

**SANOAT USKUNALARINING NOSOZLIKLARINI BASHORAT
QILISH: IoT SENSORLAR MA'LUMOTLARI ASOSIDA MASHINALI
O'RGANISH ALGORITMLARINI QO'LLASH**

Mansurov Muhammadjon Murodjon o'g'li

Ilmiy rahbar: t.f.b.f.d, (PhD), dotsent Durbek Roxmonov

Namangan davlat texnika universiteti

“Axborot tizimlari va texnologiyalari” kafedrası stajor o'qituvchisi

muhammadjon0513@gmail.com


Annotatsiya. Maqolada sanoat uskunalarining ishdan chiqishini IoT sensorlar ma'lumotlari asosida oldindan aniqlovchi bashoratli texnik xizmat ko'rsatish (Predictive Maintenance) tizimining arxitekturası taklif etilgan. Sun'iy sensor ma'lumotlarida to'rtta mashinali o'rganish modeli solishtirilgan, eng muvozanatli natijani Gradient Boosting ko'rsatgan ($F1 = 0,66$).

Kalit so'zlar. bashoratli texnik xizmat, IoT, mashinali o'rganish, nosozlikni bashorat qilish, sanoat uskunaları.

Kirish. Sanoat korxonalarida uskunaning kutilmagan to'xtashi ishlab chiqarishni to'xtatadi va qo'shimcha xarajat keltiradi. An'anaviy yondashuvlar ikki turga bo'linadi: nosozlik yuz bergandan keyin ta'mirlash va belgilangan muddat bo'yicha profilaktik xizmat [1]. Birinchisi to'xtab qolish xavfini oshiradi, ikkinchisi hali ishlashga yaroqli qismlarni ham almashtirishga olib keladi. Bashoratli yondashuv uskunaning haqiqiy holatiga tayanadi: sensorlardan kelgan ma'lumotlar tahlil qilinib, xizmat faqat kerak bo'lgan paytda rejalashtiriladi. So'nggi sharhlar shuni ko'rsatadiki, mashinali o'rganish usullari bu sohada tobora keng qo'llanilmoqda [2]. Tadqiqotning maqsadi IoT ma'lumotlari asosida uskunaning ishdan chiqish ehtimolini baholaydigan tizimni ishlab chiqish va unga mos modelni tanlashdir.


Tizim arxitekturası. Taklif etilgan tizim besh bosqichdan iborat (1-rasm).

Sensorlar tebranish, harorat, bosim va tok kuchini o'lchaydi. Shlyuz qurilmasi signallarni yig'ib, filtrlaydi va MQTT protokoli orqali ma'lumotlar omboriga uzatadi. Omborda vaqt qatorlari tozalanadi, ulardan xususiyatlar hosil qilinadi va model o'qitiladi. Model ishdan chiqish ehtimolini hisoblaydi, ehtimol belgilangan chegaradan oshganda esa texnik xizmat (TXK) bo'yicha ogohlantirish yuboriladi. Haqiqiy nosozliklar to'g'risidagi ma'lumotlar modelni davriy yangilash uchun qayta aloqa sifatida ishlatiladi.



1-rasm. IoT asosidagi bashoratli texnik xizmat tizimining arxitekturası

Bashoratning mohiyati. Uskunaning holati vaqt o'tishi bilan asta-sekin yomonlashadi. Sog'lik indikatori ogohlantirish chegarasidan pastga tushganda tizim signal beradi, nosozlik chegarasigacha esa hali vaqt qoladi (2-rasm). Aynan shu oraliq, ya'ni bashorat oynasi, ta'mirni ishlab chiqarishga xalaqit bermaydigan vaqtga rejalashtirish imkonini beradi.




2-rasm. Sog'lik indikatori va bashorat oynasi (shartli misol)

Tadqiqot usuli. Modellarni solishtirish uchun 8000 namunadan iborat sun'iy ma'lumotlar to'plami yaratildi. Har bir namuna oltita xususiyatni o'z ichiga oladi: tebranish, harorat, bosim, tok kuchi, aylanish tezligi va ish soati. Namunalarning 9,8 foizi nosozlik oldi holatiga tegishli bo'lib, sinflar muvozanatsiz. Ma'lumotlar o'qitish (75 %) va sinov (25 %) qismlariga sinflar nisbatini saqlagan holda bo'lindi. Logistik regressiya, SVM (RBF yadro), Random Forest [3] va Gradient Boosting [4] modellari scikit-learn kutubxonasida [5] o'qitildi. Sifat precision, recall, F1 va ROC-AUC ko'rsatkichlari bilan baholandi.

Natijalar. Natijalar 1-jadvalda va 3-rasmda keltirilgan. Gradient Boosting eng yuqori F1 ko'rsatkichini (0,66) berdi, precision va recall o'rtasida muvozanatni saqlab qoldi. Logistik regressiya va SVM nosozliklarning 90–92 foizini topdi, biroq precision atigi 0,39–0,42 bo'ldi, ya'ni ko'p yolg'on signal chiqdi. Random Forest esa eng yuqori precision (0,74) va eng past recall (0,52) bilan ajralib turdi. Xususiyatlar ahamiyati bo'yicha harorat (0,33) birinchi, tebranish va bosim (har biri 0,20) keyingi o'rinlarda turibdi.

1-jadval. Modellarning sinov to'plamidagi natijalari

Model	Precision	Recall	F1	ROC-AUC
Logistik regressiya	0.42	0.90	0.57	0.96
SVM (RBF)	0.39	0.92	0.55	0.94
Random Forest	0.74	0.52	0.61	0.95
Gradient Boosting	0.69	0.63	0.66	0.95



3-rasm. Modellar sifatini solishtirish va xususiyatlar ahamiyati

Muhokama. Modelni tanlash xatolarning narxiga bog'liq. Nosozlikni o'tkazib yuborish og'ir oqibat keltirsa, recall yuqori modellar afzal, ammo ular ko'p yolg'on ogohlantirish beradi. Yolg'on signal narxi yuqori bo'lsa, precision yuqori model mos keladi. Ko'p hollarda ehtimol chegarasini sozlash va Gradient Boosting kabi muvozanatli modeldan foydalanish maqbul kelishuvdir. Shuni ta'kidlash kerakki, tajriba sun'iy ma'lumotlarda o'tkazildi, shuning uchun mutlaq ko'rsatkichlar haqiqiy uskunadagi natijani bildirmaydi. Keyingi bosqichda AI4I 2020 [6] va NASA C-MAPSS [7] kabi ochiq to'plamlarda hamda korxonaning real ma'lumotlarida tekshirish rejalashtirilgan.

Xulosa. IoT sensorlar va mashinali o'rganishga asoslangan tizim uskunaning ishdan chiqishini oldindan aniqlash va texnik xizmatni to'g'ri vaqtga rejalashtirish imkonini beradi. Solishtirilgan modellar orasida Gradient Boosting eng muvozanatli natija berdi, harorat va tebranish esa eng muhim signallar bo'ldi. Ishning davomi sifatida real ma'lumotlarda tekshirish va qolgan resursni (RUL) bashorat qilish ko'zda tutilgan.

Foydalanilgan adabiyotlar

1. Mobley R.K. An Introduction to Predictive Maintenance. 2nd ed. – Amsterdam: Butterworth-Heinemann, 2002.
2. Carvalho T.P., Soares F.A.A.M.N., Vita R. et al. A systematic literature review of machine learning methods applied to predictive maintenance // Computers & Industrial Engineering. – 2019. – Vol. 137. – Art. 106024.

3. Breiman L. Random Forests // Machine Learning. – 2001. – Vol. 45, No. 1. – P. 5–32.
4. Friedman J.H. Greedy function approximation: a gradient boosting machine // The Annals of Statistics. – 2001. – Vol. 29, No. 5. – P. 1189–1232.
5. Pedregosa F. et al. Scikit-learn: Machine Learning in Python // Journal of Machine Learning Research. – 2011. – Vol. 12. – P. 2825–2830.
6. Matzka S. Explainable Artificial Intelligence for Predictive Maintenance Applications // Proc. 3rd Int. Conf. on Artificial Intelligence for Industries (AI4I). – 2020. – P. 69–74.
7. Saxena A., Goebel K. Turbofan Engine Degradation Simulation Data Set. – NASA Ames Prognostics Data Repository, 2008.