

DOI 10.5281/zenodo.20587625

Link: <https://doi.org/10.5281/zenodo.20587625>

SANOAT TEXNIK OBYEKTЛАRI UCHUN CHUQUR O‘RGANISHGA ASOSLANGAN NOSOZLIKЛАRNI ANIQLASH VA BASHORATLI TEXNIK XIZMAT KO‘RSATISH TIZIMI

Batirbek Kaipbergenov

Axborot tizimlari va texnologiyalari kafedrasi, Nukus davlat texnika universiteti

k.batyrbek@nukusstu.uz

Davronbek Seytniyazov

Axborot tizimlari va texnologiyalari kafedrasi, Nukus davlat texnika universiteti,

d.seytniyazov@nukusstu.uz

Bayrambay Shanazarov

Sun'iy intellekt kafedrasi, Toshkent davlat iqtisodiyot universiteti,

bayramsh90@gmail.com

Kazbek Ergaliyev

Axborot tizimlari va texnologiyalari kafedrasi, Nukus davlat texnika universiteti,

kdmergaliev@gmail.com

Aydos Atamuratov

Axborot tizimlari va texnologiyalari kafedrasi, Nukus davlat texnika universiteti,

aydos1990@gmail.com

Annotatsiya: Ushbu maqolada sanoat texnik obyektlari — xususan, issiqlik elektr stantsiyalari — uchun mo'ljallangan chuqur o'rganishga asoslangan nosozliklarni aniqlash va bashoratli texnik xizmat ko'rsatish tizimi taqdim etiladi. Taklif qilingan tizim graf neyron tarmoqlari (GNN), ko'p agentli mustahkamlash o'rganishi (MARL), Proximal Policy Optimization (PPO) va Soft Actor-Critic (SAC) algoritmlarini hamda Shapley-asosli koordinatsiya mexanizmini birlashtiradi. Eksperimental natijalar GNN+MARL giperlarning nosozliklarni aniqlash aniqligini 98.3% ga, F1-ko'rsatkichni esa 97.5% ga etkazganini ko'rsatdi, bu esa mavjud usullardan sezilarli darajada ustun kelishini tasdiqlaydi. Bundan tashqari, tizim real vaqtda kechikishni 22.6 ms chegarasida saqlab qoladi, bu esa sanoat joylashtirishning amaliy talablariga javob beradi.

Kalit so'zlar: chuqur o'rganish, nosozliklarni aniqlash, graf neyron tarmoqlari, ko'p agentli mustahkamlash o'rganishi, bashoratli texnik xizmat, issiqlik elektr stantsiyasi.

Аннотация: В данной статье представлена система выявления неисправностей и прогнозного технического обслуживания на основе глубокого обучения, предназначенная для промышленных технических объектов, в частности для тепловых электростанций. Предлагаемая система объединяет графовые нейронные сети (GNN), многоагентное обучение с подкреплением (MARL), алгоритмы Proximal Policy Optimization (PPO) и Soft Actor-Critic (SAC), а также механизм координации на основе метода Шепли. Экспериментальные результаты показали, что модель GNN+MARL повысила точность выявления неисправностей до 98,3%, а показатель F1 — до 97,5%, что подтверждает её значительное превосходство над существующими методами. Кроме того, система сохраняет задержку в режиме реального времени в пределах 22,6 мс, что соответствует практическим требованиям промышленного внедрения.

Ключевые слова: глубокое обучение, выявление неисправностей, графовые нейронные сети, многоагентное обучение с подкреплением, прогнозное техническое обслуживание, тепловая электростанция.

KIRISH

Zamonaviy sanoat korxonalarida, xususan energetika sektorida, texnik obyektlarning ishonchli ishlashi davlat iqtisodiyoti va fuqarolar hayoti uchun hal qiluvchi ahamiyat kasb etadi. Issiqlik elektr stantsiyalarida qozon, turbina, generator va yordamchi tizimlardagi kutilmagan nosozliklar nafaqat katta moddiy zararga, balki halokatli oqibatlariga ham olib kelishi mumkin. Shu sababli, ushbu tizimlarda nosozliklarni erta aniqlash va bashoratli texnik xizmat ko'rsatish (predictive maintenance) masalasi tobora dolzarb ahamiyat kasb etmoqda.

An'anaviy qoidalarga asoslangan nosozliklarni aniqlash tizimlari (rule-based fault detection systems) tizim parametrlarining oldindan belgilangan chegara qiymatlariga asoslangan bo'lib, murakkab, dinamik va o'zaro bog'liq sanoat jarayonlarida yetarli samaradorlikni ta'minlay olmaydi [1]. Shuningdek, ushbu yondashuv har bir tizim uchun mutaxassis bilimlarini qo'lda kodlashni talab etadi, bu esa katta hajmli va murakkab sanoat obyektlarida amaliy qo'llash uchun maqbul hisoblanmaydi.

Chuqur o'rganish (deep learning, DL) texnologiyalarining jadal rivojlanishi nosozliklarni aniqlash sohasida yangi imkoniyatlar yaratdi. Xususan, vaqtli ketma-ketliklarni tahlil qiluvchi rekurrent neyron tarmoqlari (RNN, LSTM) [2], konvolyutsion neyron tarmoqlari (CNN) [3] va avtoenkoderlarga (autoencoder) asoslangan anomaliyalarni aniqlash tizimlari [4] sanoat qo'llanmalarida keng o'rganilgan. Ammo ushbu usullar sensorlar o'rtasidagi murakkab topologik munosabatlarni to'liq hisobga olmaydi va ko'p komponentli tizimlar uchun markazlashtirilgan boshqaruv arxitekturasiga asoslanadi, bu esa masshtablanish va real vaqtda ishlash nuqtai nazaridan cheklovlarga ega.

Ushbu tadqiqotda yuqoridagi cheklovlarni bartaraf etish maqsadida GNN, MARL, PPO/SAC va Shapley-asosli koordinatsiyani o'z ichiga olgan integral giperlarchi taklif etiladi. Taklif qilingan tizim quyidagi asosiy muammolarni hal etadi: (1) sensorlar o'rtasidagi topologik bog'liqliklarni dinamik graf sifatida modellashtirish, (2) ko'p komponentli tizimni taqsimlangan agentlar yordamida avtomatik boshqarish, (3) Shapley qiymatlari asosida kredit belgilash muammosini (credit assignment problem) adolatli hal qilish.

Maqolaning qolgan qismi quyidagi tartibda tashkil etilgan: 2-bo'limda tegishli adabiyotlar tahlil qilinadi; 3-bo'limda muammo rasmiy ifodasi keltiriladi; 4-bo'limda taklif qilingan metodologiya batafsil tavsiflanadi; 5-bo'limda eksperimental baholash natijalari muhokama qilinadi; 6-bo'limda xulosalar va kelajak yo'nalishlar bayon etiladi.

ADABIYOTLAR TAHLILI

Chuqur o'rganishga asoslangan nosozliklarni aniqlash

Chuqur o'rganish usullarini sanoat nosozliklarini aniqlashga qo'llash so'nggi o'n yil ichida intensiv rivojlandi. Zhang va boshq. [5] LSTM tarmoqlarini turbina tebranish signallarini tahlil qilish uchun qo'llab, 91.2% aniqlikka erishdi. Jiang va boshq. [6] CNN-1D arxitekturasini vaqt qatorlari tasnifiga moslashtirdi va motor

dvigatellari nosozliklarida 89.5% natija ko'rsatdi. Lei va boshq. [7] esa chuqur autoenkoderlarga asoslangan anomaliyalarni aniqlash yondashuvini taklif qildi, bu usul etiketlanmagan ma'lumotlarda ham qo'llana oladi.

Biroq ko'pchilik mavjud usullar bir komponentli tizimlarga yo'naltirilgan bo'lib, komponentlar o'rtasidagi o'zaro ta'sir va topologik bog'liqliklarni e'tiborga olmaydi. Hasan va boshq. [8] bu muammoni ko'rsatib o'tib, ko'p sensorli tizimlarda individual tahlilning cheklovlarini batafsil muhokama qildi.

Graf neyron tarmoqlari sanoatda

GNN [9] dastlab molekulyar tuzilmalarni tahlil qilish uchun ishlab chiqilgan bo'lsa-da, keyinchalik murakkab grafik strukturalar bilan ifodalanuvchi sanoat tizimlarida keng qo'llanila boshladi. Wu va boshq. [10] GNN-ni elektr tarmog'i xatolarini aniqlashga tatbiq etdi va an'anaviy usullardan 7.3% yuqori aniqlikka erishdi. Zhou va boshq. [11] grafik konvolyutsion tarmoqlarini (GCN) mexanik tizimlardagi nosozliklarni diagnostika qilish uchun qo'llab, sensor munosabatlarini dinamik graflar sifatida tasvirladi. Li va boshq. [12] esa issiqlik almashish tizimlarida GNN-asosli anomaliyalarni aniqlashni o'rganib, tizim topologiyasini hisobga olish aniqlikni sezilarli oshirishini isbotladi.

Ko'p agentli mustahkamlash o'rganishi sanoatda

MARL sanoat jarayonlarini taqsimlangan boshqarish uchun istiqbolli paradigma sifatida tan olinmoqda [13]. PPO algoritmi [14] uzoq davom etuvchi stabil o'qitish xususiyati sababli sanoat qo'llanmalarida keng qo'llaniladi. SAC [15] esa entropiyaga asoslangan ob'ektiv funksiya orqali qidiruv-foydalanish balansini samarali boshqaradi. Lowe va boshq. [16] ko'p agentli muhitlarda markazlashtirilgan o'qitish va taqsimlangan bajarishni (CTDE) taklif etdi, bu esa sanoat nazorat tizimlariga juda mos keladi.

Shapley qiymatlari [17] kooperativ o'yin nazariyasidan olinib, MARL tizimlarida kredit belgilash muammosini hal qilish uchun muvaffaqiyatli tatbiq etildi [18]. Ushbu yondashuv har bir agentning umumiy natijaga hissasini adolatli baholashga imkon beradi, bu esa taqsimlangan sanoat nazorat tizimlarida ayniqsa muhim.

MUAMMO RASMIY IFODASI

Faraz qilaylik, sanoat texnik obyekti $S = \{s_1, s_2, \dots, s_n\}$ to'plami sifatida ifodalansin, bunda s_i i-chi quyi tizimni bildiradi. Har bir quyi tizim s_i uchun davlat vektori $x_i(t) \in \mathbb{R}^d$ mavjud bo'lib, u d ta sensor o'lchovi asosida t vaqt momentida aniqlanadi. Butun tizim holati $X(t) = \{x_1(t), x_2(t), \dots, x_n(t)\}$ sifatida belgilanadi.

Nosozliklarni aniqlash masalasi quyidagicha rasmiy ifodalanadi: berilgan tarix oynasi $T = \{t-\tau, \dots, t\}$ uchun tizim holati ketma-ketligi $X(T)$ asosida quyidagi ikkilik tasnif funksiyasini aniqlash:

$$f: X(T) \rightarrow \{0, 1\}^n$$

bunda $f(X(T))_i = 1$ i-chi quyi tizimda nosozlik mavjudligini, 0 esa normal holatni bildiradi. Bashoratli texnik xizmat ko'rsatish uchun esa kelajakdagi h vaqt oralig'idagi nosozlik ehtimolligini bashorat qiluvchi quyidagi funksiya aniqlanadi:

$$g: X(T) \rightarrow [0, 1]^n, \text{ bunda } g(X(T))_i = P(f_i(t+h) = 1 | X(T))$$

Tizimlararo bog'liqliklarni ifodalash uchun $G = (V, E, W)$ dinamik grafidan foydalaniladi, bunda $V = \{v_1, \dots, v_n\}$ tugunlar (quyi tizimlar), $E \subseteq V \times V$ qirralar (fizik yoki funksional bog'liqliklar) va $W: E \rightarrow \mathbb{R}^+$ qirra og'irliklari to'plamini bildiradi. Ushbu graf vaqt o'tishi bilan yangilanib turadi: $G(t) = (V, E(t), W(t))$.

TAKLIF QILINGAN METODOLOGIYA

Umumiy arxitektura

Taklif qilingan tizim to'rt asosiy moduldan iborat: (1) Ma'lumotlarni qayta ishlash va sensor integratsiyasi moduli; (2) GNN-asosli nosozliklarni aniqlash moduli; (3) MARL-asosli bashoratli texnik xizmat ko'rsatish moduli; (4) Shapley-asosli koordinatsiya va qaror qabul qilish moduli. Ushbu modullar ma'lumotlar uzatish va qayta aloqa mexanizmlari orqali o'zaro integratsiyalashgan.

Ma'lumotlarni qayta ishlash

Sanoat muhitida sensor ma'lumotlari ko'pincha shovqin, o'tkazib yuborilgan qiymatlar va heterojen namuna chastotalari bilan ifloslangan. Ushbu muammolarni bartaraf etish uchun ko'p bosqichli qayta ishlash konveyeri qo'llaniladi. Birinchidan, interpolyatsiya va Kalman filtrlash usullari yordamida o'tkazib yuborilgan qiymatlar tiklanadi. Ikkinchidan, Z-score normalizatsiyasi yordamida sensor qiymatlari standartlashtiriladi: $\hat{x} = (x - \mu) / \sigma$, bunda μ va σ mos ravishda o'rtacha va standart og'ishni bildiradi. Uchinchidan, Hampel identifikatori yordamida ekstremal qiymatlar (outlier) aniqlanib, o'chiriladi.

Vaqtli oyna yondashuvi qo'llaniladi: $\tau = 60$ soniya uzunlikdagi oynalar, 30 soniya siljish bilan hosil qilinadi. Har bir oyna ichida 13 ta statistik xususiyat (o'rtacha, dispersiya, oblique, kurtosis, min, max va boshq.) hisoblanib, asosiy sensor qiymatlari bilan birlashtirilib yakuniy xususiyat vektori tashkil etiladi.

Graf neyron tarmog'i moduli

GNN moduli uchun dinamik grafni qurishda sanoat obyektining fizik topologiyasi va sensor korrelyatsiyalari hisobga olinadi. Qirra og'irliklari Pearson korrelyatsiya koeffitsientlari asosida dinamik ravishda hisoblanadi: $w_{ij}(t) = |\text{corr}(x_i(t-\tau:t), x_j(t-\tau:t))|$, agar $w_{ij} > \theta$ bo'lsa, bu ikkala komponent o'rtasidagi qirra sifatida qo'shiladi.

Xabar uzatish (message passing) mexanizmi quyidagi formula asosida amalga oshiriladi:

$$h_i^{(l+1)} = \sigma(W^{(l)} \cdot \text{AGGR}(\{ h_j^{(l)} \cdot w_{ij} : j \in N(i) \cup \{i\} \}))$$

bunda $h_i^{(l)}$ l-chi qatlam chiqishidagi i-tugun xususiyat vektori, $\text{AGGR}(\cdot)$ o'rtacha agreglash funksiyasi, $W^{(l)}$ l-chi qatlam parametrlar matritsasi, $\sigma(\cdot)$ esa ReLU

faollashtirish funksiyasi. $L = 4$ ta GNN qatlami qo'llaniladi. So'nggi qatlam chiqishlari global o'rtacha havza (global mean pooling) orqali agreglanib, nosozlikni tasniflash uchun to'liq ulanish qatlamiga uzatiladi.

4.4. MARL moduli: PPO va SAC gibridi

MARL modulida har bir quyi tizim s_i uchun alohida agent A_i aniqlanadi. Agent holati $s_i(t) = \{h_i^{(L)}, \text{GNN chiqishi, tizim xolati tarixi}\}$ dan iborat. Amal fazosi A_i uchun diskret: $\{\text{TA'MIR_BUYUR, TEXNIK_NAZORAT, NORMAL_ISHLASH, ISHDAN_TO'XTAT}\}$ to'rt amalni o'z ichiga oladi.

Mukofot funksiyasi quyidagicha belgilanadi:

$$r_i(t) = \alpha \cdot TP_i(t) - \beta \cdot FP_i(t) - \gamma \cdot C_i(t) + \delta \cdot E_i(t)$$

bunda TP_i to'g'ri aniqlangan nosozliklar soni, FP_i noto'g'ri ogohlantirishlar, C_i texnik xizmat ko'rsatish xarajatlari va E_i energiya samaradorligi ko'rsatkichi. $\alpha = 1.0$, $\beta = 0.5$, $\gamma = 0.3$, $\delta = 0.2$ giperaraliqlarni belgilaydi.

Doimiy xarakterli nazorat amallari (masalan, turbina quvvatini sozlash) uchun SAC qo'llaniladi, diskret qarorlar (texnik xizmat buyurtmasi) uchun esa PPO ishlatiladi. Ikkala algoritmni birlashtirish uchun ierarxik arxitektura qo'llaniladi: yuqori darajali PPO agent strategik qaror qabul qilsa, quyi darajali SAC agent taktik parametrlarni optimallashtiradi.

4.5. Shapley-asosli koordinatsiya

Ko'p agentli tizimda kredit belgilash muammosini hal qilish uchun Shapley qiymatlari [17] qo'llaniladi. i -chi agentning Shapley qiymati quyidagicha hisoblanadi:

$$\phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(|N|-|S|-1)!}{|N|!} \cdot [v(S \cup \{i\}) - v(S)]$$

bunda N barcha agentlar to'plami, $S \subseteq N \setminus \{i\}$ koalitsiya, $v(S)$ koalitsiyaning umumiy mukofot funksiyasi. Haqiqiy vaqt talablariga javob berish uchun Monte-Karlo approksimatsiyasi (1000 samplingli) qo'llaniladi, bu esa hisoblash murakkabligini $O(2^n)$ dan $O(n \cdot k)$ ga kamaytiradi (k = namunaviy koalitsiyalar soni).

Koordinatsiya mexanizmi umumiy qarorlarni shu tarzda optimallashtiriladi: har bir agent Shapley qiymati nisbatida mukofot oladi, bu esa tizim darajasidagi maqsadga erishish uchun optimizatsiyaga rag'batlantiradi va agentlararo muvofiqlikni ta'minlaydi.

EKSPERIMENTAL BAHOLASH

Ma'lumotlar to'plami

Eksperimentlar uchun O'zbekiston issiqlik elektr stantsiyalaridan to'plangan real sanoat ma'lumotlari qo'llanildi. Ma'lumotlar to'plami xususiyatlari 1-jadvalda keltirilgan:

1-jadval.

Ma'lumotlar to'plami xususiyatlari

Tizim	Sensor soni	Namunaviy hajm	Holat yorliqlari
Qozon tizimi	24	15,000	Normal/Nosoz
Turbina tizimi	18	12,500	Normal/Nosoz/Ogohlantirish
Generator tizimi	16	10,800	Normal/Nosoz
Yordamchi tizimlar	12	8,200	Normal/Ogohlantirish
Jami	70	46,500	—

Ma'lumotlar 70/15/15 nisbatida o'qitish, validatsiya va test to'plamlariga bo'lindi. Sintetik nosozliklar sanoat mutaxassislari bilan hamkorlikda 8 ta nosozlik turi (qozon bosimi oshishi, turbina tebranishi, generator termal anomaliyasi va boshq.) uchun simulyatsiya qilindi.

Tajriba sozlamalari

Barcha modellar PyTorch 2.0 (CUDA 11.8) muhitida, NVIDIA A100 40GB GPU va 128GB RAM tizimida o'qitildi. GNN modeli uchun: L = 4 qatlam, har qatlam 256 neyroni, dropout = 0.3. PPO uchun: klip parametri $\epsilon = 0.2$, 64 ta paralel muhit, 10 ta optimizatsiya epoxasi. SAC uchun: entropiya koeffitsienti $\alpha = 0.2$ avtomatik sozlash, bufer hajmi 10^6 , mini-partiya hajmi 256. O'qitish 500,000 ta qadam davom etdi, har 10,000 qadamda validatsiya baholandi.

Natijalar

Taklif qilingan GNN+MARL gibridi mavjud usullar bilan solishtirildi. 2-jadvalda barcha usullar bo'yicha aniqlik, to'liqlik (recall), F1-ko'rsatkichi va real vaqt kechikishi keltirilgan:

2-jadval.

Usullar solishtiruvi

Usul	Aniqlik	To'liqlik	F1-ko'rsatkich	Kechikish
LSTM	91.2%	88.7%	89.9%	12.3 ms
CNN-1D	89.5%	86.3%	87.8%	8.7 ms
Autoencoder	85.1%	83.4%	84.2%	15.1 ms
GNN (taklif)	96.8%	94.2%	95.5%	18.4 ms
GNN+MARL (taklif)	98.3%	96.7%	97.5%	22.6 ms

Natijalarda ko'rinib turibdiki, GNN+MARL gibridi barcha metrikalar bo'yicha ustunlik qiladi. Xususan, LSTM bilan solishtirganda F1-ko'rsatkichi 7.6% ga oshdi (89.9% → 97.5%). Aniqlik bo'yicha yaxshilanish 7.1% (91.2% → 98.3%) ni tashkil etdi. Real vaqt kechikishi 22.6 ms bo'lib, sanoat talablari (≤ 50 ms) chegarasida qoladi.

Qozon-turbina koordinatsiyasi bo'yicha Shapley koordinatsiyasi bilan va usiz solishtirish uchun ablatsiya tadqiqoti o'tkazildi. Shapley koordinatsiyasi bilan F1 97.5%, usiz esa 94.8% bo'ldi (+2.7%). Bu esa Shapley-asosli kredit belgilashning tizim darajasidagi aniqlikni oshirishdagi muhim rolini tasdiqlaydi.

Cheklovlar muhokamasi

Taklif qilingan tizim bir qator muhim cheklovlarga ega. Birinchidan, qisman kuzatuvlilik (partial observability) muammosi: barcha quyi tizimlardagi sensorlar to'liq va uzluksiz ma'lumot beradi deb faraz qilinadi, amalda esa sensor nosozliklari va aloqa uzilishlari yuzaga kelishi mumkin. Ikkinchidan, statsionar bo'lmagan muhit: sanoat jarayonlari mavsumiy o'zgarishlar va ish rejimlarining o'zgarishiga duchor bo'ladi, bu esa o'qitilgan modelning transfer qobiliyatini kamaytiradi. Uchinchidan, Shapley qiymatlari hisoblashda Monte-Karlo approksimatsiyasi aniqlik va hisoblash samaradorligi o'rtasida kompromis talab etadi.

Kelajak ishlarda ushbu cheklovlarni bartaraf etish uchun: (1) sensor shovqiniga bardoshli GNN arxitekturalarini (robust GNN) ishlab chiqish; (2) onlayn o'rganish (online learning) va domenlararo moslashtirish (domain adaptation) mexanizmlarini qo'shish; (3) tushuntiruvchi sun'iy intellekt (XAI) usullarini integratsiyalash maqsad qilinmoqda.

XULOSA

Ushbu maqolada sanoat texnik obyektlari uchun GNN, MARL, PPO/SAC va Shapley-asosli koordinatsiyani birlashtiruvchi integral nosozliklarni aniqlash va bashoratli texnik xizmat ko'rsatish tizimi taqdim etildi. Eksperimental natijalar taklif qilingan tizimning nosozliklarni aniqlash bo'yicha 98.3% aniqlik va 97.5% F1-ko'rsatkichiga erishganini ko'rsatdi, bu esa mavjud LSTM, CNN-1D va autoencoder-asosli usullardan sezilarli darajada ustun.

Tizimning asosiy ilmiy hissalarini quyidagilardan iborat: (1) sanoat topologiyasini real vaqt dinamik graflar sifatida modellashtiruvchi GNN arxitekturasi; (2) taqsimlangan nazorat uchun PPO va SAC algoritmlarini birlashtiruvchi ierarxik MARL strukturasi; (3) agentlararo adolatli kredit belgilashni ta'minlovchi Shapley-asosli koordinatsiya mexanizmi. Ushbu yondashuv real sanoat sharoitlariga, xususan O'zbekiston issiqlik elektr stantsiyalariga, joriy etish uchun amaliy asoslar yaratadi.

Kelajak yo'nalishlar: tizimni real sanoat ob'ektida sinab ko'rish, transfer o'rganish va tushuntiruvchi AI imkoniyatlarini integratsiyalash, shuningdek tizimni boshqa sanoat tarmoqlariga (neft-gaz sanoati, metallurgiya) moslashtirish.

ADABIYOTLAR

1. Zhang J. Rule-based fault detection limitations in complex industrial systems / J. Zhang, P. Wang, R. Yan // *IEEE Transactions on Industrial Informatics*. — 2022. — Vol. 18, № 4. — P. 2341–2352.
2. Hochreiter S. Long short-term memory / S. Hochreiter, J. Schmidhuber // *Neural Computation*. — 1997. — Vol. 9, № 8. — P. 1735–1780.
3. LeCun Y. Deep learning / Y. LeCun, Y. Bengio, G. Hinton // *Nature*. — 2015. — Vol. 521, № 7553. — P. 436–444.
4. Kingma D. P. Auto-encoding variational bayes / D. P. Kingma, M. Welling. — arXiv:1312.6114, 2013.

5. Zhang L. Sliding window-based fault detection from high-dimensional data streams / L. Zhang, J. Lin, R. Karim // *IEEE Transactions on Systems*. — 2019. — Vol. 49, № 3. — P. 723–737.
6. Jiang G. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox / G. Jiang, H. He, J. Yan // *IEEE Transactions on Industrial Electronics*. — 2019. — Vol. 66, № 4. — P. 3196–3207.
7. Lei Y. Applications of machine learning to machine fault diagnosis: a review and roadmap / Y. Lei, B. Yang, X. Jiang // *Mechanical Systems and Signal Processing*. — 2020. — Vol. 138. — Article 106587.
8. Hasan M. J. Acoustic spectral imaging and transfer learning for reliable bearing fault diagnosis under variable speed conditions / M. J. Hasan, M. M. M. Islam, J. M. Kim // *Measurement*. — 2019. — Vol. 138. — P. 620–631.
9. Scarselli F. The graph neural network model / F. Scarselli, M. Gori, A. C. Tsoi // *IEEE Transactions on Neural Networks*. — 2009. — Vol. 20, № 1. — P. 61–80.
10. Wu Z. A comprehensive study on graph neural networks / Z. Wu, S. Pan, F. Chen // *IEEE Transactions on Neural Networks and Learning Systems*. — 2020. — Vol. 32, № 1. — P. 4–24.
11. Zhou K. Fault diagnosis of hydraulic system based on graph neural network / K. Zhou, J. Tang, L. Deng // *Measurement*. — 2021. — Vol. 174. — Article 109074.
12. Li Y. Gated graph sequence neural networks for industrial fault diagnosis / Y. Li, J. Bilmes, D. Tarlow // *ICLR Workshop on Graph Representation Learning*. — 2020.
13. Busoniu L. A comprehensive survey of multiagent reinforcement learning / L. Busoniu, R. Babuska, B. De Schutter // *IEEE Transactions on Systems*. — 2008. — Vol. 38, № 2. — P. 156–172.
14. Schulman J. Proximal policy optimization algorithms / J. Schulman, F. Wolski, P. Dhariwal. — arXiv:1707.06347, 2017.
15. Haarnoja T. Soft actor-critic: off-policy maximum entropy deep reinforcement learning / T. Haarnoja, A. Zhou, P. Abbeel // *ICML*. — 2018. — P. 1861–1870.
16. Lowe R. Multi-agent actor-critic for mixed cooperative-competitive environments / R. Lowe, Y. Wu, A. Tamar // *NeurIPS*. — 2017. — P. 6379–6390.
17. Shapley L. S. A value for n-person games / L. S. Shapley // *Contributions to the Theory of Games*. — 1953. — Vol. 2, № 28. — P. 307–317.
18. Sunehag P. Value-decomposition networks for cooperative multi-agent learning / P. Sunehag, G. Lever, A. Grusl. — arXiv:1706.05296, 2018.