



Sun'iy intellekt va mashinali o'qitish asosida transport vositalari nosozliklarini diagnostika qilish va prognozlash: zamonaviy yondashuvlar sharhi

Kulmuradov Dilshod Istamovich

Jizzax politexnika institute dotsenti, DSc

proseralex@gmail.com

<https://orcid.org/0000-0002-0938-2434>

ANNOTATSIYA

Mazkur maqolada transport vositalarining texnik holatini nazorat qilish, nosozliklarni erta aniqlash va ularning yuzaga kelish ehtimolini prognozlashda sun'iy intellekt hamda mashinali o'qitish texnologiyalaridan foydalanishning zamonaviy yondashuvlari tahlil qilinadi. Transport vositalarining ekspluatatsion ishonchliligini oshirish, texnik xizmat ko'rsatish xarajatlarini kamaytirish va kutilmagan nosozliklarning oldini olishda ma'lumotlarga asoslangan diagnostika tizimlarining ahamiyati yoritiladi. Mashinali o'qitishning nazorat qilinadigan va nazoratsiz algoritmlari, neyron tarmoqlar, chuqur o'qitish, ansambl modellari hamda prediktiv texnik xizmat ko'rsatish usullarining qo'llanish xususiyatlari umumlashtiriladi. Shuningdek, CAN-bus, OBD, telematik tizimlar va turli sensorlardan olinadigan ekspluatatsion ma'lumotlarni qayta ishlash asosida nosozliklarni tasniflash va qoldiq resursni baholash imkoniyatlari ko'rib chiqiladi. Tahlil natijasida intellektual diagnostika tizimlarining afzalliklari, mavjud cheklovlari va kelgusidagi rivojlanish yo'nalishlari aniqlanadi.

Kalit so'zlar:

transport vositalari, sun'iy intellekt, mashinali o'qitish, texnik diagnostika, nosozliklarni aniqlash, nosozliklarni prognozlash, prediktiv texnik xizmat, ekspluatatsion ishonchlilik, CAN-bus, OBD, neyron tarmoqlar, qoldiq resurs.

Диагностика и прогнозирование неисправностей транспортных средств на основе искусственного интеллекта и машинного обучения: обзор современных ПОДХОДОВ

АННАТАЦИЯ

В статье представлен обзор современных подходов к применению технологий искусственного интеллекта и машинного обучения для контроля технического состояния, раннего выявления и прогнозирования неисправностей транспортных средств. Рассматривается значение интеллектуальных диагностических систем для повышения эксплуатационной надёжности автомобилей, снижения затрат на техническое обслуживание и предупреждения внезапных отказов. Обобщены особенности применения алгоритмов контролируемого и неконтролируемого машинного обучения, нейронных сетей, глубокого обучения, ансамблевых моделей и методов предиктивного технического обслуживания. Особое внимание уделяется обработке эксплуатационных данных, получаемых через

Ключевые слова:

транспортные средства, искусственный интеллект, машинное обучение, техническая диагностика, выявление неисправностей, прогнозирование неисправностей,



CAN-bus, OBD, телематические системы и различные датчики, с целью классификации неисправностей, оценки технического состояния и прогнозирования остаточного ресурса компонентов транспортных средств. По результатам анализа определены преимущества, существующие ограничения и перспективные направления развития интеллектуальных систем диагностики транспортных средств.

предиктивное техническое обслуживание, эксплуатационная надёжность, CAN-bus, OBD, нейронные сети, остаточный ресурс.

Artificial intelligence and machine learning-based diagnosis and prediction of vehicle failures: a review of modern approaches

ABSTRACT

This paper reviews modern approaches to the application of artificial intelligence and machine learning technologies for monitoring vehicle technical condition, early fault detection, and failure prediction. Particular attention is given to the role of intelligent diagnostic systems in improving vehicle operational reliability, reducing maintenance costs, and preventing unexpected failures. The review summarizes the application of supervised and unsupervised machine learning algorithms, neural networks, deep learning techniques, ensemble models, and predictive maintenance methods in vehicle diagnostics. The possibilities of processing operational data obtained from CAN-bus, OBD systems, telematics platforms, and various onboard sensors for fault classification, technical condition assessment, and remaining useful life estimation are also examined. Based on the reviewed approaches, the main advantages and current limitations of artificial intelligence-driven vehicle diagnostics are identified, and promising directions for further development of intelligent fault diagnosis and prognostics systems in vehicle operation are outlined

Keywords:

vehicles, artificial intelligence, machine learning, technical diagnostics, fault detection, failure prediction, predictive maintenance, operational reliability, CAN-bus, OBD, neural networks, remaining useful life.

KIRISH

Zamonaviy transport vositalarining konstruksiyasi yildan-yilga murakkablashib, ularning ishlashi ko'plab mexanik, elektron va dasturiy tizimlarning o'zaro bog'liq faoliyatiga asoslanmoqda. Dvigatel, transmissiya, tormoz tizimi, rul boshqaruvi, osma, elektr jihozlari va elektron boshqaruv bloklarining barqaror ishlashi transport vositasining xavfsizligi, ishonchliligi hamda ekspluatatsion samaradorligini bevosita belgilaydi. Bunday sharoitda nosozlikni faqat u yuzaga kelganidan keyin aniqlashga asoslangan an'anaviy texnik xizmat ko'rsatish yondashuvlari har doim ham yetarli samara bermaydi. Chunki ayrim buzilishlar dastlab aniq tashqi belgilar bilan namoyon bo'lmasdan, vaqt o'tishi bilan agregat yoki tizimning jiddiy ishdan chiqishiga olib kelishi mumkin.

Transport vositalaridan foydalanish intensivligining ortishi hamda ularning texnik tuzilmasida elektron komponentlar ulushining ko'payishi diagnostika jarayoniga yangi talablarni qo'ymoqda. Endilikda texnik holatni baholashda faqat mexanik o'lchovlar bilan cheklanib qolmasdan, transport vositasining o'zidan olinadigan katta hajmdagi ekspluatatsion ma'lumotlardan ham foydalanish imkoniyati mavjud. Bort diagnostika tizimlari, elektron boshqaruv bloklari, CAN-bus tarmog'i, telematik qurilmalar va turli sensorlar dvigatel aylanish tezligi, harorat, bosim, yonilg'i sarfi, vibratsiya, kuchlanish, tezlik, yuklanish va boshqa ko'plab parametrlarni uzluksiz qayd etadi. Mazkur ma'lumotlarni to'g'ri tahlil qilish transport vositasining texnik holatini ancha chuqurroq baholash imkonini beradi.



Shu nuqtai nazardan, sun'iy intellekt va mashinali o'qitish texnologiyalarining transport vositalari diagnostikasiga kirib kelishi muhim ilmiy-amaliy yo'nalishlardan biriga aylandi. Mashinali o'qitish algoritmlari katta hajmdagi ma'lumotlar orasidan inson tomonidan bevosita aniqlanishi qiyin bo'lgan bog'liqliklar va yashirin qonuniyatlarni topish imkonini beradi. Natijada nosozliklarni dastlabki bosqichda aniqlash, ularning rivojlanish tendensiyasini baholash, ma'lum detal yoki agregatning ishdan chiqish ehtimolini oldindan prognozlash hamda qoldiq resursini aniqlash imkoniyatlari kengaymoqda.

Transport vositalarining texnik diagnostikasida sun'iy intellektidan foydalanish faqat nosozlik mavjud yoki mavjud emasligini aniqlash bilan chegaralanmaydi. Zamonaviy intellektual tizimlar nosozlik turini tasniflash, uning kelib chiqish sabablarini aniqlash, texnik holatdagi o'zgarishlarni kuzatish va keyingi texnik xizmat ko'rsatish muddatini belgilashda ham qo'llanilmoqda. Ayniqsa, neyron tarmoqlar, qaror daraxtlari, tayanch vektorlar usuli, ansambl algoritmlari va chuqur o'qitish modellarining rivojlanishi transport vositalari ekspluatatsiyasi jarayonida to'planadigan murakkab va ko'p o'lchovli ma'lumotlarni qayta ishlash samaradorligini oshirdi.

Mazkur texnologiyalarning yana bir muhim jihati prediktiv texnik xizmat ko'rsatish tizimini shakllantirish imkoniyati bilan bog'liq. An'anaviy texnik xizmat ko'rsatishda ishlar odatda belgilangan masofa yoki vaqt oralig'idan kelib chiqib amalga oshiriladi. Bunda ayrim detallar hali yetarli ish resursiga ega bo'lishiga qaramay almashtirilishi, boshqa hollarda esa nosozlik belgilangan xizmat muddatidan oldin yuzaga kelishi mumkin. Prediktiv yondashuvda esa real ekspluatatsion ma'lumotlar asosida har bir agregatning amaldagi texnik holati baholanadi va texnik xizmat yoki ta'mirlash zarurati individual ravishda prognoz qilinadi. Bu esa texnik xizmat ko'rsatish xarajatlarini kamaytirish, transport vositasining bekor turish vaqtini qisqartirish va ekspluatatsion ishonchlilikni oshirishga xizmat qiladi.

Biroq sun'iy intellekt va mashinali o'qitish asosidagi diagnostika tizimlaridan amaliy foydalanish bir qator murakkab masalalarni ham yuzaga keltirmoqda. Jumladan, ma'lumotlarning yetarli hajmda va sifatli to'planishi, turli transport vositalaridan olingan parametrlarning bir xil bo'lmasligi, nosozlik holatlari bo'yicha ishonchli ma'lumotlar bazasining cheklanganligi, algoritmlarning yangi ekspluatatsiya sharoitlariga moslashuvi hamda olingan natijalarni texnik jihatdan izohlash masalalari hali to'liq hal etilmagan. Shu sababli mavjud yondashuvlarni bir-biri bilan qiyoslash, ularning afzallik va cheklovlarini aniqlash hamda transport vositalari ekspluatatsiyasi uchun eng istiqbolli yechimlarni belgilash muhim ilmiy vazifa hisoblanadi.

Mazkur tadqiqotning maqsadi transport vositalari nosozliklarini diagnostika qilish va prognozlashda sun'iy intellekt hamda mashinali o'qitish texnologiyalaridan foydalanishga bag'ishlangan zamonaviy ilmiy yondashuvlarni tizimli ravishda tahlil qilish, ularning qo'llanish xususiyatlarini umumlashtirish, mavjud muammolarni aniqlash va keyingi tadqiqotlar uchun istiqbolli yo'nalishlarni belgilashdan iborat. Ushbu sharh natijalari transport vositalarining texnik holatini baholash, nosozliklarning oldini olish va ekspluatatsion ishonchlilikini oshirishga qaratilgan intellektual diagnostika tizimlarini yanada takomillashtirish uchun nazariy asos bo'lib xizmat qilishi mumkin.

MAVZUGA OID ADABIYOTLAR TAHLILI

Transport vositalarining texnik holatini diagnostika qilish va nosozliklarni oldindan prognozlash masalasi ilmiy adabiyotlarda dastlab holatga asoslangan texnik xizmat ko'rsatish — *condition-based maintenance* konsepsiyasi doirasida rivojlangan. A.K.S. Jardine, D. Lin va D. Banjevic tomonidan olib borilgan fundamental tahlilda holatga asoslangan texnik xizmat ko'rsatish uchta o'zaro bog'liq bosqich — ma'lumotlarni yig'ish, ularni qayta ishlash va texnik xizmat bo'yicha qaror qabul qilish jarayonlaridan iborat ekanligi ko'rsatilgan. Mualliflar diagnostikani mavjud nosozlikni aniqlash, lokalizatsiya qilish va uning xususiyatini belgilash bilan, prognostikani esa nosozlik yuzaga kelishidan oldin uning ehtimoli va vaqtini baholash bilan bog'laydi [1]. Mazkur yondashuv keyinchalik transport vositalarida prediktiv texnik xizmat ko'rsatish tizimlarini yaratish uchun nazariy asoslardan biriga aylandi.



Sun'iy intellekt texnologiyalarining rivojlanishi diagnostikada qo'llaniladigan usullar tarkibini sezilarli darajada kengaytirdi. R. Zhao va hammualliflar mashinalarning texnik holatini monitoring qilishda chuqur o'qitish usullarining qo'llanilishini tahlil qilib, bunday modellar murakkab sensor signallaridan diagnostik belgilarni avtomatik ajratib olish imkoniyatiga ega ekanligini ko'rsatgan [2]. Y. Lei va hammualliflar esa mashinali o'qitishga asoslangan nosozliklar diagnostikasining rivojlanishini an'anaviy mashinali o'qitish, chuqur o'qitish va bilimlarni yangi ish sharoitlariga ko'chirish imkonini beruvchi transfer learning yo'nalishlari bilan bog'laydi [3]. Bu tadqiqotlar transport vositalarida ham diagnostik belgilarni qo'lda tanlashdan ma'lumotlar asosida avtomatik shakllantirishga o'tishning metodologik asosini tushuntirib beradi.

Avtomobil transportiga bevosita bag'ishlangan eng muhim sharhlardan biri A. Theissler, J. Pérez-Velázquez, M. Kettelgerdes va G. Elger tomonidan amalga oshirilgan. Mualliflar avtomobil tizimlarida mashinali o'qitishga asoslangan prediktiv texnik xizmat ko'rsatish bo'yicha adabiyotlarni tizimli ravishda o'rganib, yakuniy tahlilga 62 ta ilmiy ishni kiritgan [4]. Tadqiqot natijalariga ko'ra, avtomobil diagnostikasida sun'iy neyron tarmoqlar, tayanch vektorlar usuli, tasniflash, regressiya va anomalialarni aniqlash algoritmlari faol qo'llaniladi. Shu bilan birga, mualliflar ochiq va sifatli avtomobil nosozliklari ma'lumotlar bazalarining yetishmasligi, ko'pchilik tadqiqotlarning belgilangan ma'lumotlarni talab qiluvchi nazorat qilinadigan o'qitishga tayanishi hamda chuqur o'qitish modellarining interpretatsiyasi murakkabligini asosiy muammolar sifatida ko'rsatgan. Turli sensor va ekspluatatsion ma'lumotlarni birlashtirish esa diagnostika aniqligini oshirishi mumkinligi qayd etilgan [4].

M. Jain, D. Vasdev, K. Pal va V. Sharma transport vositalarining texnik holatini mashinali o'qitish yordamida baholash va prediktiv texnik xizmat ko'rsatishga bag'ishlangan tizimli adabiyotlar sharhida OBD tizimlari orqali olinadigan ma'lumotlarning alohida ahamiyatini ta'kidlaydi [5]. Mualliflar avtomobil sanoatida nosozlikni oldindan aniqlash imkoniyatlari kengayayotgan bo'lsa-da, ayrim parametrlarni o'lchash uchun sensorlarning mavjud emasligi, real nosozliklar bo'yicha ma'lumotlar hajmining cheklanganligi va diagnostik modellarni turli transport vositalariga moslashtirish zarurati amaliy muammo bo'lib qolayotganini ko'rsatadi. Shuning uchun transport diagnostikasida algoritmnining o'zi bilan bir qatorda, kiruvchi ma'lumotlarning sifati, diagnostik parametrlarning to'g'ri tanlanishi va modelni real ekspluatatsiya sharoitida tekshirish ham muhim hisoblanadi [5].

U. Shafi va hammualliflarning tadqiqoti avtomobilning real ekspluatatsion ma'lumotlarini mashinali o'qitish bilan birlashtirish bo'yicha amaliy ishlardan biri hisoblanadi [6]. Tadqiqotda Toyota Corolla avtomobillarining yonilg'i ta'minoti, o't oldirish, chiqarish va sovitish tizimlari bo'yicha ma'lumotlar OBD-II vositalari yordamida yig'ilgan. Qaror daraxti (*Decision Tree*), tayanch vektorlar mashinasi (*Support Vector Machine*), k-eng yaqin qo'shnilar (*k-NN*) va *Random Forest* algoritmlari nosozliklarni aniqlash uchun qo'llanilgan. Model jami 70 ta transport vositasidan olingan ma'lumotlar asosida baholangan [6]. Ushbu tadqiqot OBD ma'lumotlari asosida avtomobilning texnik holatini masofadan monitoring qilish va nosozlikni oldindan baholash mumkinligini amaliy jihatdan ko'rsatgan. Shu bilan birga, ma'lumotlarning bitta avtomobil modeli bilan cheklanganligi bunday algoritmlarning boshqa rusum va ekspluatatsiya sharoitlariga ko'chirilishini alohida tekshirish zarurligini anglatadi.

Avtomobil dvigatellaridagi nosozliklarni aniqlash bilan bir qatorda, ularni nosozlik sodir bo'lishidan oldin aniqlash masalasi ham alohida tadqiqot yo'nalishiga aylangan. X. Li, N. Wang, Y. Lyu, Y. Duan va J. Zhao avtomobil dvigateli uchun ma'lumotlarga asoslangan erta ogohlantirish modelini ishlab chiqib, bir nechta mashinali o'qitish algoritmlarini ansambl shaklida birlashtirgan [7]. Tadqiqotda dvigatelning normal va nosoz holatlari ko'p o'lchovli belgilar fazosida ifodalanib, model chiqishidagi ehtimollik ko'rsatkichlaridan nosozlik rivojlanishini oldindan baholash uchun foydalanilgan. Mualliflarning yondashuvi diagnostikadan prognostikaga o'tishda faqat nosozlik sinfini aniqlash emas, balki parametrlarning vaqt davomida o'zgarishini kuzatish ham zarurligini ko'rsatadi.



M. Cervantes-Bobadilla va hammualliflar ichki yonuv dvigatelida bir vaqtning o'zida yuz beradigan sensor nosozliklarini aniqlash va ajratish masalasini sun'iy neyron tarmoqlar yordamida tadqiq qilgan [8]. Ishda MAF, MAP va TPS kabi o'zaro bog'liq sensorlarning signallarini baholash uchun neyron tarmoqlar bankidan foydalanilgan. Bunday yondashuvning ahamiyati shundaki, zamonaviy avtomobilda bitta sensor yoki komponentdagi nosozlik boshqa parametrlarning ham o'zgarishiga olib kelishi mumkin. Natijada oddiy chegaraviy qiymatlarga asoslangan diagnostika haqiqiy nosozlik manbasini noto'g'ri aniqlashi ehtimoli mavjud. Neyron tarmoqlar esa ko'p parametrlar bog'lanishlarni hisobga olish orqali individual va birgalikda yuz beruvchi nosozliklarni farqlash imkoniyatini kengaytiradi [8].

Keyingi tadqiqotlarda an'anaviy mashinali o'qitish algoritmlaridan murakkab gibrid chuqur o'qitish modellariga o'tish kuzatilmoqda. M.A. Rahim va hammualliflar transport vositasi dvigatelining texnik holatini baholash uchun CNN va BiGRU arxitekturalarini birlashtirgan gibrid modelni taklif qilgan [9]. Ushbu model sensorlardan olinadigan ma'lumotlar hamda dvigatel komponentlarining zaiflik ko'rsatkichlarini birgalikda qayta ishlab, dvigatel holatini bir nechta darajaga tasniflagan. Mualliflar ishlab chiqqan Deep CNN-BiGRU modeli sinovlarda 0,8897 aniqlik ko'rsatkichiga erishgan. Tadqiqot natijalari vaqt qatorlaridagi bog'lanishlarni o'rganish va turli diagnostik belgilarni birlashtirishda gibrid chuqur o'qitish modellarining imkoniyati yuqori ekanligini ko'rsatadi [9].

Elektr transport vositalarining ommalashishi bilan nosozliklarni prognozlash tushunchasi yangi komponentlarga, ayniqsa tortish akkumulyatorlariga nisbatan ham qo'llanila boshladi. H. Rauf, M. Khalid va N. Arshad mashinali o'qitish asosida lity-ion akkumulyatorlarning *State of Health* (SOH) va *Remaining Useful Life* (RUL) ko'rsatkichlarini baholash usullarini keng tahlil qilgan [10]. Mualliflar batareya degradatsiyasining noxiziq xarakteri sababli an'anaviy deterministik modellarning imkoniyatlari cheklanishi mumkinligini, ma'lumotlarga asoslangan modellar esa kuchlanish, tok, harorat, zaryadlash sikllari va boshqa parametrlar orasidagi murakkab bog'lanishlarni o'rganish imkonini berishini ko'rsatadi. Biroq modelning aniqligi ekspluatatsiya rejimi, tashqi harorat va ma'lumotlar bazasining reprezentativligiga kuchli bog'liq bo'lib qoladi [10].

A.P. Renold va N.S. Kathayat elektr transport vositalari batareyalarining texnik holatini prognozlashda mashinali o'qitish, chuqur o'qitish va raqamli egizak texnologiyalarini birgalikda tahlil qilgan [11]. Ularning tadqiqotida SOH prognozining ishonchliligi uchun ma'lumotlar sifati va mavjudligi, modelni verifikatsiya va validatsiya qilish, shuningdek, modelning yangi sharoitlarga umumlashish qobiliyati muhim ekanligi qayd etiladi. Raqamli egizak yondashuvi real transport vositasidan olinadigan ma'lumotlarni uning virtual modeli bilan bog'lash orqali texnik holatni uzluksiz kuzatish va kelajakdagi degradatsiyani baholash uchun istiqbolli yo'nalish sifatida ko'rilmogda [11].

So'nggi tadqiqotlarda belgilangan nosozlik ma'lumotlariga yuqori darajadagi qaramlikni kamaytirishga ham e'tibor kuchaygan. Z. Lv, S. Ou, H. Jing, G. Wu va D. Shi 2026-yilda e'lon qilgan tadqiqotida elektr transport vositalari akkumulyatorlarining qoldiq resursini real ekspluatatsiya ma'lumotlari asosida prognozlash uchun self-supervised VAE-LSTM modelini taklif qilgan [12]. Model laboratoriya ma'lumotlari bilan emas, real ekspluatatsiyadagi turli avtomobil parklaridan olingan ma'lumotlar bilan baholangan. Tadqiqotda belgilangan ma'lumotlar yetarli bo'lmagan sharoitda ham dastlab belgisiz ma'lumotlardan foydali degradatsiya belgilarini o'rganish mumkinligi ko'rsatilgan. Bu natija avtomobil diagnostikasining kelgusi rivojlanishida *self-supervised learning* va turli transport parklariga bilimni ko'chirish usullari muhim o'rin egallashini ko'rsatadi [12].

M.N. Hossain, M.M. Rahman va D. Ramasamy tomonidan 2025-yilda e'lon qilingan zamonaviy sharhda transport vositalari texnik holatini intellektual monitoring qilish usullari modelga asoslangan, signalga asoslangan va ma'lumotlarga asoslangan yondashuvlar bo'yicha tizimlashtirilgan [13]. Mualliflar an'anaviy avtomobillar, elektromobillar va avtonom transport vositalari uchun ishlab chiqilgan ko'plab yechimlarga qaramay, turli sensorlar, IoT vositalari, sun'iy



intellekt va ko'p sensorli ma'lumotlarni birlashtirishni yagona tizimga integratsiya qilish masalasi to'liq hal etilmaganini ko'rsatadi. Ayniqsa, diagnostik modelning masshtablanuvchanligi, yangi transport vositasiga moslashishi va real vaqt rejimida ishlash samaradorligi dolzarb masalalar sifatida saqlanib qolmoqda [13].

Y. Mahale, S. Kolhar va A.S. More tomonidan 2025-yilda Scopus va Web of Science bazalaridan tanlangan 94 ta ilmiy ish asosida bajarilgan sharh ham ushbu xulosalarni tasdiqlaydi [14]. Mualliflar zamonaviy transport vositalarida mashinali o'qitish va chuqur o'qitish bilan bir qatorda tushuntiriladigan sun'iy intellekt - *Explainable AI* vositalarining ahamiyati ortayotganini qayd etadi. Chunki texnik xizmat ko'rsatish bo'yicha qaror qabul qilayotgan mutaxassis uchun algoritm faqat "nosozlik mavjud" degan xulosani berishi emas, balki ushbu natijaga qaysi parametrlar va qanday o'zgarishlar sabab bo'lganini tushuntirib bera olishi ham muhimdir [14].

Ko'rib chiqilgan ilmiy manbalar tahlili transport vositalari nosozliklarini intellektual diagnostika qilish sohasida uchta asosiy rivojlanish bosqichini ajratish imkonini beradi: diagnostik belgilarni oldindan belgilashga asoslangan klassik mashinali o'qitish; sensor ma'lumotlaridan belgilarni avtomatik ajratadigan chuqur o'qitish; hamda real ekspluatatsiya sharoitlari o'zgarishiga moslasha oladigan transfer, self-supervised va gibrid modellar. Shu bilan birga, mavjud tadqiqotlarning katta qismi alohida agregat yoki tizimga - dvigatel, sensor, akkumulyator yoki boshqa komponentga qaratilgan. Turli rusumdagi transport vositalari, iqlim va yo'l sharoitlari, haydash rejimlari hamda turlicha texnik holatdagi avtomobillar uchun bir xil darajada ishonchli ishlaydigan universal diagnostik model masalasi hali to'liq yechilmagan.

Shunday qilib, mavjud adabiyotlarda yuqori diagnostik aniqlikka erishishga qaratilgan ko'plab algoritmlar taklif etilgan bo'lsa-da, ularni bevosita real ekspluatatsiya sharoitiga tatbiq etishda ma'lumotlar yetishmasligi, nosozlik sinflarining nomutanosibligi, turli avtomobil platformalaridagi parametrlar farqi, modelning yangi ish rejimlariga moslashuvi va natijalarning interpretatsiyasi bilan bog'liq muammolar saqlanib qolmoqda [4,5,11,13,14]. Shu sababli transport vositalari nosozliklarini sun'iy intellekt va mashinali o'qitish asosida diagnostika qilish hamda prognozlashga oid zamonaviy yondashuvlarni ma'lumot manbai, diagnostika vazifasi, qo'llaniladigan algoritm, transport vositasining diagnostika qilinadigan tizimi va amaliy qo'llash imkoniyatlari bo'yicha kompleks ravishda qiyoslash zarur. Mazkur holat ushbu tadqiqotning asosiy ilmiy yo'nalishini belgilaydi.

TADQIQOT METODOLOGIYASI

Mazkur tadqiqotda **tizimli adabiyotlar tahlili va tematik tasniflash metodi** qo'llanildi. Ushbu metod transport vositalari nosozliklarini sun'iy intellekt va mashinali o'qitish asosida diagnostika qilish hamda prognozlashga oid ilmiy tadqiqotlarni izchil tanlash, guruhlash va o'zaro taqqoslash imkonini beradi.

Tahlil uchun, asosan, Scopus va Web of Science bazalarida indekslangan xalqaro ilmiy jurnallarda chop etilgan tadqiqotlar tanlandi. Manbalarni qidirishda "vehicle fault diagnosis", "vehicle fault prediction", "artificial intelligence in vehicle diagnostics", "machine learning for vehicle maintenance", "predictive maintenance", "OBD-II diagnostics", "CAN-bus fault diagnosis", "deep learning vehicle diagnostics" va "remaining useful life prediction" kabi kalit so'zlardan foydalanildi. Tadqiqot mavzusiga bevosita aloqador, metodologiyasi aniq bayon etilgan hamda transport vositalari, ularning agregat va tizimlari texnik holatini baholashga qaratilgan ilmiy ishlar asosiy tanlov mezonlari sifatida qabul qilindi.

Tanlangan manbalar mazmuniga ko'ra bir necha tematik yo'nalishga ajratildi: klassik mashinali o'qitish algoritmlariga asoslangan diagnostika; sun'iy neyron tarmoqlar va chuqur o'qitish modellari; OBD-II, CAN-bus va sensor ma'lumotlariga asoslangan texnik holat monitoringi; prediktiv texnik xizmat ko'rsatish; qoldiq resursni prognozlash; elektromobillar akkumulyatorlarining SOH va RUL ko'rsatkichlarini baholash; shuningdek, transfer learning, self-supervised learning va Explainable AI kabi zamonaviy yondashuvlar.

Har bir ilmiy manba diagnostika qilinayotgan obyekt, foydalanilgan ma'lumotlar turi, qo'llanilgan algoritm, aniqlanadigan nosozlik turi, modelning baholash mezonlari, olingan natijalar



hamda amaliy cheklovlar bo'yicha qiyosiy tahlil qilindi. Bunday yondashuv turli algoritmlarning afzallik va kamchiliklarini bir xil mezonlar asosida baholashga imkon berdi.

Tahlil jarayonida transport vositalarining real ekspluatatsiya sharoitida ishlashiga alohida e'tibor qaratildi. Shu sababli laboratoriya sharoitida yuqori aniqlik ko'rsatgan modellar bilan real avtomobil ma'lumotlari asosida sinovdan o'tkazilgan yondashuvlar o'rtasidagi farqlar ham hisobga olindi. Shuningdek, ma'lumotlar hajmi va sifati, nosozlik sinflarining muvozanati, modelning boshqa transport vositalariga moslashuvchanligi, hisoblash murakkabligi va natijalarni texnik jihatdan izohlash imkoniyati asosiy baholash mezonlari sifatida belgilandi.

Mazkur metodologik yondashuv asosida mavjud tadqiqotlar tizimlashtirildi, sun'iy intellekt va mashinali o'qitishga asoslangan transport vositalari diagnostikasining rivojlanish tendensiyalari aniqlandi hamda amaliyotda qo'llash uchun istiqbolli yo'nalishlar belgilandi.

TAHLIL VA NATIJALAR

Tizimli adabiyotlar tahlili transport vositalari nosozliklarini diagnostika qilish va prognozlashda qo'llanilayotgan sun'iy intellekt algoritmlarining samaradorligi faqat model turiga emas, balki kiruvchi ma'lumotlarning xususiyati, diagnostika qilinayotgan agregat, kuzatuv davomiyligi va hal qilinayotgan vazifaga ham bog'liqligini ko'rsatdi. Shu sababli Random Forest, SVM, ANN, CNN, LSTM, CNN-BiGRU va self-supervised learning modellarini yagona "eng yaxshi algoritim" mezoni asosida baholash ilmiy jihatdan to'g'ri emas. Ularning har biri transport vositasidan olinadigan ma'lumotlarning muayyan turi va diagnostik vazifa uchun o'z ustunligiga ega.

1-jadval. Transport vositalari diagnostikasida qo'llaniladigan sun'iy intellekt va mashinali o'qitish algoritmlarining qiyosiy tavsifi

Algoritim	Asosiy ma'lumot turi	Diagnostikadagi asosiy vazifasi	Kuchli tomonlari	Asosiy cheklovlari	Transport vositalarida maqbul qo'llanish sohasi
Random Forest (RF)	OBD-II, DTC, sensor va ekspluatatsion parametrlar	Nosozliklarni tasniflash, texnik holatni baholash	Nochiziqli bog'lanishlarni aniqlaydi; ko'p belgili ma'lumotlar bilan ishlaydi; ortiqcha moslashishga nisbatan alohida qaror daraxtidan barqarorroq; belgilar ahamiyatini baholash mumkin	Vaqt bo'yicha ketma-ket bog'lanishlarni bevosita modellashtirmaydi; juda murakkab vaqt qatorlarida qo'shimcha xususiyat ajratish talab etiladi	Dvigatel, yonilg'i, sovitish va chiqarish tizimlaridagi nosozliklarni klassifikatsiya qilish
Support Vector Machine (SVM)	OBD-II, DTC, vibratsiya, bosim va boshqa ajratilgan	Normal va nosoz holatlarni ajratish, nosozlik turini tasniflash	Nisbatan kichik va o'rta hajmdagi ma'lumotlarda samarali; kernel	Katta ma'lumotlar bazasida hisoblash yuklamasi ortadi; parametr va kernel tanlash	Sensor nosozliklari, dvigatelning ish rejimlari va aniq nosozlik



	diagnostik belgilar		funksiyalari yordamida nochiziqli chegaralarni aniqlaydi	natijaga sezilarli ta'sir qiladi	sinflarini aniqlash
ANN / MLP	Ko'p o'lchovli sensor signallari, bosim, vibratsiya, akustik va ekspluatatsion ma'lumotlar	Murakkab nochiziqli bog'lanishlarni aniqlash va tasniflash	Bir nechta parametr o'rtasidagi yashirin bog'liqliklarni o'rganadi; ko'p sensorli diagnostikaga mos	Yetarli o'quv ma'lumotlarini talab qiladi; ortiqcha moslashish xavfi mavjud; qarorlarning izohlanishi chegaralangan	Dvigatel sensorlari, yonish jarayoni, misfire, mexanik va akustik nosozliklar diagnostikasi
CNN	Vibratsiya, akustik signal, vaqt-chastota tasvirlari va ko'p kanalli sensor ma'lumotlari	Diagnostik belgilarni avtomatik ajratish va nosozlikni klassifikatsiya qilish	Belgilarni qo'lda shakllantirish ehtiyojini kamaytiradi; lokal va murakkab signal xususiyatlarini yaxshi aniqlaydi	Katta o'quv to'plami va yuqoriroq hisoblash resursini talab qilishi mumkin; mustaqil CNN uzoq vaqtli bog'lanishlarni to'liq aks ettirmasligi mumkin	Dvigatel vibratsiyasi, misfire, podshipnik, transmissiya va akustik nosozliklarni aniqlash
LSTM	Ketma-ket vaqt qatorlari, sensor monitoringi, degradatsiya ma'lumotlari	Nosozlik rivojlanishini va qoldiq resursni prognozlash	Uzoq muddatli vaqt bog'lanishlarini o'rganadi; degradatsiya tendensiyasini hisobga oladi	O'qitish nisbatan murakkab; ma'lumotlar ketma-ketligi va sifati muhim; oddiy klassifikatsiya uchun ortiqcha murakkab bo'lishi mumkin	RUL, akkumulyator SOH, agregat degradatsiyasi va vaqt bo'yicha nosozlik rivojlanishini prognozlash
CNN-BiGRU	Ko'p o'lchovli sensor va vaqt qatori ma'lumotlari	Belgilarni avtomatik ajratish va vaqt bog'lanishlarini birgalikda tahlil qilish	CNN lokal xususiyatlarni, BiGRU esa ketma-ketlikdagi bog'lanishlarini o'rganadi; murakkab dvigatel holatlarini tasniflashga mos	Model tuzilishi murakkabroq; hisoblash resurslariga talab yuqori; real vaqt tizimiga joriy etishda modelni optimallashtirish talab qilinadi	Dvigatel holatini kompleks monitoring qilish va bir nechta texnik holat darajasiga ajratish
Self-supervis	Katta hajmdagi	Belgilarni mustaqil	Belgilangan nosozlik	Oldindan o'qitish	Elektromobil akkumulyatorl



ed learning	belgilarsiz real ekspluatatsiya ma'lumotlar	o'rganish, RUL va degradatsiyani prognozlash	ma'lumotlari ga bo'lgan talabni kamaytiradi; katta transport parklaridagi belgisiz ma'lumotlardan foydalanish imkonini beradi; boshqa park yoki sharoitga moslashish salohiyati yuqori	murakkab; representatsiyani ng fizik ma'nosini tekshirish zarur; real diagnostika uchun keyingi moslashtirish talab etiladi	ari RUL prognozi, park miqyosidagi prediktiv diagnostika va kam belgilangan ma'lumotli vazifalar
-------------	---	--	--	---	--

Klassik mashinali o'qitish algoritmlari orasida SVM va Random Forest transport vositalarining strukturaviy yoki jadval ko'rinishidagi diagnostik ma'lumotlari uchun amaliy jihatdan qulay algoritmlar hisoblanadi. Shafi va hammualliflar OBD-II orqali olingan ma'lumotlardan foydalanib, Toyota Corolla avtomobillarining o't oldirish, yonilg'i ta'minoti, chiqarish va sovitish tizimlarida Decision Tree, SVM, k-NN va Random Forest algoritmlarini qiyoslagan [6]. Tadqiqotda aynan shu ma'lumotlar to'plamida SVM ayrim tizimlar uchun yuqori klassifikatsiya natijalarini ko'rsatgan. Masalan, o't oldirish tizimida 96,6 %, yonilg'i tizimida esa 98 % dan yuqori aniqlik qayd etilgan [6]. Biroq ushbu natijalar 70 ta bir xil modeldagi Toyota Corolla avtomobillaridan to'plangan ma'lumotlarga asoslanganligi sababli, ularni barcha transport vositalari uchun universal ko'rsatkich sifatida qabul qilish mumkin emas. Bu holat mashinali o'qitish modellarini baholashda test ma'lumotlarining tarkibi va transport vositalarining xilma-xilligini hisobga olish zarurligini ko'rsatadi.

Random Forest algoritmining muhim xususiyati bir nechta qaror daraxtlarining natijalarini birlashtirish orqali tasniflash barqarorligini oshirishidir. Transport diagnostikasida bu usul ko'p sonli sensor parametrlarini bir vaqtda tahlil qilish, ularning nosozlikka ta'sir darajasini aniqlash va murakkab noxiziq bog'lanishlarni ajratish uchun qulay. Biroq RF vaqt bo'yicha ketma-ketlikni o'z modelida tabiiy ravishda hisobga olmaydi. Shu sababli dvigatel harorati, vibratsiya yoki akkumulyator degradatsiyasi kabi vaqt davomida rivojlanadigan jarayonlarni prognozlashda RFga oldindan hisoblangan statistik yoki temporal belgilarni kiritish talab qilinishi mumkin. Zamonaviy avtomobil diagnostikasi sharhlarida ham RF ko'p o'lovli ma'lumotlarni qayta ishlashda foydali klassik algoritmlardan biri sifatida qayd etilgan [14].

Sun'iy neyron tarmoqlar transport vositasining turli parametrlaridagi murakkab noxiziq munosabatlarni modellashtirish imkoniyati bilan ajralib turadi. Cervantes-Bobadilla va hammualliflar ichki yonuv dvigatelining bir nechta o'zaro bog'liq sensorlarida yuzaga keladigan nosozliklarni ANN asosida aniqlash va ajratish mumkinligini ko'rsatgan [8]. Bunday yondashuv ayniqsa bir sensorning xatosi boshqa parametrlarning ham o'zgarishiga sabab bo'ladigan holatlarda muhimdir. Oddiy chegaraviy diagnostikada bir nechta signal bir vaqtda me'yordan chiqishi bir nechta nosozlik mavjud degan noto'g'ri xulosaga olib kelishi mumkin. ANN esa parametrlar o'rtasidagi o'zaro bog'liqlikni o'rganish orqali nosozlikning haqiqiy manbasini ajratishga yordam beradi. Avtomobil dvigatellarida neyron tarmoqlardan sensor nosozligi, misfire, akustik va bosim signallari asosidagi diagnostikada foydalanilganligi ilmiy tadqiqotlarda tasdiqlangan.



Chuqur o'qitish usullarining rivojlanishi bilan diagnostik belgilarni oldindan qo'lda tanlashga bo'lgan ehtiyoj kamaymoqda. CNN modellarining asosiy ustunligi vibratsiya, akustik signal yoki vaqt–chastota tasviri kabi murakkab ma'lumotlardan nosozlikka xos belgilarni avtomatik ajratishidir. Shu sababli CNN dvigateldagi yonish buzilishi, misfire, transmissiya va boshqa mexanik komponentlarning signalga asoslangan diagnostikasida istiqbolli hisoblanadi. Biroq CNNning o'zi asosan lokal xususiyatlarni aniqlashga kuchli bo'lib, uzoq vaqt davomida shakllanadigan degradatsiya jarayonlarini aks ettirish uchun ketma-ketlikni tahlil qiluvchi model bilan birlashtirilishi maqsadga muvofiq [3,14].

LSTM algoritmi ushbu kamchilikni vaqt qatorlaridagi uzoq muddatli bog'lanishlarni o'rganish orqali qisman bartaraf etadi. Transport vositasining texnik holati ko'pincha bitta vaqt nuqtasidagi parametr bilan emas, balki uning ma'lum davr davomida qanday o'zgargani bilan aniqlanadi. Masalan, akkumulyator sig'imining pasayishi, haroratning davriy ortishi, vibratsiya amplitudasining asta-sekin kuchayishi yoki bosim qiymatining uzoq muddatli siljishi agregat degradatsiyasining muhim belgisi bo'lishi mumkin. LSTM shunday temporal bog'lanishlarni o'rganishga mo'ljallanganligi sababli, oddiy nosozlik klassifikatsiyasidan ko'ra RUL va texnik holatning kelajakdagi o'zgarishini prognozlash vazifalarida alohida ahamiyat kasb etadi.

Tahlil qilinayotgan zamonaviy yo'nalishlardan biri CNN va rekurrent tarmoqlarni birlashtiruvchi gibrid arxitekturalardir. Rahim va hammualliflarning transport vositasi dvigateli holatini monitoring qilishga qaratilgan tadqiqotida Deep CNN-BiGRU modeli sensor ma'lumotlari va dvigatel komponentlarining zaiflik haqidagi axborotlarini birgalikda qayta ishlash uchun qo'llanilgan [9]. Model dvigatel holatini "good", "minor", "moderate" va "critical" darajalarga ajratgan hamda mualliflar tajribasida **0,8897, ya'ni 88,97 % aniqlik** ko'rsatgan. Bunda CNN diagnostik ma'lumotlardagi muhim lokal xususiyatlarni ajratsa, BiGRU ketma-ketlikdagi bog'lanishlarni ikki yo'nalishda tahlil qiladi. Natija gibrid arxitekturalarning kompleks texnik holatni baholashda alohida algoritmlardan ko'ra kengroq axborotni qayta ishlash imkoniyatiga ega ekanligini ko'rsatadi [9]. Biroq bunday modelning tuzilishi murakkab bo'lib, bort qurilmasida real vaqt rejimida ishlatilishi uchun hisoblash tezligi va resurs sarfini optimallashtirish zarur.

Algoritmlarni qiyoslash natijasida diagnostika va prognostika vazifalari o'rtasida muhim farq mavjudligi aniqlandi. **RF, SVM va ANN asosan "hozir transport vositasida qanday holat mavjud?" degan savolga javob berishda samarali**, ya'ni normal va nosoz rejimlarni ajratish hamda nosozlik turini tasniflash vazifalarida qo'llaniladi. **LSTM va boshqa rekurrent modellar esa "texnik holat keyinchalik qanday o'zgaradi?" degan prognostik vazifaga ko'proq mos keladi**. CNN esa signal va ko'p o'lchovli ma'lumotlardan xususiyatlarni ajratish vositasi sifatida ikkala yo'nalishda ham ishlatilishi mumkin. Shu sababli zamonaviy tadqiqotlarda CNN-LSTM, CNN-BiGRU va boshqa gibrid arxitekturalarga qiziqish ortib bormoqda.

Biroq chuqur o'qitish usullarining asosiy muammolaridan biri katta hajmdagi to'g'ri belgilangan nosozlik ma'lumotlariga ehtiyojdir. Real ekspluatatsiyada avtomobillar juda ko'p ma'lumot hosil qiladi, ammo ularning faqat kichik qismi "qaysi detal qachon va nima sababdan ishdan chiqqan" degan ishonchli belgi bilan biriktirilgan bo'ladi. Aynan shu muammo self-supervised learning yondashuvining transport diagnostikasidagi ahamiyatini oshirmoqda.

Lv va hammualliflarning 2026-yildagi tadqiqoti ushbu yo'nalishning amaliy imkoniyatini elektromobil akkumulyatorlari misolida ko'rsatadi [12]. Mualliflar contrastive-enhanced VAE-LSTM asosidagi self-supervised modeldan foydalanib, katta hajmdagi belgilersiz real zaryadlash ma'lumotlaridan degradatsiyaga oid latent xususiyatlarni o'rgangan. Model uchta real ekspluatatsion ma'lumotlar to'plamida sinovdan o'tkazilib, asosiy ma'lumotlar to'plamida RUL prognozi uchun **27 siki RMSE** natijasini ko'rsatgan. Boshqa transport parklariga ko'chirishda esa to'liq belgilangan bazaga ehtiyoj sezilarli kamaygan: transport vositalarining atigi 30 % qismi uchun label mavjud bo'lgan holatda model to'liq nazorat qilinadigan model prognoz samaradorligining qariyb 95 % ini saqlab qolgan. Mualliflar, shuningdek, ayrim cross-fleet holatlarida bazaviy modellarga nisbatan RMSEning 42 % gacha kamayishini qayd etgan [12]. Bu natija katta transport



parklarida to'planayotgan, ammo qo'lda belgilash qimmat bo'lgan ekspluatatsion ma'lumotlardan samarali foydalanish uchun self-supervised learning istiqbolli ekanligini ko'rsatadi.

Demak, transport vositalari nosozliklarini diagnostika qilishning keyingi rivojlanish bosqichi alohida mashinali o'qitish algoritmini tanlashdan ko'ra, sensor ma'lumotlarini birlashtiruvchi, vaqt bo'yicha degradatsiyani kuzatuvchi va cheklangan belgilangan ma'lumotlardan samarali foydalana oladigan gibril intellektual tizimlarni yaratish bilan bog'liq. Ayniqsa, CNN va rekurrent tarmoqlarning kombinatsiyasi, self-supervised learning, transfer learning hamda tushuntiriladigan sun'iy intellekt vositalarini bir tizimda integratsiya qilish transport vositalarining prediktiv diagnostikasi va ekspluatatsion ishonchliligini oshirish uchun istiqbolli ilmiy yo'nalish hisoblanadi.

XULOSA

O'tkazilgan tahlil transport vositalari nosozliklarini diagnostika qilish va prognozlashda sun'iy intellekt hamda mashinali o'qitish texnologiyalarining imkoniyatlari sezilarli darajada kengayib borayotganini ko'rsatdi. Zamonaviy diagnostika tizimlari transport vositasining joriy texnik holatini aniqlash bilan cheklanmay, nosozliklarning rivojlanish tendensiyasini baholash, qoldiq resursni prognozlash va texnik xizmat ko'rsatish vaqtini oldindan belgilash imkonini bermoqda. Bu esa ekspluatatsion ishonchlilikni oshirish, kutilmagan buzilishlarni kamaytirish va texnik xizmat ko'rsatish jarayonlarini yanada samarali tashkil etish uchun muhim ahamiyatga ega.

Algoritmning qiyosiy tahlili barcha diagnostik vazifalar uchun yagona universal model mavjud emasligini ko'rsatdi. Random Forest va SVM OBD-II, DTC hamda strukturaviy sensor ma'lumotlari asosida nosozliklarni tasniflashda samarali bo'lsa, ANN ko'p parametrliligi noquliyatli bog'lanishlarni aniqlash imkoniyati bilan ajralib turadi. CNN vibratsiya, akustik va boshqa murakkab signallardan diagnostik belgilarni avtomatik ajratishda, LSTM esa vaqt qatorlari asosida degradatsiya va qoldiq resursni prognozlashda yuqori salohiyatga ega. CNN-BiGRU kabi gibril arxitekturalar lokal xususiyatlar va vaqt bo'yicha bog'lanishlarni birgalikda hisobga olish imkonini beradi. Self-supervised learning yondashuvlari esa katta hajmdagi belgilarisiz ekspluatatsion ma'lumotlardan foydalanish orqali an'anaviy nazorat qilinadigan o'qitish usullarining ma'lumotlarga bo'lgan yuqori talabini kamaytirishi bilan istiqbolli hisoblanadi.

Shu bilan birga, sun'iy intellektga asoslangan diagnostika tizimlarini real transport vositalarida keng joriy etish uchun bir qator masalalar hali yechimini talab qiladi. Jumladan, turli avtomobil rusumlari va ekspluatatsiya sharoitlaridan olingan sifatli ma'lumotlar bazalarining yetishmasligi, nosozlik sinflarining nomutanosibligi, modellarni boshqa transport vositalariga moslashtirish, real vaqt rejimida ishlashni ta'minlash va chiqarilgan diagnostik xulosalarni texnik jihatdan izohlash masalalari dolzarbligicha qolmoqda. Ayniqsa, laboratoriya sharoitida yuqori natija ko'rsatgan modelning real ekspluatatsiyada ham bir xil aniqlikda ishlashini ta'minlash muhim ilmiy-amaliy vazifa hisoblanadi.

Kelgusidagi tadqiqotlarda ko'p sensorli ma'lumotlarni birlashtirish, CNN va rekurrent tarmoqlarni gibril shaklda qo'llash, self-supervised va transfer learning usullaridan foydalanish, shuningdek Explainable AI vositalarini diagnostika tizimlariga integratsiya qilish maqsadga muvofiq. Bunday yondashuvlar transport vositalarining texnik holatini uzluksiz monitoring qilish, nosozliklarni erta aniqlash, ularning rivojlanishini prognozlash va prediktiv texnik xizmat ko'rsatish tizimlarini takomillashtirish uchun muhim ilmiy asos bo'lib xizmat qiladi. Natijada transport vositalarining ekspluatatsion ishonchliligi, xavfsizligi va texnik xizmat ko'rsatish samaradorligini oshirish imkoniyati yuzaga keladi.

FOYDALANILGAN ADABIYOTLAR

1. Jardine A. K. S., Lin D., Banjevic D. A review on machinery diagnostics and prognostics implementing condition-based maintenance // *Mechanical Systems and Signal Processing*. – 2006. – Vol. 20, No. 7. – P. 1483–1510. – DOI: 10.1016/j.ymssp.2005.09.012.
2. Zhao R., Yan R., Chen Z., Mao K., Wang P., Gao R. X. Deep learning and its applications to machine health monitoring // *Mechanical Systems and Signal Processing*. – 2019. – Vol. 115. – P. 213–237. – DOI: 10.1016/j.ymssp.2018.05.050



3. Lei Y., Yang B., Jiang X., Jia F., Li N., Nandi A. K. Applications of machine learning to machine fault diagnosis: A review and roadmap // **Mechanical Systems and Signal Processing**. – 2020. – Vol. 138. – Art. 106587. – DOI: 10.1016/j.ymssp.2019.106587
4. Theissler A., Pérez-Velázquez J., Kettelgerdes M., Elger G. Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry // **Reliability Engineering & System Safety**. – 2021. – Vol. 215. – Art. 107864. – DOI: 10.1016/j.res.2021.107864.
5. Jain M., Vasdev D., Pal K., Sharma V. Systematic literature review on predictive maintenance of vehicles and diagnosis of vehicle's health using machine learning techniques // **Computational Intelligence**. – 2022. – Vol. 38, No. 6. – P. 1990–2008. – DOI: 10.1111/coin.12553.
6. Shafi U., Safi A., Shahid A. R., Ziauddin S., Saleem M. Q. Vehicle Remote Health Monitoring and Prognostic Maintenance System // **Journal of Advanced Transportation**. – 2018. – Vol. 2018. – Art. ID 8061514. – 10 p. – DOI: 10.1155/2018/8061514.
7. Li X., Wang N., Lyu Y., Duan Y., Zhao J. Data-Driven Fault Early Warning Model of Automobile Engines Based on Soft Classification // **Electronics**. – 2023. – Vol. 12, No. 3. – Art. 511. – DOI: 10.3390/electronics12030511.
8. Cervantes-Bobadilla M., García-Morales J., Saavedra-Benítez Y. I., Hernández-Pérez J. A., Adam-Medina M., Guerrero-Ramírez G. V., Escobar-Jiménez R. F. Multiple fault detection and isolation using artificial neural networks in sensors of an internal combustion engine // **Engineering Applications of Artificial Intelligence**. – 2023. – Vol. 117, Part A. – Art. 105524. – DOI: 10.1016/j.engappai.2022.105524.
9. Rahim M. A., Rahman M. M., Islam M. S., Muzahid A. J. M., Rahman M. A., Ramasamy D. Deep learning-based vehicular engine health monitoring system utilising a hybrid convolutional neural network/bidirectional gated recurrent unit // **Expert Systems with Applications**. – 2024. – Vol. 257. – Art. 125080. – DOI: 10.1016/j.eswa.2024.125080.
10. Rauf H., Khalid M., Arshad N. Machine learning in state of health and remaining useful life estimation: Theoretical and technological development in battery degradation modelling // **Renewable and Sustainable Energy Reviews**. – 2022. – Vol. 156. – Art. 111903. – DOI: 10.1016/j.rser.2021.111903.
11. Renold A. P., Kathayat N. S. Comprehensive Review of Machine Learning, Deep Learning, and Digital Twin Data-Driven Approaches in Battery Health Prediction of Electric Vehicles // **IEEE Access**. – 2024. – Vol. 12. – P. 43984–43999. – DOI: 10.1109/ACCESS.2024.3380452.
12. Lv Z., Ou S., Jing H., Wu G., Shi D. Self-supervised learning for electric vehicle battery remaining useful life prediction using real-world unlabeled data // **Energy**. – 2026. – Vol. 356. – Art. 141302. – DOI: 10.1016/j.energy.2026.141302.
13. Hossain M. N., Rahman M. M., Ramasamy D. Advances in intelligent vehicular health monitoring and fault diagnosis: Techniques, technologies, and future directions // **Measurement**. – 2025. – Vol. 253, Part B. – Art. 117618. – P. 1–22. – DOI: 10.1016/j.measurement.2025.117618
14. Mahale Y., Kolhar S., More A. S. A comprehensive review on artificial intelligence driven predictive maintenance in vehicles: Technologies, challenges and future research directions // **Discover Applied Sciences**. – 2025. – Vol. 7. – Art. 243. – DOI: 10.1007/s42452-025-06681-3