murakkab muhitlarda muhim, chunki klassik algoritmlar bunday sharoitda ko‘proq hisoblash vaqtini talab qiladi va ba‘zan mahalliy minimumlarda “tiqilib qolishi” mumkin. DQN esa taqsimotli mukofot funksiyasi orqali noaniq sharoitlarda ham barqaror va xavfsiz qaror qabul qilish imkonini berdi.



(a)




(b)

O‘quv egri chiziqlarini tahlil qilganda, dastlabki bosqichlarda mukofotlarning

tebranishi kuzatildi, ammo epizodlar soni oshgani sari model konvergensiyaga erishdi va o'rganish jarayoni barqarorlashdi. Ayniqsa, 3-xarita kabi murakkab muhitlarda o'quv jarayonining sekinlashgani ko'proq o'quv epizodlari talab qilinishini ko'rsatdi. Bu natija robotni real muhitlarda yanada ko'proq vaziyatlar bilan o'rgatish zarurligini bildiradi. Boshqa tomondan, modelning umumlashma (generalizatsiya) qobiliyati yaxshi bo'lib, turli xaritalarda ham samarali natijalar berdi.

Shuni alohida ta'kidlash kerakki, taklif etilgan yondashuvning eng katta ustunliklaridan biri – noaniqlik sharoitida mustahkam qaror qabul qilish qobiliyatidir. Bu esa real hayotdagi murakkab va dinamik muhitlarda muhim ahamiyatga ega, chunki robot to'satdan paydo bo'ladigan to'siqlarga yoki o'zgaruvchan yo'l sharoitlariga tezkor moslasha oladi. Shu bilan birga, modelning bu xususiyati uni xavfsizlik darajasi yuqori bo'lgan sanoat, logistika va xizmat ko'rsatish sohalarida qo'llash imkoniyatini ochadi.



(c)

8-rasm. Turli tajriba ssenariylarida olingan asl va silliqlangan o'quv egri chiziqlari:

a) 1-xarita; b) 2-xarita; c) 3-xarita.

Biroq, ushbu usulning ba'zi cheklovlari ham mavjud. Eng avvalo, DQN modelini o'qitish katta hisoblash resurslarini talab qiladi va kuchli GPU quvvatisiz jarayon ancha sekinlashadi. Bundan tashqari, tadqiqot hozircha faqat simulyatsiya muhitida sinovdan o'tkazildi. Amaliyotda yanada yaxshi natijalarga erishish uchun real robot platformalarida tajribalar o'tkazish, qo'shimcha sensor ma'lumotlarini (LiDAR, IMU, ultratovush sensorlari) integratsiya qilish va onlayn o'rganish metodlarini joriy etish tavsiya etiladi. Bu esa robotga real vaqt rejimida moslashuvchan qaror qabul qilish imkonini beradi va tizimni yanada barqaror qiladi.

XULOSA

Ushbu maqolada **tozalovchi robot** navigatsiyasi uchun taqsimotli mustahkamlashga asoslangan yo'l rejalashtirish strategiyasi taklif etildi. Aniqroq aytganda, mobil robot tomonidan ish jarayonida olingan chuqurlik tasvirlari LIDIA shovqinni kamaytirish algoritmi yordamida qayta ishlanib, kalibrlangan. Ushbu tayyorlangan ma'lumotlar DQN asosidagi tarmoqni o'qitish va robotni avtomatik

boshqarishga yo'naltirish uchun ishlatildi. O'qitish natijalari turli xil murakkab tuzilmali muhitlarda taklif etilgan modelning aniqligini namoyish etdi. Bundan tashqari, turli usullar bilan qiyosiy sinovlar natijalari taklif etilgan yondashuvning samaradorligi va optimallashtirish imkoniyatlarini ochib berdi. Taklif etilgan usul robotning tasvirni qayta ishlash va yo'l topish jarayonlarida yaxshi natijalar ko'rsatdi. Biroq, usul sezilarli hisoblash resurslarini talab qiladi. Shuningdek, usulning barqarorligi va amaliy samaradorligini mustahkamlash uchun uni haqiqiy robotlarda sinovdan o'tkazish muhimdir. Mazkur tadqiqot axloqiy me'yorlarga amal qiladi hamda inson/ hayvonlar ishtirokidagi tajribalarni yoki ijtimoiy tarmoqlardan ma'lumot to'plashni o'z ichiga olmaydi. Loyiha fayllari va dasturiy ta'minot kodlari muallif tomonidan ochiq manba sifatida taqdim etilgan bo'lib, tadqiqotchilar, talabalar va qiziquvchilar uchun o'rganish va ushbu ishlanma asosida yangi ishlanmalar yaratish imkoniyatini beradi.

ADABIYOTLAR RO'YXATI

- [1] R. Arrais, M. Oliveira, C. Toscano, G. Veiga, A mobile robot based sensing approach for assessing spatial inconsistencies of a logistic system, *J. Manuf. Syst.* 43 (2017) 129–138.
- [2] B. Hichri, J.C. Fauroux, L. Adouane, I. Doroftei, Y. Mezouar, Design of cooperative mobile robots for co-manipulation and transportation tasks, *Robot. Comput. Integr. Manuf.* 5
- [3] F. Hennecke, J. Bomer, " R.H. Heim, Modification of an automated precision farming robot for high temporal resolution measurement of leaf angle dynamics using stereo vision, *MethodsX.* 14 (2025) 103169. [4] K.S. Suresh, R. Venkatesan, S. Venugopal, Mobile robot path planning using multi-objective genetic algorithm in industrial automation, *Soft. comput.* 26 (15) (2022) 7387–7400.
- [5] T.T. Mac, T.D. Nguyen, H.K. Dang, D.T. Nguyen, X.T. Nguyen, Intelligent agricultural robotic detection system for greenhouse tomato leaf diseases using soft computing techniques and deep learning, *Sci. Rep.* 14 (1) (2024) 23887.
- [6] H.A. Bui, T.T. Mac, X.T. Nguyen, A Human tracking system for the rocker-bogie mobile robot utilizing the YOLOv8 network, *Vietnam J. Comput. Sci.* (2025) 1–22.
- [7] H.T. Tran, D.T. Tran, M.T. Nguyen, T.C. Vu, Intelligent mobile robot for contagious disease treatments in hospitals, *MethodsX.* 13 (2024) 102941.
- [8] K.C. Park, H. Chung, J.G. Lee, Dead reckoning navigation for autonomous mobile robots, *IFAC Proceed. Volumes* 31 (3) (1998) 219–224. March.
- [9] G.-S. Cai, H.-Y. Lin, S.-F. Kao, Mobile robot localization using GPS, IMU and Visual odometry, in: 2019 International Automatic Control Conference (CACS), Keelung, Taiwan, 2019, pp. 1–6, <https://doi.org/10.1109/CACS47674.2019.9024731>.
- [10] J. Hanzel, F. Duchon, " J. Rodina, P. P' azsto, " Global navigation systems for mobile robots, *Int. J. Systems Appl., Eng. Dev.* 7 (5) (2013).
- [11] Y. Yun, J. Jin, N. Kim, J. Yoon, and C. Kim. Outdoor localization with optical navigation sensor, IMU and GPS. 2012 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI). [12] H. Yin, X. Xu, S. Lu, et al., A survey on global LiDAR localization: challenges, advances and open problems, *Int.*

J. Comput. Vis. 132 (2024) 3139–3171.

[13] Y. He, F. Ma, Visual navigation method and simulation validation, in: 2023 7th International Conference on Transportation Information and Safety (ICTIS), Xi'an, China, 2023, pp. 1–4, <https://doi.org/10.1109/ICTIS60134.2023.10243758>.

[14] Y.D.V. Yasuda, LEG. Martins, F.A.M. Cappabianco. Autonomous Visual Navigation for Mobile robots: A systematic literature review. ACM Computing Surveys (CSUR), Volume 53, Issue 1 (13), 1–34.

[15] G. Vaksman, M. Elad, P. Milanfar, Lidia: Lightweight learned image denoising with instance adaptation, in: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020, pp. 524–525.

[16] M.G. Bellemare, W. Dabney, M. Rowland, Distributional Reinforcement Learning, MIT Press, 2023.

[17] M. Frank, M. Plaue, F.A. Hamprecht, Denoising of continuous-wave time-of-flight depth images using confidence measures, Optical Eng. 48 (7) (2009) 077003. - 077003.

[18] J. Xie, R.S. Feris, S.S. Yu, M.T. Sun, Joint super resolution and denoising from a single depth image, IEEE Trans. Multimedia 17 (9) (2015) 1525–1537.

[19] S. Patil, S. Kukreja, Deep reinforced cognitive analytics algorithm (DRCAM): an advanced method to early detection of cognitive skill impairment using deep learning and reinforcement learning, MethodsX. 14 (2025) 103277.

[20] Y. Zuo, Q. Wu, Y. Fang, P. An, L. Huang, Z. Chen, Multi-scale frequency reconstruction for guided depth map super-resolution via deep residual network, IEEE Trans. Circuits Systems Video Technol. 30 (2) (2019) 297–306.

[21] Y. Zuo, Q. Wu, Y. Fang, P. An, L. Huang, Z. Chen, Multi-scale frequency reconstruction for guided depth map super-resolution via deep residual network, IEEE Trans. Circuits Syst. Video Technol. 30 (2) (2019) 297–306.

[22] C. Zhang, CuFusion2: accurate and denoised volumetric 3D object reconstruction using depth cameras, IEEE Access. 7 (2019) 49882–49893.

[23] S. Gu, S. Guo, W. Zuo, Y. Chen, R. Timofte, L. Van Gool, L. Zhang, Learned dynamic guidance for depth image reconstruction, IEEE Trans. Pattern. Anal. Mach. Intell. 42 (10) (2019) 2437–2452.

[24] B. Liu, Q. Ling, Edge-guided depth image super-resolution based on KSVD, IEEE Access. 8 (2020) 41108–41115.

[25] C. Yan, Z. Li, Y. Zhang, Y. Liu, X. Ji, Y. Zhang, Depth image denoising using nuclear norm and learning graph model, ACM Trans. Multim. Comput., Commun. Appl. (TOMM) 16 (4) (2020) 1–17.

[26] M.A. Irfan, E. Magli, Exploiting color for graph-based 3D point cloud denoising, J. Vis. Commun. Image Represent. 75 (2021) 103027.

[27] T. Huang, C. Wang, X. Liu, Depth image denoising algorithm based on fractional calculus, Electronics. (Basel) 11 (12) (2022) 1910.

[28] M. Schelling, P. Hermosilla, T. Ropinski, RADU: Ray-aligned depth update convolutions for ToF data denoising, in: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022, pp. 671–680.

- [29] Z. Niu, Y. Fujimoto, M. Kanbara, T. Sawabe, H. Kato, DFusion: denoised TSDF fusion of multiple depth maps with sensor pose noises, *Sensors* 22 (4) (2022) 1631.
- [30] P.K. Panigrahi, S.K. Bisoy, Localization strategies for autonomous mobile robots: A review, *J. King Saud Univ. – Comput. Inf. Sci.* 34 (2022) 6019–6039.
- [31] S.V. Deshpande, R. Hari Krishnan, J. Sampe, A. Patwa, An algorithm to create model file for Partially Observable Markov Decision Process for mobile robot path planning, *MethodsX*. 12 (2024) 102552.
- [32] S-An Li, Li-H Chou, T.-H. Chang, C.-H. Yang, Yu-C Chang, Obstacle avoidance of mobile robot based on HyperOmni Vision, *Sensors Mater.* 31 (3) (2019) 1021–1036.
- [33] C.-H. Hsu, J.-G. Juang, Using a robot for indoor navigation and door opening control based on image processing, *Actuators*. 13 (2) (2024) 78.
- [34] K. Zhang, J. Chen, G. Yu, X. Zhang, Z. Li, Visual trajectory tracking of wheeled mobile robots with uncalibrated camera extrinsic parameters, *IEEE Trans. Syst., Man, Cybernet.: Syst.* 51 (11) (2021).
- [35] M. Stefanczyk, ' K. Banachowicz, M. Wałęcki, T. Winiarski, 3D Camera and lidar utilization for mobile robot navigation (2013), *J. Autom. Mobile Robotics Intell. Syst.* 7 (4) (2013) 27–33.
- [36] J. Jeong, T.S. Yoon, J.B. Park, Towards a meaningful 3D map using a 3D lidar and a camera, *Sensors* 18 (2018) 2571.
- [37] L. Mu, P. Yao, Y. Zheng, K. Chen, F. Wang, N. Qi, Research on SLAM algorithm of mobile robot based on the fusion of 2D LiDAR and depth camera, *IEEE Access* 8 (2020).
- [38] C.K. Dewa, J. Miura, Framework for DRL navigation with State transition checking and velocity increment scheduling, *IEEE Access*. 8 (2020) 191826–191838.
- [39] W. Zhang, Y. Zhang, N. Liu, Danger-aware adaptive composition of DRL agents for self-navigation, *Unmanned Systems* 9 (1) (2021) 1–9.
- [40] J. Kulhanek, ' E. Derner, R. Babuška, Visual navigation in real-world indoor environments using end-to-end deep reinforcement learning, *IEEE Robot. Autom. Letters*. 6 (3) (2021) 4345–4352.
- [41] C. Wei, Y. Li, Y. Ouyang, Ze Ji, Deep reinforcement learning with heuristic corrections for UGV navigation, *J. Intell. Robot. Systems*. Vol. 109 (18) (2023)
- [42] Y. Ou, Y. Cai, Y. Sun, T. Qin, Autonomous navigation by mobile robot with sensor fusion based on deep reinforcement learning, *Sensors* (2024) 3895