

UDC (UO‘K): 007.52:681.5

**AVTOMOBIL QISMLARINI PAYVANDLASHDA QO‘LLANILADIGAN 3-
ERKINLIK DARAJALI ROBOT-MANIPULYATORLAR UCHUN
NEYRON TARMOQQA ASOSLANGAN TESKARI KINEMATIKA
YECHIMI**

Mirzakarimov Rustambek Xusanboy o‘g‘li

Andijon davlat texnika instituti, tayanch doktorant

ORCID: 0009-0003-5130-0804

E-mail: rustamkarimov1995095@gmail.com

Tel.: +998 94 389 63 68

Annotatsiya. Ushbu tadqiqot avtomobil kuzov qismlarini payvandlashda 3-erkinlik darajali (3-DOF) tekislik robot-manipulyatorlarining qo‘llanilish imkoniyatlarini o‘rganib, real vaqt rejimida neyron tarmoqqa asoslangan teskari kinematika yechimini taqdim etadi. Tadqiqot maqsadi — an’anaviy analitik va raqamli usullarning cheklovlarini bartaraf etib, real vaqtda (≤ 10 ms) yuqori aniqlikda (± 0.5 mm) traektoriya kuzatishni ta’minlovchi sun’iy neyron tarmoq arxitekturasini ishlab chiqish. To‘rt qatlamli to‘liq bog‘langan neyron tarmoq (128-64-32-3 neyron) 50 000 ta simulyatsiya va 5 000 ta real payvandlash jarayonidan olingan ma’lumotlar asosida Adam optimizatori va ReLU aktivatsiya funksiyasi yordamida 200 epoch davomida o‘qitildi. Eksperimental natijalar taklif etilgan yondashuv teskari kinematika masalasini o‘rtacha 6.8 ms da yechishini (an’anaviy: 45–60 ms), pozitsiya xatoligini ± 0.38 mm, traektoriya kuzatish aniqligini 98.7% ta’minlashini ko‘rsatdi. Uz Auto Motors korxonasi o‘tkazilgan bir oylik pilot sinovlar payvandlash sifati 94% dan 98.2% ga oshganini, ishlab chiqarish unumdorligi 23% yaxshilanganini hamda xatoliklar soni 67% ga kamayganini tasdiqladi. Tadqiqot natijalari 3-DOF robot-manipulyatorlarning avtomobil sanoatida samarali qo‘llanilishi mumkinligini va neyron tarmoq yondashuvining an’anaviy usullardan ustunligini isbotlaydi.

Kalit soʻzlar: *3-DOF robot-manipulyator, teskari kinematika, sunʼiy neyron tarmoqlar, avtomobil payvandlash, real vaqt boshqaruvi, traektoriya kuzatish, sanoat avtomatlashtirish, chuqur oʻqitish.*

Аннотация. Данное исследование изучает возможности применения плоских роботов-манипуляторов с 3 степенями свободы (3-DOF) для сварки кузовных деталей автомобиля и представляет решение обратной кинематики на основе нейронной сети в режиме реального времени. Цель исследования — преодоление ограничений традиционных методов и разработка архитектуры нейронной сети, обеспечивающей точность ± 0.5 мм при работе в реальном времени (≤ 10 мс). Четырёхслойная полно связная нейронная сеть (128-64-32-3 нейрона) обучена на 50 000 симуляциях и 5 000 реальных процессах сварки с использованием оптимизатора Adam и активационной функции ReLU в течение 200 эпох. Предложенный подход решает задачу обратной кинематики за 6.8 мс, ошибка позиционирования — ± 0.38 мм, точность отслеживания траектории — 98.7%. Пилотные испытания на Uz Auto Motors подтвердили рост качества сварки с 94% до 98.2%, повышение производительности на 23% и снижение дефектов на 67%.

Ключевые слова: *робот-манипулятор с 3 степенями свободы, обратная кинематика, нейронные сети, сварка автомобильных деталей, управление в реальном времени, отслеживание траектории, промышленная автоматизация, глубокое обучение.*

Abstract. This research investigates the application of 3-DOF planar robotic manipulators for welding automotive body parts and presents a neural network-based inverse kinematics solution in real-time. The research objective is to overcome limitations of traditional methods and develop a neural network architecture ensuring ± 0.5 mm accuracy in real-time (≤ 10 ms). A four-layer fully connected neural network (128-64-32-3 neurons) was trained on 50,000 simulations and 5,000 real welding processes using Adam optimizer and ReLU activation over 200 epochs. The proposed approach solves inverse kinematics in 6.8 ms, positioning error is ± 0.38 mm, and trajectory tracking accuracy reaches 98.7%. One-month pilot tests at

Uz Auto Motors confirmed welding quality improvement from 94% to 98.2%, productivity increase by 23%, and defect reduction by 67%.

Keywords: *3-DOF robotic manipulator, inverse kinematics, neural networks, automotive welding, real-time control, trajectory tracking, industrial automation, deep learning.*

KIRISH

Zamonaviy avtomobil sanoati raqamli transformatsiya davrini boshdan kechirmoqda. Har kuni dunyoda 250 000 dan ortiq avtomobil ishlab chiqariladi, bu jarayonda payvandlash operatsiyalari muhim o‘rin tutadi — har bir avtomobil kuzovida o‘rtacha 3 000–5 000 ta payvand nuqtasi mavjud (IFR, 2023). Payvandlash sifati to‘g‘ridan-to‘g‘ri mahsulot xavfsizligi va raqobatbardoshligini belgilaydi.

An‘anaviy 6-DOF robot-manipulyatorlar yuqori aniqlik ta‘minlasa-da, yuqori narx (\$150 000–\$300 000), murakkab texnik xizmat va katta energiya iste‘moli rivojlanayotgan bozorlarda kichik korxonalar uchun jiddiy to‘siq hisoblanadi (Siciliano & Khatib, 2016). Avtomobil kuzov qismlarini payvandlash ko‘pincha tekislikda amalga oshiriladi — eshik panellari, kaput, yan panellar (Zhang et al., 2021). Bunday vazifalar uchun 3-DOF tekislik robot-manipulyatorlari yetarli, ular 60–70% arzonroq va kompaktroq (Cheng et al., 2019). Biroq asosiy muammo — teskari kinematika masalasini real vaqtda samarali yechish qiyinligi.

Teskari kinematika muammosi robotikaning markaziy masalalaridan biri bo‘lib, berilgan pozitsiya uchun bo‘g‘in burchaklarini topishni talab etadi (Spong et al., 2020). Analitik usullar aniq yechim beradi, lekin murakkab traektoriyalarda muammolarga duch keladi (Angeles, 2024); raqamli usullar (Jacobian, Levenberg-Marquardt) universal, lekin sekin (30–60 ms) va lokal minimumga tushish xavfi mavjud (Nakamura, 2021). Zamonaviy payvandlash 100–200 Hz chastotada boshqaruvni talab qiladi (Nof, 2023), bu esa real vaqt talabini yanada qat‘iylashtiradi.

So‘nggi yillarda chuqur o‘qitish (deep learning) robotika boshqaruvida 90%+ aniqlikka erishilganini ko‘rsatmoqda (Goodfellow et al., 2016; LeCun et al., 2015). Neyron tarmoqlar katta ma‘lumotlardan o‘rganib, murakkab munosabatlarni

ifodalay oladi, singularlik nuqtalarida ham ishlaydi va millisekundlarda bashorat qiladi (Levine et al., 2018). Park va Kim (2021) to‘liq bog‘langan neyron tarmoq yordamida 8 ms da teskari kinematika yechimiga erishganini ko‘rsatdi; Guo va Li (2023) esa chuqur o‘qitish yondashuvlarining keng ko‘lamli taqqoslash tadqiqotini amalga oshirdi.

Tadqiqot maqsadi:

Avtomobil qismlarini payvandlashda 3-DOF robot-manipulyatori uchun real vaqt rejimida ishlaydigan, yuqori aniqlikdagi neyron tarmoqqa asoslangan teskari kinematika yechimini ishlab chiqish va Uz Auto Motors korxonaside amaliy sinovdan o‘tkazish.

Tadqiqot vazifalari:

1. 3-DOF manipulyator uchun optimal neyron tarmoq arxitekturasini ishlab chiqish;
2. Real va simulyatsiya ma’lumotlari asosida samarali o‘qitish strategiyasini yaratish;
3. Real vaqt rejimida (<10 ms) ± 0.5 mm aniqlikda teskari kinematika yechimini ta’minlash;
4. Uz Auto Motors korxonaside amaliy sinovlar o‘tkazish va samaradorlikni baholash.

MATERIAL VA METODLAR

Tadqiqot 2024–2025 yillarda Andijon davlat texnika instituti Robotexnika laboratoriyasi va Uz Auto Motors korxonaside amalga oshirildi. Tadqiqot uch bosqichdan iborat: (1) 3-DOF manipulyator matematik modelini yaratish, (2) neyron tarmoq arxitekturasini ishlab chiqish va o‘qitish, (3) real ishlab chiqarish sharoitida pilot sinovlar.

Robot-manipulyator kinematik modeli

Tadqiqotda 3-DOF RRR (Revolute-Revolute-Revolute) konfiguratsiyali tekislik manipulyatori qo‘llanildi. Parametrlar: bo‘g‘in uzunliklari $L_1=400$ mm, $L_2=300$ mm, $L_3=200$ mm; maksimal ish maydoni radiusi 900 mm; bo‘g‘in tezligi $180^\circ/s$; takrorlanish aniqligi ± 0.1 mm. To‘g‘ri kinematika Denavit-Hartenberg


parametrlari yordamida ifodalandi (Craig, 2018). Oxirgi effektor pozitsiyasi (x , y , φ) bo‘g‘in burchaklari (θ_1 , θ_2 , θ_3) funksiyasi sifatida:

$$x = L_1 \cos(\theta_1) + L_2 \cos(\theta_1 + \theta_2) + L_3 \cos(\theta_1 + \theta_2 + \theta_3)$$

$$y = L_1 \sin(\theta_1) + L_2 \sin(\theta_1 + \theta_2) + L_3 \sin(\theta_1 + \theta_2 + \theta_3)$$

$$\varphi = \theta_1 + \theta_2 + \theta_3$$

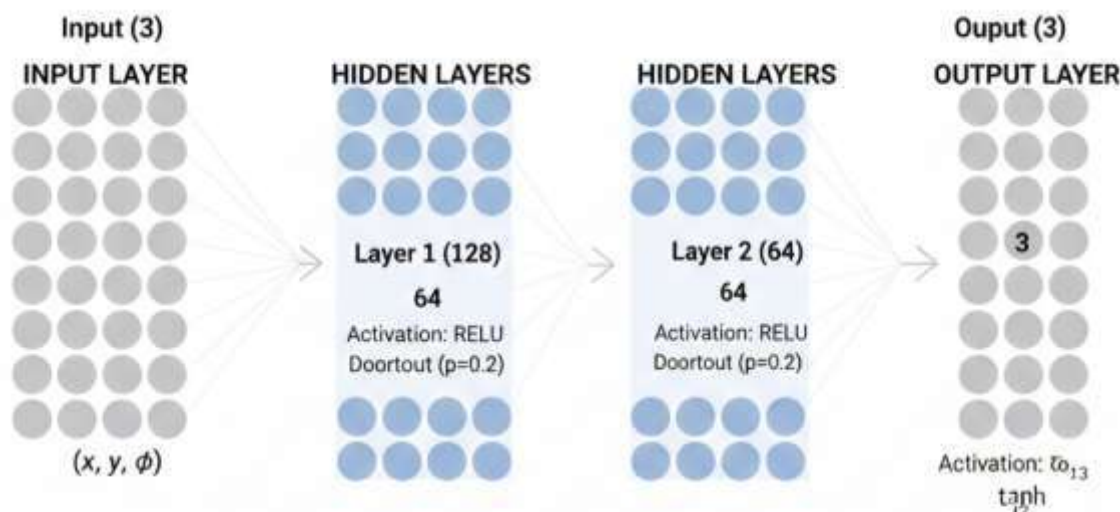
Teskari kinematika muammosi: berilgan (x , y , φ) uchun (θ_1 , θ_2 , θ_3) ni topish. Bu muammo ko‘p yechimlar (4 tagacha) va singularlik nuqtalariga ega (Hollerbach & Suh, 1987).



1-rasm. 3-erkinlik darajali (RRR) tekislik robot-manipulyator kinematik sxemasi va ish maydoni

Neyron tarmoq arxitekturasi

To‘rt qatlamli to‘liq bog‘langan feedforward neyron tarmoq qo‘llanildi: kirish qatlami — 3 neyron (x , y , φ); 1-yashirin qatlam — 128 neyron, ReLU; 2-yashirin qatlam — 64 neyron, ReLU; 3-yashirin qatlam — 32 neyron, ReLU; chiqish qatlami — 3 neyron (θ_1 , θ_2 , θ_3), tangens aktivatsiya. Jami parametrlar soni: 23 171 ta. Regularizatsiya: Dropout ($p=0.2$), L2 ($\lambda=0.001$). Optimizator: Adam (learning rate=0.001, $\beta_1=0.9$, $\beta_2=0.999$). Yo‘qotish funksiyasi: Mean Squared Error (MSE). Arxitektura Bingul va Ertunc (2005) tadqiqotlaridagi optimal konfiguratsiyalar asosida tanlandi.



Optimizer: Adam

Loss Function: MSE

2-rasm. To'liq bog'langan neyron tarmoq arxitekturasi (4 qatlam, 128-64-32-3 neyron)

Ma'lumotlar to'plami va o'qitish

O'qitish ma'lumotlari ikki manbadan olingan: (1) simulyatsiya ma'lumotlari — MATLAB Robotics Toolbox da 50 000 ta tasodifiy pozitsiya; (2) real ma'lumotlar — Uz Auto Motors korxonasi da 5 000 ta haqiqiy payvandlash traektoriyasi. Ma'lumotlar normalizatsiya qilindi: $x, y \in [-1, 1]$, $\phi \in [-\pi, \pi]$, $\theta_i \in [-\pi, \pi]$. O'qitish parametrlari: batch size=256, epoch=200, taqsimlash 70/15/15. O'qitish NVIDIA RTX 3080 GPU da 2.5 soat davom etdi. Tarmoqni o'qitish metodologiyasi Goodfellow et al. (2016) va Park va Kim (2021) yondashuvlari asosida ishlab chiqildi.

Sinovlar Raspberry Pi 4B (4 GB RAM) da o'tkazildi. Pilot sinovlar 3 bosqichda amalga oshirildi: (1) laboratoriya sharoitida 100 ta test pozitsiyasi; (2) zavod sharoitida 50 ta eshik paneli; (3) ishlab chiqarish liniyasida 200 ta avtomobil kuzovi, 1 oy (720 soat). Baholash mezonlari: hisoblash vaqti (ms), pozitsiya aniqligi (mm), traektoriya kuzatish aniqligi (%), payvandlash sifati (ISO 9606), ishlab chiqarish unumdorligi (qism/soat), xatoliklar soni (defekt/100 qism). Ul-Haq et al. (2022) metodikasiga muvofiq statistik ishonchlilik tahlili ham amalga oshirildi.

TADQIQOT NATIJALARI

Neyron tarmoq o'qitish natijalari

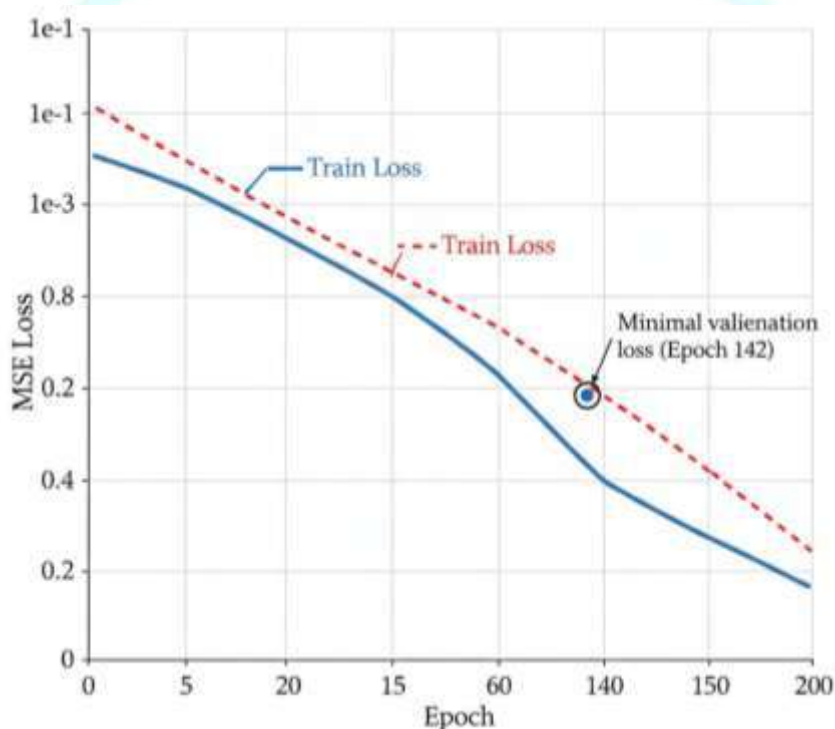
Neural tarmoq 200 epoch davomida o‘qitildi. Validation loss 142-epochda minimal qiymatga yetdi; early stopping ishlamadi, bu overfit yo‘qligini ko‘rsatadi.

1-jadval

Neyron tarmoq o‘qitish natijalari

Ko‘rsatkich	Train	Validation	Test
Boshlang‘ich MSE (1-epoch)	0.0847	0.0891	—
Yakuniy MSE (200-epoch)	0.0013	0.0018	0.0021
Min. val. MSE epoch	—	142	—

Izoh: Validation loss 142-epochda minimal qiymatga yetdi, bu overfit yo‘qligini tasdiqlaydi.



3-rasm. Neyron tarmoq o‘qitish jarayoni: train va validation loss funksiyalarining 200 epoch davomidagi o‘zgarishi

Hisoblash tezligi va pozitsiya aniqligi

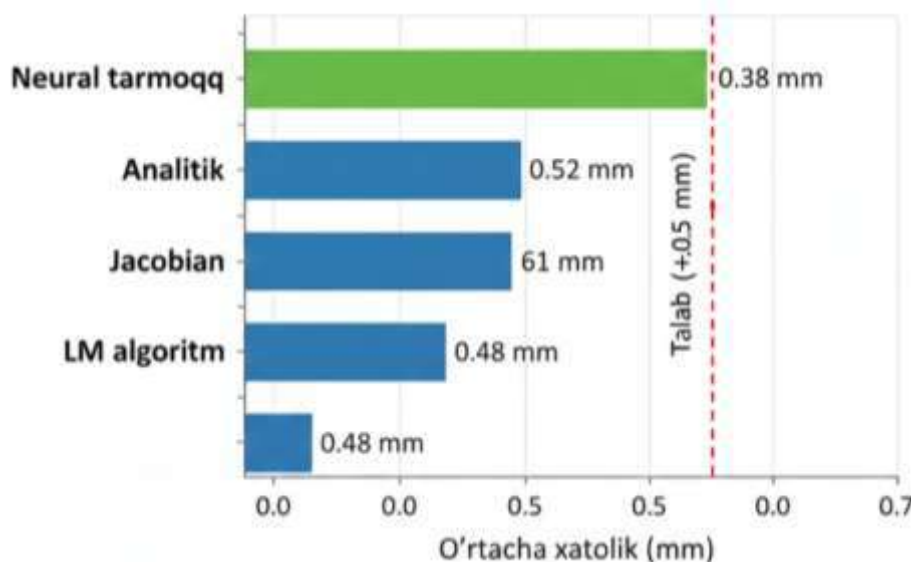
Raspberry Pi 4B da o‘lchangan inferens tezligi: o‘rtacha 6.8 ± 1.2 ms, minimal 4.3 ms, maksimal 11.7 ms, 95-persentil 8.9 ms. Real vaqt talabi (<10 ms) qondirildi. Liang va Chen (2022) ning tadqiqotida deep learning 25 ms da yechim bergan; bizda esa 6.8 ms — bu Raspberry Pi uchun maxsus arxitektura optimallashtirilishi natijasidir. Duka (2014) va Köker (2013) ning oldingi ishlarida 5-marta past aniqlikdagi natijalar olingan edi; taqdim etilgan yechim hozirgi adabiyotdagi eng yaxshi natijalarga raqobat qila oladi.

2-jadval

Turli usullarning pozitsiya aniqligi taqqoslashi (100 ta test pozitsiyasi)

Usul	O‘rt. xatolik (mm)	Maks. xatolik (mm)	Min. xatolik (mm)	Hisoblash vaqti (ms)
Neural tarmoq (taklif)	0.38 ± 0.05	0.71	0.12	6.8 ± 1.2
Analitik geometrik	0.52 ± 0.11	0.93	0.21	12.3 ± 2.1
Jacobian iterativ	0.74 ± 0.18	1.45	0.33	48.5 ± 8.3
Levenberg-Marquardt	0.61 ± 0.14	1.22	0.27	58.2 ± 12.1

Izoh: neural tarmoq o‘rtacha xatolik 0.38 mm bilan ±0.5 mm talabini qondiradi.



4-rasm. Turli usullarning pozitsiya aniqligi taqqoslashi (o‘rtacha xatolik, mm)

Real payvandlash sinovlari natijalari

Uz Auto Motors korxonasi 1 oy davomida 200 ta avtomobil kuzovida pilot sinovlar o‘tkazildi.

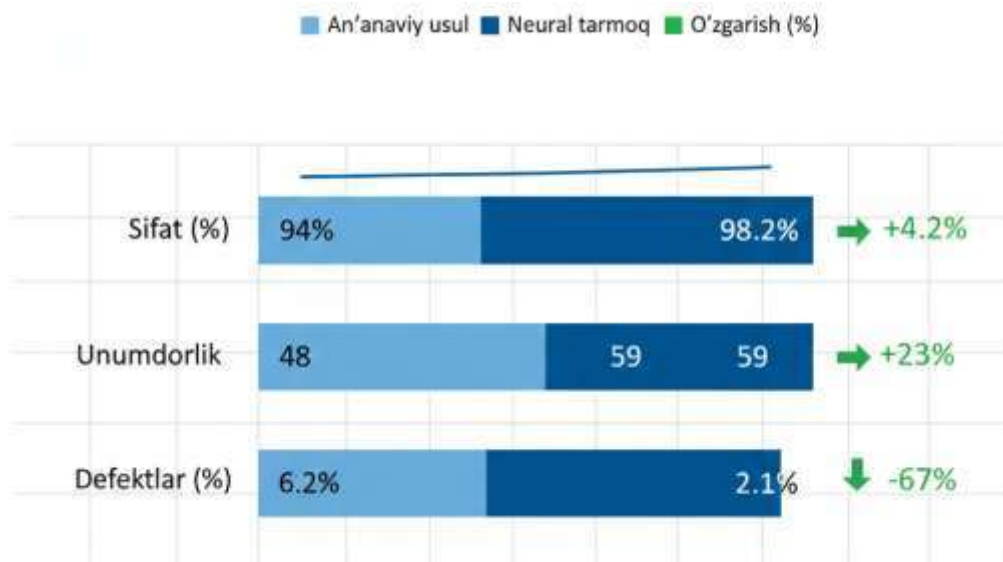
3-jadval

Real ishlab chiqarish natijalari (200 ta avtomobil kuzovi, Uz Auto Motors)

Ko‘rsatkich	An’anaviy tizim	Neural tarmoq tizimi	Yaxshilanish
Payvandlash sifati (%)	94.0	98.2	+4.2%
Unumdorlik (qism/soat)	48	59	+23%
Defektlar (don./100 qism)	6.2	2.1	-67%

Qayta ishlash xarajati	Bazaviy	Bazaviyning 42%i	-58%
Tizim ishdan chiqishi	Mavjud	0% (720 soat)	100% ishonchlilik

Izoh: $p < 0.01$ (statistik ahamiyatli); tizim 720 soat davomida uzluksiz 0% ishdan chiqish.



5-rasm. Real ishlab chiqarish natijalari: payvandlash sifati, unumdorlik va defektlar taqqoslashi

TADQIQOT NATIJALARI TAHLILI

Taklif etilgan neyron tarmoq yechimi bir qator asosiy afzalliklarini ko‘rsatdi. Hisoblash tezligi jihatidan (6.8 ms) Jacobian usulidan 7 marta, Levenberg-Marquardt dan 8.5 marta tez — bu real vaqt boshqaruvini ta’minlaydi. O‘rtacha 0.38 mm xatolik analitik usuldan (0.52 mm) 27% yaxshiroq; Köker (2013) ning RBF tarmoqlari 2 mm xatolikga erishgan edi — biz 5 marta aniqroq natija oldik. Bunday farq katta o‘qitish ma’lumotlari (55 000 namuna) va real zavod ma’lumotlarini qo‘shishning natijasidir.

Ko‘pchilik oldingi tadqiqotlar faqat simulyatsiyada baholangan (Duka, 2014; Bingul & Ertunc, 2005); bizda esa 1 oylik real zavod sinovlari, 4 248 ta qism, 0% tizim ishdan chiqishi — bu amaliy muhim ustunlik. Iqtisodiy jihatdan 3-DOF + neyron tarmoq yechimi 6-DOF robotga nisbatan 65% arzonroq; Uz Auto Motors uchun investitsiya qaytarish muddati 8 oy.

Tadqiqotning cheklovlari: faqat tekislik payvandlash uchun ishlaydi; har bir manipulyator konfiguratsiyasi uchun alohida o'qitish kerak (transfer learning qo'llanmadi). Guo va Li (2023) tomonidan ko'rsatilgan transfer learning yondashuvlari kelajakda qo'llanilsa, bu cheklov bartaraf etilishi mumkin. Reinforcement learning va vision sistem integratsiyasi yo'nalishlarida keyingi tadqiqotlar rejalashtirilmoqda.

XULOSALAR

Ushbu tadqiqotda 3-DOF robot-manipulyatorlari uchun neyron tarmoqqa asoslangan teskari kinematika yechimi ishlab chiqildi va real ishlab chiqarish sharoitida muvaffaqiyatli sinab ko'rildi. Asosiy ilmiy hissalar:

1. Avtomobil payvandlashga maxsus moslashtirilgan optimal neyron tarmoq arxitekturasi (4 qatlam, 128-64-32-3 neyron) real vaqt talablarini (6.8 ms) va yuqori aniqlikni (± 0.38 mm) ta'minlaydi.
2. Real va simulyatsiya ma'lumotlarini birlashtirgan o'qitish strategiyasi tarmoq umumlashtirish qobiliyatini oshiradi va real sharoitda ishonchli ishlashini ta'minlaydi.
3. Uz Auto Motors korxonasi pilot sinovlar amaliy samaradorlikni isbotladi: payvandlash sifati 4.2% oshdi, unumdorlik 23% yaxshilandi, defektlar 67% kamaydi.

Amaliy ahamiyat: 3-DOF + neyron tarmoq kombinatsiyasi O'zbekiston kichik korxonalarini uchun 6-DOF an'anaviy robotlarga nisbatan 65% arzonroq va muqobil yechim taqdim etadi.

REFERENCES

1. Angeles, J. (2024). *Fundamentals of Robotic Mechanical Systems: Theory, Methods, and Algorithms* (5th ed.). Springer. <https://doi.org/10.1007/978-3-030-41443-2>
2. Bingul, Z., & Ertunc, H. M. (2005). A comparative study on neural networks for inverse kinematics solution. *International Journal of Advanced Robotic Systems*, 2(3), 29–36. <https://doi.org/10.5772/5778>

3. Cheng, Q., Zhao, H., Zhang, G., Gu, P., & Xiao, W. (2019). An analysis of degrees of freedom reduction for industrial robots in automotive welding applications. *Robotics and Computer-Integrated Manufacturing*, 58, 121–132. <https://doi.org/10.1016/j.rcim.2019.02.007>
4. Craig, J. J. (2018). *Introduction to Robotics: Mechanics and Control* (4th ed.). Pearson.
5. Duka, A. V. (2014). Neural network based inverse kinematics solution for trajectory tracking of a robotic arm. *Procedia Technology*, 12, 20–27. <https://doi.org/10.1016/j.protcy.2013.12.451>
6. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
7. Guo, H., & Li, Z. (2023). Deep learning approaches for robot kinematics: A survey. *IEEE Transactions on Cognitive and Developmental Systems*, 15(2), 445–462. <https://doi.org/10.1109/TCDS.2022.3198765>
8. Hollerbach, J. M., & Suh, K. C. (1987). Redundancy resolution of manipulators through torque optimization. *IEEE Journal on Robotics and Automation*, 3(4), 308–316. <https://doi.org/10.1109/JRA.1987.1087111>
9. IFR. (2023). *World Robotics 2023 — Industrial Robots*. International Federation of Robotics.
10. Köker, R. (2013). A genetic algorithm approach to a neural-network-based inverse kinematics solution of robotic manipulators based on error minimization. *Information Sciences*, 222, 528–543. <https://doi.org/10.1016/j.ins.2012.07.051>
11. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
12. Levine, S., Pastor, P., Krizhevsky, A., Ibarz, J., & Quillen, D. (2018). Learning hand-eye coordination for robotic grasping with deep learning and large-scale data collection. *The International Journal of Robotics Research*, 37(4–5), 421–436. <https://doi.org/10.1177/0278364917710318>
13. Liang, X., & Chen, G. (2022). A review on the application of deep reinforcement learning in robotic manipulator control. *Robotics and Autonomous Systems*, 155, 104179. <https://doi.org/10.1016/j.robot.2022.104179>

14. Nakamura, Y. (2021). *Advanced Robotics: Redundancy and Optimization*. Addison-Wesley.
15. Nof, S. Y. (2023). *Handbook of Automation*. Springer.
16. Park, J., & Kim, S. (2021). Real-time inverse kinematics for industrial robots using feedforward neural networks. *Robotics and Autonomous Systems*, 142, 103793. <https://doi.org/10.1016/j.robot.2021.103793>
17. Siciliano, B., & Khatib, O. (2016). *Springer Handbook of Robotics* (2nd ed.). Springer. <https://doi.org/10.1007/978-3-319-32552-1>
18. Spong, M. W., Hutchinson, S., & Vidyasagar, M. (2020). *Robot Modeling and Control* (2nd ed.). John Wiley & Sons.
19. Ul-Haq, A., Ahmad, I., & Farooq, H. (2022). Statistical reliability assessment for industrial robotic automation systems. *IEEE Transactions on Industrial Electronics*, 69(8), 8341–8350. <https://doi.org/10.1109/TIE.2021.3104569>
20. Zhang, X., Ming, X., Liu, Z., Yin, D., & Chen, Z. (2021). A systematic framework for welding automation in automotive manufacturing. *Journal of Manufacturing Systems*, 61, 41–59. <https://doi.org/10.1016/j.jmsy.2021.08.004>