

=====

TEMIR YO‘L INFRATUZILMASI ELEMENTLARINING TEXNIK HOLATINI  
SUN‘IY INTELLEKT ASOSIDA BAHOLASH

G‘ulomov Latifjon Ilyosjon o‘g‘li  
Toshkent davlat transport universiteti

MAQOLA  
MALUMOTI

ANNOTATSIYA:

**MAQOLA TARIXI:**

Received: 25.06.2026

Revised: 26.06.2026

Accepted: 27.06.2026

**KALIT SO‘ZLAR:**

*sun‘iy intellekt, temir  
yo‘l infratuzilmasi,  
texnik holatni baholash,  
prediktiv ta‘mirlash,  
kompyuter ko‘rish,  
vibratsion monitoring,  
chuqur o‘qitish*

*Temir yo‘l infratuzilmasining texnik holatini ishonchli baholash harakat xavfsizligi, ekspluatatsion uzluksizlik va ta‘mirlash xarajatlarini boshqarish uchun tayanch vazifa hisoblanadi. So‘nggi yillarda sun‘iy intellektga asoslangan yondashuvlar rels, mahkamlagich, ballast, strelka-o‘tkazgich, ko‘prik va kontakt tarmog‘i kabi elementlarning degradatsiyasini an‘anaviy davriy ko‘rikdan ko‘ra tezroq va aniqroq aniqlash imkonini bermoqda. Adabiyotlar shuni ko‘rsatadiki, kompyuter ko‘rish, vibratsion tahlil, akustik monitoring, geometriya o‘lchovlari va IoT sensorlaridan olingan ma‘lumotlar mashinaviy o‘qitish hamda chuqur o‘qitish modellariga uzatilganda texnik holatni baholash reaktiv ta‘mirdan prediktiv ta‘mirlashga o‘tadi. Shu bilan birga, ma‘lumotlarning parchalanishi, kam uchraydigan nosozliklar, izohlanuvchanlik va real ekspluatatsiya sharoitida validatsiya masalalari hanuz dolzarb. Mazkur maqolada temir yo‘l infratuzilmasi elementlarining texnik holatini sun‘iy intellekt asosida baholashning asosiy yo‘nalishlari, qo‘llanilayotgan ma‘lumot manbalari, model sinflari, amaliy natijalari va joriy etish cheklovlari tahlil qilinadi.*

**Kirish:** Temir yo‘l infratuzilmasining texnik holatini ishonchli baholash harakat xavfsizligi, ekspluatatsion uzluksizlik va ta‘mirlash xarajatlarini boshqarishda muhim ahamiyatga ega. So‘nggi yillarda sun‘iy intellekt (SI) asosidagi yondashuvlar rels, mahkamlagich, ballast, strelka-o‘tkazgich, ko‘prik va kontakt tarmog‘i kabi elementlarning degradatsiyasini an‘anaviy ko‘rik usullariga nisbatan tezroq va aniqroq aniqlash imkonini bermoqda.

Kompyuter ko‘rish, vibratsion tahlil, akustik monitoring va IoT sensorlaridan olingan ma‘lumotlar mashinaviy o‘qitish va chuqur o‘qitish modellariga kiritilganda prediktiv ta‘mirlash imkoniyati yuzaga keladi [2], [3]. Biroq ma‘lumotlarning parchalanishi, kam uchraydigan nosozliklar va izohlanuvchanlik muammolari hanuz dolzarb.

**Adabiyotlar bo'yicha umumiy manzara**

<b>Manba</b>	<b>Qamrov</b>	<b>Asosiy hissa</b>	<b>Maqola uchun ahamiyati</b>
(Bris-Peñalver et al., 2026)	Temir yo'1 infratuzilmasi bo'yicha AI-enabled predictive maintenance survey	Infratuzilma, energiya va signalizatsiya quyi tizimlari kesimida ma'lumotlar, modellar va bo'shliqlarni tizimlashtiradi	Eng yaqin umumiy tayanch manba
(Summa et al., 2023)	Railway infrastructure monitoring bo'yicha deep learning sharhi	Rail area va overhead contact system uchun DL vazifalarini tasniflaydi	Ko'rish asosidagi monitoring uchun asos beradi
(Davari et al., 2021)	Data-driven predictive maintenance survey	Failure prediction, RUL, anomaly detection, classification, regression tasnifini beradi	Texnik holat baholashning metodik skeletini beradi
(Binder et al., 2023)	Railway predictive maintenance systematic review	Turli aktivlar va algoritmlarni bir joyga yig'adi	Prediktiv ta'mirlash oqimini yoritadi
(Bešinović et al., 2022)	Railway AI taxonomy	AI yondashuvlarini temir yo'1 subdomenlari bilan bog'laydi	Kengroq konseptual ramka beradi
(Donato et al., 2022)	Audio-video based defect detection survey	Vizual va akustik kuzatuvning amaliy afzalliklari hamda cheklovlarini ko'rsatadi	Sensor va ma'lumot turlarini boyitadi

## Sun'iy intellekt asosidagi texnik holat baholash yondashuvlari

### Kompyuter ko'rish asosidagi baholash

Kompyuter ko'rish temir yo'l infratuzilmasi holatini baholashda eng tez pishib borayotgan yo'nalishlardan biridir, chunki u ko'rikni subyektiv kuzatuvdan standartlashgan, takrorlanuvchi va yuqori chastotali raqamli inspeksiyaga aylantiradi [2], [11]. Amaliyotda bu yondashuv rels yuzasidagi yoriq, squat va corrugationlarni, mahkamlagichlarning bo'shishi yoki sinishini, ballast holatini, sleeper nuqsonlarini hamda kontakt tarmog'i elementlaridagi defektlarni aniqlash uchun qo'llanadi [6], [11].

So'nggi sharhlar ko'rsatishicha, kompyuter ko'rishda uchta vazifa ustun: **detection**, **segmentation** va **classification** [2]. Detection nuqsonning joylashuvini topadi, segmentation uning maydoni va shaklini aniq ajratadi, classification esa obyekt yoki nuqson holatini sinflarga bo'ladi. Temir yo'l inspeksiyasi uchun bu uchala bosqichning ketma-ket qo'llanishi ayniqsa muhim, chunki amaliy qaror qabul qilishda faqat nuqson borligi emas, uning qayerda ekanligi va qanchalik xavfli ekani ham kerak bo'ladi [11].

Rels va mahkamlagichlar bo'yicha [7] uch bosqichli pipeline taklif qiladi: avval YOLOv5 asosida rels va mahkamlagich lokalizatsiya qilinadi, keyin Mask R-CNN yordamida rels yuzasidagi nuqson segmentatsiya qilinadi, so'ng ResNet orqali mahkamlagich holati normal, bo'shashgan yoki singan sinflarga ajratiladi. Ushbu yondashuv yuqori aniqlik va tezlikka erishib, ballastli va ballastsiz yo'llarda ham qo'llanishini ko'rsatgan. Bu natija temir yo'l inspeksiyasida ko'p bosqichli pipeline'lar sodda bitta klassifikatordan ko'ra amaliyroq ekanini ko'rsatadi [7].

Audio-video inspeksiya bo'yicha sharhda [6] vizual ma'lumotlar ustunligini, lekin akustik signallar hali yetarlicha ishlatilmayotganini qayd etadi. Bu muhim, chunki kamera tashqi nuqsonni juda yaxshi ko'rsa ham, akustik kanal ichki shikastlanish yoki ko'zga darhol tashlanmaydigan defektlarga sezgir bo'lishi mumkin. Shu sababli multimodal inspeksiya, ya'ni video va audio oqimlarni birlashtirish, ayniqsa yolg'on ogohlantirishlarni kamaytirish va yomon yoritish yoki ko'rish sharoitida ishonchlilikni oshirish uchun istiqbolli yo'nalish hisoblanadi [6].

Yangi ishlar ko'rsatishicha, kompyuter ko'rish faqat rels va fastener bilan cheklanmayapti. [11] ballast degradatsiyasi, yo'l geometriyasi siljishlari, sleeper nuqsonlari va hatto UAV orqali olingan tasvirlar asosida masofaviy kuzatuvni ham umumlashtiradi. Bu esa AI asosidagi texnik holat baholash asta-sekin statsionar kamera inspeksiyasidan mobil va tarmoq miqyosidagi monitoringga o'tayotganini anglatadi [11], [12].

Shu bilan birga, bu yo'nalishda amaliy cheklovlar ham kuchli. Adabiyotlarda yomon yoritish, yomg'ir, qor, tuman, yuqori tezlik sababli motion blur, mayda nuqsonlarning fon bilan aralashib ketishi va annotatsiyalangan datasetlar tanqisligi asosiy to'siqlar sifatida ko'rsatiladi [6], [11]. Demak, Q1 darajadagi tahlilda kompyuter ko'rishni "yuqori aniqlikdagi model" sifatida emas, balki ma'lumot sifati, kamera joylashuvi, tezlik va hisoblash quvvatiga kuchli bog'liq inspeksion tizim sifatida baholash to'g'riroq bo'ladi.

### Vibratsion va dinamik monitoring

Strelka-o'tkazgichlar, ko'priklar, relslar va ayrim hollarda ballast hamda yo'l geometriyasi elementlari uchun vibratsion monitoring AI bilan qo'shilganda ayniqsa kuchli natija beradi [1], [3]. Bu yondashuvning asosiy afzalligi shundaki, u ko'pincha ko'zga ko'rinmaydigan degradatsiyani dinamik javobdagi nozik o'zgarishlar orqali ushlaydi. Shuning uchun vibratsion monitoring kompyuter ko'rishga nisbatan ko'proq "ichki holat"ni aks ettiruvchi usul sifatida qaraladi.

Adabiyotlarda bu yo'nalish odatda uchta bosqichda ishlaydi: signalni olish, xususiyat ajratish va holatni baholash [3]. Xususiyatlar vaqt sohasida RMS, kurtosis, crest factor kabi statistik ko'rsatkichlar bo'lishi mumkin; chastota sohasida esa FFT, wavelet yoki spektrogrammalar ishlatiladi. Aynan shu bosqichda klassik signal processing bilan chuqur o'qitishning birlashuvi kuchli natija beradi [1].

Strelka-o'tkazgichlar bo'yicha [8] to'liq o'lchamli sinov stendida akselerometrlar yordamida vibratsiya ma'lumotlarini yig'ib, yeyilish darajasini baholash uchun ikki xil modelni sinagan. LSTM vaqt sohasidagi xususiyatlar bilan ishlagan, ResNet esa vibratsiya signallaridan hosil qilingan spektrogrammalar bilan o'qitilgan. Natijalar ResNet o'rta darajadagi yeyilish bosqichlarini farqlashda LSTMdan yaxshiroq ishlaganini ko'rsatadi. Bu esa vibratsion signallarni tasvirga aylantirib tahlil qilish ayrim holatlarda oddiy ketma-ketlik modelidan kuchliroq bo'lishi mumkinligini anglatadi [8].

[9] strelka tayanchlarining suv bosish sharoitida degradatsiyasini pattern recognition asosida 98% dan yuqori aniqlik bilan tasniflash mumkinligini ko'rsatadi. Ushbu natija muhim, chunki u dinamik monitoring faqat mexanik yeyilishni emas, balki ekstremal ob-havo ta'sirida yuzaga keladigan tayanch zaiflashuvini ham aniqlay olishini ko'rsatadi. Demak, vibratsion AI modellari uchun tashqi muhit omillarini kirish parametri sifatida kiritish foydali emas, balki ko'p hollarda zarur [9].

Ko'priklar bo'yicha yanada qiziq yo'nalish — **drive-by monitoring**. [13] shikastlanishni to'g'ridan-to'g'ri ko'prikkaga sensor o'rnatmasdan, ko'prikdan o'tayotgan poyezdning dinamik javobi orqali aniqlash mumkinligini ko'rsatadi. Unda train-borne vertikal tezlanishlar Continuous Wavelet Transform orqali 2D ko'rinishga keltirilib, GoogLeNet asosidagi CNN yordamida "sog'lom" va "shikastlangan" holatlar ajratiladi. Bu yondashuvning asosiy qiymati shundaki, u tarmoq bo'yicha ko'plab ko'priklarni bitta instrumentlangan harakat tarkibi yordamida baholash imkoniyatini ochadi [13].

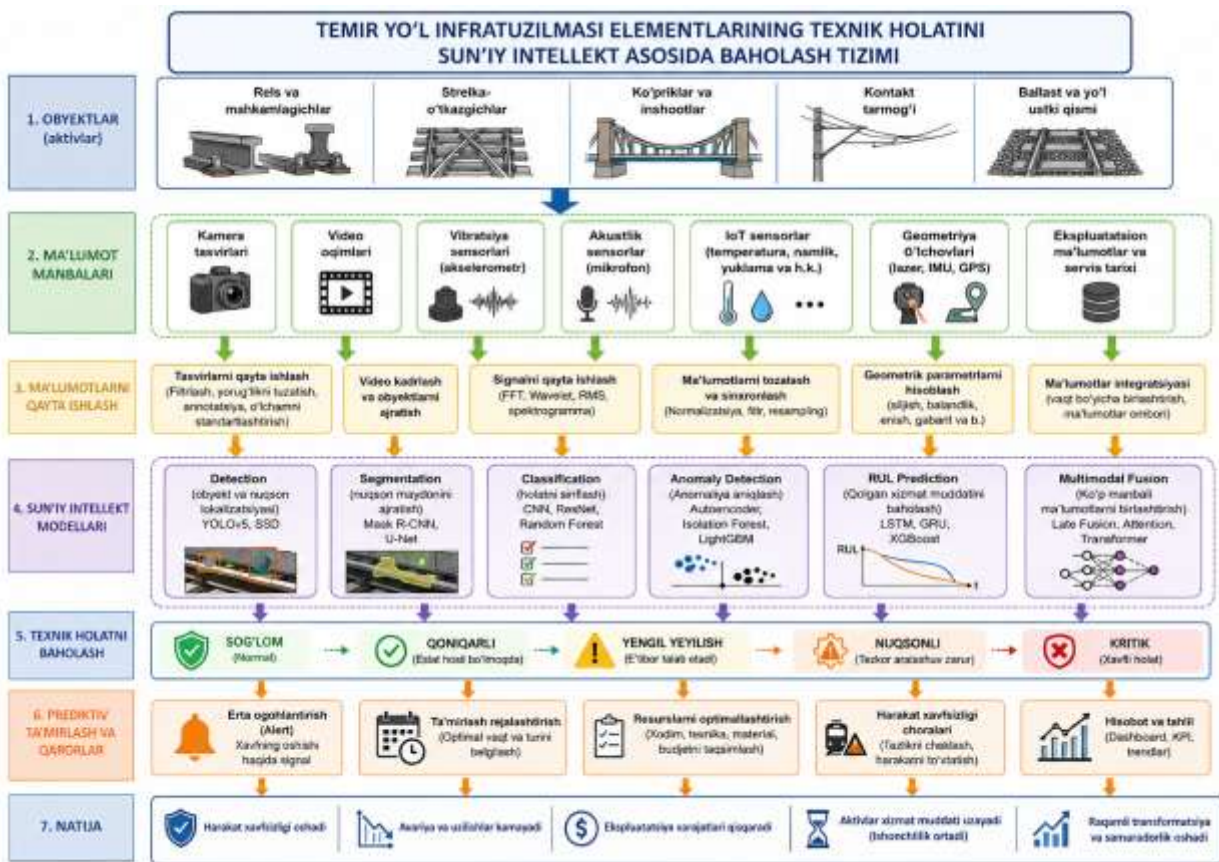
Shu bilan birga, vibratsion monitoringning zaif tomoni ham bor. Signal tarkibi yuklama turi, poyezd tezligi, g'ildirak holati, ballast sifati va atrof-muhit shovqini bilan kuchli aralashadi [1], [3]. Demak, yuqori aniqlik faqat model tanlovi bilan emas, balki signalni to'g'ri normallashtirish, sharoitga mos kalibrlash va fizik ma'noga ega xususiyatlarni ajratish bilan ham belgilanadi. Shu nuqtai nazardan, vibratsion monitoringda "physics-informed AI" yoki hech bo'lmaganda signal processing bilan boyitilgan AI yondashuvi sof black-box modeldan ko'ra ishonchliroq ko'rinadi.

**Struktur sog'liq monitoringi**

Ko'priklar, estakadalar va boshqa yirik sun'iy inshootlar uchun struktur sog'liq monitoringi temir yo'l infratuzilmasi ichida alohida sinf bo'lib, bunda maqsad nuqsonni topishdan ko'ra konstruksiyaning global xatti-harakatidagi o'zgarishni kuzatishdir [10], [14]. Bu yerda AI odatda anomaliyani aniqlovchi qatlam sifatida ishlaydi: avval normal holatning dinamik "imzosi" o'rganiladi, keyin undan og'ish xavfli holat sifatida baholanadi.

[10] temir yo'l ko'prigi uchun arzon simsiz MEMS akselerometrlar, edge-cloud arxitekturasi, FFT asosidagi xususiyatlar va LightGBM klassifikatorini birlashtirgan. Mualliflar normal tebranish klasterlarini k-means bilan ajratib, keyin raqamli egizak va FEM yordamida shikastlanish ssenariyalarini modellashtirgan. Natijada tizim anomal vibratsion namunalarga real vaqtga yaqin ogohlantirish bera olishi, o'rnatish va xizmat ko'rsatish xarajatlarini sezilarli kamaytirishi ko'rsatilgan. Bu ish SHM tizimlarida arzon sensor + edge preprocessing + ML klassifikatori kombinatsiyasi amaliy qiymatga ega ekanini ko'rsatadi [10].

[14] ushbu yo'nalishni yanada operatsion bosqichga olib chiqadi. Mualliflar ko'prikdagi accelerometer va displacement sensorlari asosida avval Random Forest va SHAP orqali eng muhim sensor nuqtalarini tanlaydi, keyin LSTM ansambli bilan normal dinamik xulq-atvorni o'rganadi va nihoyat "safe", "limit" va "critical" zonalariga asoslangan qaror qabul qilish sxemasini taklif qiladi. Eng muhim jihati shundaki, model natijasi faqat texnik xulosa



bo‘lib qolmay, balki tezlikni cheklash yoki harakatni to‘xtatish kabi ekspluatatsion choralar bilan bog‘lanadi [14].

Taklif qilgan drive-by monitoring esa SHMning yangi paradigmasini ko‘rsatadi. Unda doimiy statsionar datchiklar o‘rniga poyezdning o‘zi o‘lchov platformasi vazifasini bajaradi. Bu yondashuv ayniqsa ko‘plab ko‘priklar mavjud bo‘lgan tarmoqlarda xarajatni kamaytirish va qamrovni kengaytirish uchun istiqbolli ko‘rinadi, garchi u hali ko‘proq nazorat qilinadigan yoki simulyatsion sharoitlarda sinab ko‘rilgan bo‘lsa ham [13].

SHM bo‘yicha adabiyotlar bir narsani aniq ko‘rsatadi: bu yerda model aniqligining o‘zi yetarli emas. Qaror qabul qilish uchun sensorlar joylashuvi, normal holat bazasining sifati, tashqi muhit ta‘siri, poezd yuklamasi va operatsion thresholdlarning asoslanganligi ham hal qiluvchi ahamiyatga ega [10], [14]. Shu sababli struktur sog‘liq monitoringida AI ko‘pincha mustaqil diagnostika vositasi emas, balki sensorlar, mexanik model va ekspluatatsion qoidalar bilan birlashgan qaror qo‘llab-quvvatlash tizimi sifatida samaraliroq ishlaydi.

### **Ko‘p manbali prediktiv ta‘mirlash**

Texnik holatni baholashning eng amaliy natijasi prediktiv ta‘mirlashga olib kelishi kerak. Bu yerda AI modelining vazifasi faqat defekt topish emas, balki nosozlikka qadar qolgan vaqtni, xavfning qaysi aktivda oshayotganini yoki qaysi obyektga birinchi bo‘lib xizmat ko‘rsatish zarurligini aniqlashdir [3], [4]. Sharhlarda ushbu vazifalar failure prediction va remaining useful life baholash sifatida ajratiladi. Lekin so‘nggi tadqiqotlar shuni ko‘rsatadiki, haqiqiy sanoat qiymati alohida modelda emas, balki **ko‘p manbali ma‘lumotlarni bitta sog‘liq modeliga yig‘ishda yotadi** [1], [15].

[1] va [4]ga ko‘ra, prediktiv ta‘mirlashda random forest, SVM, gradient boosting, LSTM, GRU, CNN va gibrid modellar eng ko‘p qo‘llanadi. Tasvirga asoslangan vazifalarda CNN oilasi ustun bo‘lsa, vaqt qatori va servis tarixiga asoslangan vazifalarda ketma-ketlik modellarining roli kuchliroq. Biroq [15] bu tasnifni yanada chuqurlashtirib, vizual, vibratsion, geometriya, operatsion va tarixiy servis ma‘lumotlari birlashgandagina aktivning haqiqiy degradatsiya trayektoriyasini tushunish mumkinligini ko‘rsatadi.

Yangi arxitekturalar bu yerda BIM, digital twin va edge-cloud hisoblashni ham qo‘shmoqda. [16] AI-assisted digital twin uchun fizik qatlam, data layer, virtual layer va service layerdan iborat reference architecture taklif qiladi. Unda sensorlardan kelgan birlamchi va ikkilamchi ma‘lumotlar avval tozalanadi va boyitiladi, so‘ng AI orqali xulq-atvor modeli yaratiladi, undan keyin esa RUL prognozi, alert va ta‘mirlash qarorlari shakllantiriladi. Bu yondashuv prediktiv ta‘mirlashni alohida model emas, balki to‘liq cyber-physical servis sifatida ko‘rsatadi [16].

Biroq bu yo‘nalishning muammolari ham jiddiy. Eng katta to‘siqlar — sog‘lom holatlar ustun bo‘lgan notekis datasetlar, turli sensor formatlari o‘rtasidagi interoperabilitet yetishmasligi, qora quti modellariga ishonch pastligi va real tarmoq darajasida bidirectional digital twinlarning kamligi [1], [15]. Demak, ko‘p manbali prediktiv ta‘mirlashning

rivojlanishi faqat yangi model qurishga emas, balki ma'lumot standartlari, ochiq interfeyslar va ekspluatatsion integratsiyaga ham bevosita bog'liq.

### **Xulosa**

Temir yo'l infratuzilmasi elementlarining texnik holatini sun'iy intellekt asosida baholash bugungi kunda rels, mahkamlagich, strelka-o'tkazgich, ko'prik va kontakt tarmog'i kabi muhim obyektlarning ishonchligini oshirishga xizmat qilayotgan istiqbolli yo'nalishlardan biri hisoblanadi [1], [2]. Tadqiqotlar natijalari shuni ko'rsatadiki, kompyuter ko'rish texnologiyalari yordamida rels va mahkamlagichlardagi nuqsonlarni avtomatik aniqlash, vibratsion monitoring asosida degradatsiya jarayonlarini baholash hamda struktur sog'liq monitoringi tizimlari orqali yirik sun'iy inshootlarning texnik holatini real vaqt rejimida nazorat qilish mumkin [7], [8], [10]. Bu esa an'anaviy davriy ko'riklarga nisbatan yuqori aniqlik, tezkorlik va iqtisodiy samaradorlikni ta'minlaydi.

Shuningdek, sun'iy intellekt texnologiyalari texnik xizmat ko'rsatish tizimini reaktiv yondashuvdan prediktiv yondashuvga o'tkazish imkonini bermoqda. Bunda infratuzilma elementlarining joriy holati, ekspluatatsion yuklamalari va tarixiy ma'lumotlari tahlil qilinib, nosozliklarning yuzaga kelish ehtimoli oldindan prognoz qilinadi. Natijada ta'mirlash ishlarini optimal muddatlarda amalga oshirish, avariya holatlar xavfini kamaytirish hamda ekspluatatsiya xarajatlarini qisqartirish imkoniyati yaratiladi [2], [3].

Biroq sun'iy intellekt tizimlarining samaradorligi faqat model arxitekturasiga bog'liq emas. Ma'lumotlar sifati va hajmi, sensorlar tarmog'ining rivojlanganligi, turli axborot manbalarining integratsiyalashganligi hamda modellar natijalarining izohlanuvchanligi muhim omillar hisoblanadi [1], [3], [5]. Ayniqsa, temir yo'l transporti kabi xavfsizlik darajasi yuqori bo'lgan sohalarda AI tizimlarining ishonchligi va amaliy ekspluatatsiya sharoitlarida validatsiyasi alohida ahamiyat kasb etadi.

### **References**

[1] F. J. Bris-Peñalver, R. Verdecia-Peña, and J. I. Alonso, "A Survey of AI-Enabled Predictive Maintenance for Railway Infrastructure: Models, Data Sources, and Research Challenges," *Sensors (Basel, Switzerland)*, vol. 26, Jan. 2026, doi: [10.3390/s26030906](https://doi.org/10.3390/s26030906).

[2] M. D. Summa *et al.*, "A Review on Deep Learning Techniques for Railway Infrastructure Monitoring," *IEEE Access*, vol. 11, pp. 114638–114661, 2023, doi: [10.1109/ACCESS.2023.3309814](https://doi.org/10.1109/ACCESS.2023.3309814).

[3] N. Davari, B. Veloso, G. de A. Costa, P. Pereira, R. P. Ribeiro, and J. Gama, "A Survey on Data-Driven Predictive Maintenance for the Railway Industry," *Sensors (Basel, Switzerland)*, vol. 21, Aug. 2021, doi: [10.3390/s21175739](https://doi.org/10.3390/s21175739).

[4] M. Binder, V. Mezhuyev, and M. Tschandl, "Predictive Maintenance for Railway Domain: A Systematic Literature Review," *IEEE Engineering Management Review*, vol. 51, pp. 120–140, 2023, doi: [10.1109/EMR.2023.3262282](https://doi.org/10.1109/EMR.2023.3262282).

=====

[5] N. Bešinović *et al.*, “Artificial Intelligence in Railway Transport: Taxonomy, Regulations, and Applications,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, pp. 14011–14024, Sep. 2022, doi: [10.1109/TITS.2021.3131637](https://doi.org/10.1109/TITS.2021.3131637).

[6] L. D. Donato *et al.*, “A Survey on Audio-Video based Defect Detection through Deep Learning in Railway Maintenance,” *IEEE Access*, vol. PP, pp. 1–1, 2022, doi: [10.1109/ACCESS.2022.3183102](https://doi.org/10.1109/ACCESS.2022.3183102).

[7] D. Zheng *et al.*, “A Defect Detection Method for Rail Surface and Fasteners Based on Deep Convolutional Neural Network,” *Computational Intelligence and Neuroscience*, vol. 2021, Jul. 2021, doi: [10.1155/2021/2565500](https://doi.org/10.1155/2021/2565500).

[8] T. Najeh, J. Lundberg, and A. Kerrouche, “Deep-Learning and Vibration-Based System for Wear Size Estimation of Railway Switches and Crossings,” *Sensors (Basel, Switzerland)*, vol. 21, Jul. 2021, doi: [10.3390/s21155217](https://doi.org/10.3390/s21155217).

[9] J. Sresakoolchai, M. Hamarat, and S. Kaewunruen, “Automated machine learning recognition to diagnose flood resilience of railway switches and crossings,” *Scientific Reports*, vol. 13, Feb. 2023, doi: [10.1038/s41598-023-29292-7](https://doi.org/10.1038/s41598-023-29292-7).

[10] A. Armijo and D. Zamora-Sánchez, “Integration of Railway Bridge Structural Health Monitoring into the Internet of Things with a Digital Twin: A Case Study,” *Sensors (Basel, Switzerland)*, vol. 24, Mar. 2024, doi: [10.3390/s24072115](https://doi.org/10.3390/s24072115).

[11] M. Alif, G. Tucker, and M. Hussain, “Advances in computer vision for comprehensive railway engineering: from track inspection to rolling stock and safety monitoring,” *Railway Engineering Science*, Apr. 2026, doi: [10.1007/s40534-026-00434-7](https://doi.org/10.1007/s40534-026-00434-7).

[12] P. Bojarczak and P. Lesiak, “UAVs in rail damage image diagnostics supported by deep-learning networks,” *Open Engineering*, vol. 11, pp. 339–348, Jan. 2021, doi: [10.1515/eng-2021-0033](https://doi.org/10.1515/eng-2021-0033).

[13] D. Hajializadeh, “Deep-Learning-Based Drive-by Damage Detection System for Railway Bridges,” Jun. 14, 2022. doi: [10.3390/infrastructures7060084](https://doi.org/10.3390/infrastructures7060084).

[14] J. Sanz-Bobi, P. G. Martínez-Llop, P. R. Marcos, Á. S. Jiménez, and J. Fernandez, “Prediction of Degraded Infrastructure Conditions for Railway Operation,” *Sensors (Basel, Switzerland)*, vol. 24, Apr. 2024, doi: [10.3390/s24082456](https://doi.org/10.3390/s24082456).

[15] U. Mutlu and S. Kaewunruen, “Digitalised Predictive Maintenance in Railways: A Systematic Review of AI, BIM, and Digital Twins,” *Infrastructures*, Mar. 2026, doi: [10.3390/infrastructures11030087](https://doi.org/10.3390/infrastructures11030087).

[16] L. D. Donato *et al.*, “Towards AI-assisted digital twins for smart railways: preliminary guideline and reference architecture,” *Journal of Reliable Intelligent Environments*, vol. 9, pp. 303–317, Jun. 2023, doi: [10.1007/s40860-023-00208-6](https://doi.org/10.1007/s40860-023-00208-6).

[17] M. Kazemi, M. Rashidi, W.-H. Kang, and M. Siahkouhi, “Toward Smart Railway Infrastructure Predictive and Optimised Maintenance Through Digital Twin (DT) System,” *Sensors (Basel, Switzerland)*, vol. 26, Apr. 2026, doi: [10.3390/s26082333](https://doi.org/10.3390/s26082333).