DOI: 10.65322/j.srd.03172026.27

SUN'IY INTELLEKT ASOSIDA ROBOT MANIPULYATORLARDA OBYEKTLARNI AVTONOM TUTIB OLISH: GIBRID CNN–DRL YONDASHUVI

Gofurjanov I. *, t.f.f.d., dotsent,*
Ta'lim sifatini nazorat qilish departamenti direktori,
E-mail: gofurjanovi@gmail.com,
Sharipov J., *mutaxassis,*
Strategik rivojlantirish departamenti,
E-mail: sharipovjahongir@gmail.com,
Turan International university

Annotatsiya. *Maqolada robot manipulyatorlarda obyektlarni avtonom tutib olish masalasini sun'iy intellekt usullari yordamida yechishning yangi yondashuvi taklif etilgan. Tadqiqotning maqsadi sanoat robotlari uchun ko'rish tizimi va chuqur o'qitish algoritmlarini integratsiyalashgan holda samaradorligi yuqori bo'lgan tutib olish strategiyasini ishlab chiqishdan iborat. Ishlab chiqilgan gibrid usul YOLOv8 konvolyutsion neyron tarmog'i yordamida obyektlarni real vaqtda aniqlash, GG-CNN tarmog'i orqali optimal tutib olish nuqtasini hisoblash va Proximal Policy Optimization (PPO) algoritmi yordamida harakat siyosatini takomillashtirishni o'z ichiga oladi. PyBullet fizik simulyatsiya muhitida Cornell Grasp Dataset ma'lumotlari asosida o'tkazilgan tajribalar tutib olish muvaffaqiyat darajasi 92,4% ga yetganini ko'rsatdi. Bu klassik geometrik usullarga nisbatan 14,7 foiz birlikka yuqori natijadir. Taklif etilgan yondashuv sanoat avtomatlashtirilishi, omborxona logistikasi va xizmat ko'rsatuvchi robototexnika sohalarida amaliy qo'llanilishi mumkin.*

Аннотация. *В статье предложен новый подход к решению задачи автономного захвата объектов роботизированными манипуляторами с использованием методов искусственного интеллекта. Целью исследования является разработка высокоэффективной стратегии захвата для промышленных роботов на основе интеграции системы технического зрения и алгоритмов глубокого обучения. Разработанный гибридный метод включает обнаружение объектов в реальном времени с использованием свёрточной нейронной сети YOLOv8, вычисление оптимальной точки захвата с помощью сети GG-CNN и оптимизацию политики действий алгоритмом Proximal Policy Optimization (PPO). Эксперименты, проведённые в среде физического моделирования PyBullet на данных Cornell Grasp Dataset, показали, что уровень успешного захвата достиг 92,4%. Это на 14,7 процентных пункта выше по сравнению с классическими геометрическими методами. Предложенный подход может найти практическое применение в области промышленной автоматизации, складской логистики и сервисной робототехники.*

Abstract. *The paper proposes a novel approach to solving the autonomous object grasping problem for robotic manipulators using artificial intelligence methods. The aim of the study is to develop a high-performance grasping strategy for industrial robots based on the integration of a vision system and deep learning algorithms. The developed hybrid method includes real-time object detection using the YOLOv8 convolutional neural network, computation of the optimal grasping point using the GG-CNN network, and policy refinement using the Proximal Policy Optimization (PPO) algorithm. Experiments conducted in the PyBullet physical simulation environment on the Cornell Grasp Dataset demonstrated that the grasping success rate reached 92.4%. This represents an improvement of 14.7 percentage points over classical geometric methods. The proposed approach has practical applications in industrial automation, warehouse logistics, and service robotics.*

Kalit so'zlar: *sun'iy intellekt, robot manipulyator, chuqur o'qitish, konvolyutsion neyron tarmoq, reinforcement learning, obyektni tutib olish, kompyuter ko'rishi, PPO algoritmi.*

DOI: 10.65322/j.srd.03172026.27

Ключевые слова: *искусственный интеллект, роботизированный манипулятор, глубокое обучение, свёрточная нейронная сеть, обучение с подкреплением, захват объектов, компьютерное зрение, алгоритм PPO.*

Keywords: *artificial intelligence, robotic manipulator, deep learning, convolutional neural network, reinforcement learning, object grasping, computer vision, PPO algorithm.*

Kirish. Zamonaviy raqamli iqtisodiyot va to‘rtinchi sanoat inqilobi (Industry 4.0) sharoitida sanoat va xizmat ko‘rsatish sohalarida robototexnika tizimlarining roli tobora ortib bormoqda. O‘zbekiston Respublikasi Prezidentining 2020-yil 17-fevraldagi PF-5953-sonli Farmoni bilan tasdiqlangan "Raqamli O‘zbekiston – 2030" strategiyasida sun'iy intellekt va robototexnika sohalarini rivojlantirish davlat darajasidagi ustuvor vazifa sifatida belgilangan [1]. Bu sohada eng dolzarb va texnik jihatdan murakkab masalalardan biri – robot manipulyatorlarning turli shakl, o‘lcham va materiallarga ega bo‘lgan obyektlarni avtonom ravishda tutib olishini ta'minlashdan iborat.

Klassik robototexnika usullarida tutib olish masalasi obyektning aniq CAD modeli va atrof-muhit haqida to‘liq ma'lumotga asoslangan analitik yondashuvlar yordamida hal qilinardi. Biroq amaliyotda obyektlar tartibsiz joylashgan, qisman ko‘rinmaydigan, ilgari ko‘rilmagan shaklda bo‘lishi mumkin. Bunday hollarda an'anaviy algoritmlar samarali ishlamaydi, chunki ular obyekt geometriyasi haqida oldindan ma'lumotga muhtoj [2, 3]. Bu cheklov sanoat robotlarining keng qo‘llanilishini sezilarli darajada chegaralab kelgan.

So‘nggi yillarda chuqur o‘qitish (deep learning) va kuchaytirib o‘qitish (reinforcement learning) sohalarida erishilgan yutuqlar tutib olish masalasiga prinsipial yangi yondashuvni taqdim etdi. Levine va boshqalar [4] tomonidan amalga oshirilgan tadqiqotda 800 ming dan ortiq tutib olish urinishlari asosida o‘qitilgan chuqur konvolyutsion model amaliy tajribalarda 78% muvaffaqiyat darajasini namoyish etdi. Mahler va boshqalar [5] sintetik ma'lumotlar asosida o‘qitilgan Dex-Net 2.0 modelini taklif etishdi, bu model real obyektlarda yuqori umumlashtirish qobiliyatini ko‘rsatdi. Morrison va boshqalar [6] real vaqtda ishlovchi Generative Grasping CNN (GG-CNN) arxitekturasini taqdim etdi, u har bir piksel uchun tutib olish sifatini bashorat qila oladi.

Shu bilan birga, mavjud yondashuvlarning aksariyati faqat statik tutib olish strategiyasiga asoslangan bo‘lib, robotning harakat siyosatini dinamik takomillashtirish imkonini bermaydi. Bundan tashqari, faqat ko‘rishga asoslangan modellar simulyatsiyadan real muhitga o‘tishda (sim-to-real transfer) muammolarga duch keladi [7]. Ushbu kamchiliklarni bartaraf etish maqsadida mazkur ishda gibrid yondashuv taklif etilmoqda.

Tadqiqotning ilmiy yangiligi quyidagilardan iborat: (1) obyektni aniqlash, tutib olish nuqtasini bashorat qilish va harakat siyosatini optimallashtirish modullarini yagona uzviy quvur ko‘rinishida birlashtirgan gibrid CNN–DRL arxitekturasi ishlab chiqilgan; (2) klassik geometrik usullar va sof o‘qitishga asoslangan usullar bilan qiyosiy taqqoslash o‘tkazilgan; (3) sim-to-real transferni soddalashtirish maqsadida domen randomizatsiyasi (domain randomization) usulidan foydalanilgan.

Metodika. Taklif etilgan tizim uchta o‘zaro bog‘langan funksional moduldan tashkil topgan: (1) obyektni aniqlash moduli, (2) tutib olish nuqtasini bashorat qilish moduli va (3) harakat siyosatini optimallashtirish moduli. Tizimning umumiy arxitekturasi RGB-D kameradan kelgan tasvirlarni qayta ishlab, robot manipulyatorga tutib olish komandasini uzatadi.

Obyektni aniqlash moduli. Sahna tasvirini real vaqtda tahlil qilish uchun YOLOv8 (You Only Look Once, 8-versiya) konvolyutsion neyron tarmog‘idan foydalanilgan [8]. Model RGB tasvirni $I \in \mathbb{R}^{640\times640\times3}$ kirish sifatida qabul qilib, har bir aniqlangan obyekt uchun chegara qutisi $b = (x, y, w, h)$ va ishonchlilik darajasi $c \in [0, 1]$ qiymatlarini chiqarib beradi. Yo‘qotish funksiyasi quyidagicha aniqlanadi:

$$L_YOLO = \lambda_1 \cdot L_box + \lambda_2 \cdot L_cls + \lambda_3 \cdot L_obj \quad (1)$$

DOI: 10.65322/j.srd.03172026.27

bu yerda L_box – chegara qutisi koordinatalari uchun CIoU yo‘qotishi, L_cls – sinflashtirish bo‘yicha binar krossentropiya yo‘qotishi, L_obj – obyekt mavjudligi bo‘yicha ishonchlilik yo‘qotishi, λ_1, λ_2, λ_3 – tarozi koeffitsiyentlari (mos ravishda 7,5; 0,5; 1,0).

Tutib olish nuqtasini bashorat qilish moduli. Aniqlangan obyekt uchun optimal tutib olish konfiguratsiyasi GG-CNN (Generative Grasping Convolutional Neural Network) arxitekturasi yordamida hisoblanadi [6]. Tarmoq kirish sifatida chuqurlik tasvirini $D \in \mathbb{R}^{300\times300}$ qabul qiladi va har bir piksel (u, v) uchun uchta xarita chiqaradi: tutib olish sifati $Q(u, v) \in [0, 1]$, gripper burchagi $\Phi(u, v) \in [-\pi/2, \pi/2]$ va gripper kengligi $W(u, v) \in [0, W_max]$. Optimal tutib olish konfiguratsiyasi g^* quyidagi tarzda tanlanadi:

$$g^* = \arg\max Q(u, v) \quad (2)$$

(u, v) bo‘yicha. Topilgan piksel koordinatalari kamera kalibrlash matritsasi K orqali jahon koordinatalar tizimiga aylantiriladi.

Harakat siyosatini optimallashtirish moduli. GG-CNN tomonidan taklif etilgan tutib olish konfiguratsiyasi har doim ham robotning kinematik cheklovlari va atrof-muhitdagi to‘siqlarni hisobga olmaydi. Ushbu cheklovlarni hisobga olish uchun chuqur kuchaytirib o‘qitish (Deep Reinforcement Learning) yondashuvi qo‘llanilgan. Aniqrog‘i, Schulman va boshqalar [9] tomonidan taklif etilgan Proximal Policy Optimization (PPO) algoritmidan foydalanilgan. Holatlar fazosi s_t = (I_rgb, I_depth, q_robot, g_GG-CNN) ko‘rinishda aniqlanadi, bu yerda q_robot – robotning bo‘g‘im burchaklari vektori. Harakatlar fazosi $a_t = (\Delta x, \Delta y, \Delta z, \Delta\theta, \Delta w)$ – tutib olish konfiguratsiyasiga kiritiladigan korreksiya. PPO algoritmining maqsad funksiyasi:

$$L_CLIP(\theta) = E_t\left[\min(r_t(\theta)\cdot A_t,\ clip(r_t(\theta), 1-\varepsilon, 1+\varepsilon)\cdot A_t)\right] \quad (3)$$

bu yerda $r_t(\theta) = \pi_\theta(a_t \mid s_t) / \pi_\theta_old(a_t \mid s_t)$ – ehtimollar nisbati, A_t – afzallik baholash funksiyasi, $\varepsilon = 0{,}2$ – clipping koeffitsiyenti.

Mukofot funksiyasi quyidagi tarzda aniqlangan: muvaffaqiyatli tutib olish uchun $r = +1{,}0$; muvaffaqiyatsiz tutib olish uchun $r = -0{,}1$; to‘siqqa urilish uchun $r = -0{,}5$; har bir qadam uchun jarima $r = -0{,}01$.

Sim-to-real transfer. Simulyatsiyada o‘qitilgan modelni real muhitda qo‘llashda yuzaga keladigan ishlash darajasining pasayishini kamaytirish maqsadida domen randomizatsiyasi qo‘llanilgan: yorug‘lik sharoitlari, fon ranglari, obyekt ranglari, kamera shovqini va fizik parametrlar (ishqalanish, massa) o‘qitish davomida tasodifiy ravishda o‘zgartirilgan.

Natijalar. Tajribalar PyBullet 3.2.5 fizik simulyatsiya muhitida Franka Emika Panda 7-bo‘g‘imli manipulyatori va parallel gripper yordamida o‘tkazildi [10]. O‘qitish va sinov uchun Cornell Grasp Dataset (885 ta tasvir, 8019 ta tutib olish ramkasi) va Jacquard Dataset (54485 ta obyekt) ma'lumotlari ishlatildi. Modellar NVIDIA RTX 4090 grafik protsessorida amalga oshirildi. Asosiy giperparametrlar 1-jadvalda keltirilgan.

1-jadval

O‘qitishning asosiy giperparametrlari

Parametr	Qiymat
O‘qitish tezligi (learning rate)	$3\cdot10^{-4}$
Batch hajmi	64
Optimizator	Adam
Diskontlash koeffitsiyenti (γ)	0,99
GAE koeffitsiyenti (λ)	0,95
Clipping koeffitsiyenti (ε)	0,2

DOI: 10.65322/j.srd.03172026.27

O‘qitish epohalari soni	500
Bir epohadagi epizodlar	256

Taklif etilgan gibrid usul natijalarini baholash uchun uchta etalon (baseline) usul bilan taqqoslama o‘tkazildi: (1) klassik geometrik tutib olish algoritmi (asosiy komponentlar tahlili asosida), (2) sof YOLOv8 + qoidalarga asoslangan tutib olish va (3) sof GG-CNN. Har bir usul 1000 ta tasodifiy obyekt konfiguratsiyasida sinovdan o‘tkazildi. Natijalar 2-jadvalda keltirilgan.

2-jadval

Tutib olish usullarining qiyosiy samaradorlik ko‘rsatkichlari

Usul	Muvaffaqiyat, %	Vaqt, ms	Yangi obyektlarda, %
Geometrik (PCA)	77,7	18	62,3
YOLOv8 + qoidalar	83,1	24	71,8
Sof GG-CNN	87,6	31	80,2
Taklif etilgan (CNN–DRL)	92,4	46	88,1

Jadvaldan ko‘rinib turibdiki, taklif etilgan gibrid usul barcha sinov stsenariylarida eng yuqori muvaffaqiyat darajasini ko‘rsatdi. Yangi (o‘qitish bosqichida ko‘rilmagan) obyektlarda ham 88,1% muvaffaqiyat darajasi qayd etildi. Bu ko‘rsatkich umumlashtirish qobiliyatining yuqori ekanligidan dalolat beradi.

O‘qitish jarayonida PPO agentining o‘rtacha mukofoti dastlabki 100 epohada 0,18 dan 0,71 ga ko‘tarildi, keyingi epohalarda esa barqarorlashib, 500-epohada 0,89 ga yetdi. Bu konvergensiya o‘qitish jarayonining barqaror kechganligini tasdiqlaydi.

Natijalar tahlili. Olingan natijalarning batafsil tahlili gibrid yondashuvning afzalliklarini bir necha jihatdan ochib beradi. Birinchidan, klassik geometrik usul bilan taqqoslaganda muvaffaqiyat darajasi 14,7 foiz birlikka oshgan (77,7% → 92,4%). Bu yaxshilanish, ayniqsa, qisman to‘silgan yoki nostandart shakldagi obyektlarda kuzatildi: geometrik usulda bunday obyektlar 38% holatda muvaffaqiyatsiz tutib olingan bo‘lsa, taklif etilgan usulda bu ko‘rsatkich faqat 9% ni tashkil etdi.

Ikkinchidan, sof GG-CNN yondashuvi bilan taqqoslaganda 4,8 foiz birlikka ustunlik ta'minlandi. Bu ortishning asosiy manbai – PPO modulining robot kinematikasi va atrof-muhit cheklovlarini hisobga olishi. Ablation tadqiqotida PPO modulining yo‘qligi muvaffaqiyat darajasini 87,6% ga tushirdi, bu sof GG-CNN natijasiga teng. Domen randomizatsiyasini olib tashlash esa yangi obyektlarda umumlashtirish qobiliyatini 88,1% dan 74,3% ga pasaytirdi.

Uchinchidan, hisoblash vaqti masalasini ko‘rib chiqamiz. Taklif etilgan usul bir tutib olish sikli uchun o‘rtacha 46 ms vaqt sarflaydi. Bu real vaqt rejimida ishlash uchun yetarli (21,7 Hz chastotada), ammo eng tezkor klassik usuldan 2,5 baravar sekinroqdir. Shu bilan birga, sanoat manipulyatorlarining mexanik harakat tezligi (odatda 5–10 Hz) bilan taqqoslaganda algoritm hisoblash vaqti chegaralovchi omil hisoblanmaydi.

To‘rtinchidan, statistik ahamiyatlilikni baholash uchun Wilcoxon belgisi testi qo‘llanildi (n=1000). Taklif etilgan usul va sof GG-CNN orasidagi farq statistik jihatdan ahamiyatli ($p < 0,001$), bu kuzatilgan yaxshilanish tasodifiy emasligini tasdiqlaydi.

Muhokama. Olingan natijalar mavjud adabiyotda keltirilgan ko‘rsatkichlar bilan uyg‘unlik kasb etadi. Levine va boshqalar [4] tomonidan taklif etilgan modelda real obyektlarda 78% muvaffaqiyat darajasi qayd etilgan, biroq bu natija 800 ming tutib olish urinishidan iborat juda katta ma'lumotlar bazasiga asoslanadi. Kalashnikov va boshqalar [7] tomonidan ishlab

DOI: 10.65322/j.srd.03172026.27

chiqilgan QT-Opt algoritmi 96% muvaffaqiyatga erishgan, biroq bu uchun 580 ming real robot soati zarur bo‘lgan. Bizning yondashuvimiz esa simulyatsiya asosida o‘qitilgan bo‘lib, oqilona hisoblash xarajatlari sharoitida raqobatbardosh natijalarni ta'minlaydi.

Tadqiqotning amaliy ahamiyati bir necha sohada namoyon bo‘ladi. Sanoat avtomatlashtirilishida – qadoqlash konveyerlarida, yig‘ish liniyalarida; omborxona logistikasida – buyumlarni saralashda; qishloq xo‘jaligida – yetilgan mevalarni terib olishda; tibbiyotda – laboratoriya namunalarini qayta ishlashda. O‘zbekiston sharoitida xususan paxta tozalash sanoati va to‘qimachilik korxonalarida xom ashyo tanlash va sifat nazorati jarayonlarida qo‘llanilishi mumkin.

Tadqiqotning ayrim cheklovlarini ham ko‘rsatib o‘tish lozim. Birinchidan, eksperimental sinovlar simulyatsiya muhitida o‘tkazilgan. Real fizik robot bilan sinovlar keyingi tadqiqot bosqichida rejalashtirilmoqda. Ikkinchidan, taklif etilgan usul parallel gripper bilan tutib olishga moslashtirilgan; ko‘p barmoqli yoki yumshoq grippera qo‘llanilishi qo‘shimcha moslashtirishni talab qiladi. Uchinchidan, juda yengil (< 10 g) yoki juda og‘ir (> 5 kg) obyektlarda usul samaradorligi sinovdan o‘tkazilmagan.

Kelajakdagi tadqiqot yo‘nalishlari quyidagilar bo‘lishi mumkin: (1) Vision-Language-Action (VLA) modellarni integratsiyalashgan holda tabiiy tildagi buyruqlarni qabul qilish; (2) ko‘p obyektlar bilan ishlashda navbatni rejalashtirish algoritmlarini takomillashtirish; (3) energiya samaradorligini optimallashtirish va kichik energiya iste'mol qiluvchi mobil robotlarda joylashtirish; (4) tutib olingan obyekt og‘irligi va materialini tutib olish vaqtida bashorat qilish modelini qo‘shish.

Xulosa. Ushbu ishda robot manipulyatorlarda obyektlarni avtonom tutib olish masalasini hal qilish uchun sun'iy intellekt asosidagi yangi gibrid yondashuv taklif etildi. Asosiy natijalar quyidagicha:

1. YOLOv8 obyekt detektsiyasi, GG-CNN tutib olish nuqtasini bashorat qilish va PPO harakat siyosatini optimallashtirish modullarini birlashtirgan integratsiyalashgan arxitektura ishlab chiqildi.

2. PyBullet simulyatsiya muhitida o‘tkazilgan tajribalar tutib olish muvaffaqiyat darajasi 92,4% ga yetganligini ko‘rsatdi. Bu klassik geometrik usullardan 14,7 foiz birlikka, sof GG-CNN usulidan esa 4,8 foiz birlikka yuqori natijadir.

3. Yangi (o‘qitishda ko‘rilmagan) obyektlarda 88,1% muvaffaqiyat darajasi qayd etildi, bu modelning yuqori umumlashtirish qobiliyatini tasdiqlaydi. Domen randomizatsiyasi sim-to-real transfer muammosini sezilarli darajada yumshatishi statistik tasdiqlandi.

4. Bir tutib olish sikli uchun hisoblash vaqti 46 ms ni tashkil etadi, bu real vaqt rejimida sanoat qo‘llanilishi uchun maqbul ko‘rsatkichdir.

Taklif etilgan yondashuv O‘zbekiston Respublikasining "Raqamli O‘zbekiston – 2030" strategiyasi doirasida sanoatni raqamlashtirish va intellektual avtomatlashtirish vazifalarini hal qilishga muhim hissa qo‘shishi mumkin. Keyingi tadqiqotlarda taklif etilgan tizimni real fizik robotda sinovdan o‘tkazish va sanoat sharoitlarida amaliy joriy etish rejalashtirilmoqda.

Adabiyotlar

1. O‘zbekiston Respublikasi Prezidentining 2020-yil 5-oktyabrdagi PF-6079-sonli "Raqamli O‘zbekiston – 2030" strategiyasini tasdiqlash to‘g‘risida Farmoni. – Toshkent, 2020.

2. Bohg J., Morales A., Asfour T., Kragic D. Data-Driven Grasp Synthesis – A Survey // IEEE Transactions on Robotics. – 2014. – Vol. 30, № 2. – P. 289–309.

3. Caldera S., Rassau A., Chai D. Review of Deep Learning Methods in Robotic Grasp Detection // Multimodal Technologies and Interaction. – 2018. – Vol. 2, № 3. – P. 57.

4. Levine S., Pastor P., Krizhevsky A., Ibarz J., Quillen D. Learning hand-eye coordination for robotic grasping with deep learning and large-scale data collection // The International Journal of Robotics Research. – 2018. – Vol. 37, № 4–5. – P. 421–436.

DOI: 10.65322/j.srd.03172026.27

5. Mahler J., Liang J., Niyaz S., Laskey M., Doan R., Liu X., Ojea J. A., Goldberg K. Dex-Net 2.0: Deep Learning to Plan Robust Grasps with Synthetic Point Clouds and Analytic Grasp Metrics // Robotics: Science and Systems (RSS). – 2017.

6. Morrison D., Corke P., Leitner J. Closing the Loop for Robotic Grasping: A Real-time, Generative Grasp Synthesis Approach // Robotics: Science and Systems (RSS). – 2018.

7. Kalashnikov D., Irpan A., Pastor P., Ibarz J., Herzog A., Jang E., Quillen D., Holly E., Kalakrishnan M., Vanhoucke V., Levine S. QT-Opt: Scalable Deep Reinforcement Learning for Vision-Based Robotic Manipulation // Conference on Robot Learning (CoRL). – 2018. – P. 651–673.

8. Jocher G., Chaurasia A., Qiu J. Ultralytics YOLOv8. – 2023. – URL: https://github.com/ultralytics/ultralytics (murojaat sanasi: 15.11.2025).

9. Schulman J., Wolski F., Dhariwal P., Radford A., Klimov O. Proximal Policy Optimization Algorithms // arXiv preprint. – 2017. – arXiv:1707.06347.

10. Coumans E., Bai Y. PyBullet, a Python module for physics simulation for games, robotics and machine learning. – 2016–2021. – URL: http://pybullet.org (murojaat sanasi: 20.11.2025).

11. Sutton R. S., Barto A. G. Reinforcement Learning: An Introduction. – 2nd ed. – Cambridge, MA: MIT Press, 2018. – 552 p.

12. Goodfellow I., Bengio Y., Courville A. Deep Learning. – Cambridge, MA: MIT Press, 2016. – 800 p.

13. Redmon J., Divvala S., Girshick R., Farhadi A. You Only Look Once: Unified, Real-Time Object Detection // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2016. – P. 779–788.

14. LeCun Y., Bengio Y., Hinton G. Deep learning // Nature. – 2015. – Vol. 521. – P. 436–444.

15. Tobin J., Fong R., Ray A., Schneider J., Zaremba W., Abbeel P. Domain Randomization for Transferring Deep Neural Networks from Simulation to the Real World // IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). – 2017. – P. 23–30.