

AVTONOM IOT TUGUNLARIDA ENERGIYA HOLATI VA NOSOZLIK XAVFIGA MOS UCH REJIMLI DIAGNOSTIKA BOSHQARUVI

E.S. Babadjanov¹, O.K. Ataboyev¹, M.N. Jumaniyozov^{1*}

¹*Nukus davlat texnika universiteti, Nukus, O'zbekiston*

E-mail: elmurbes@gmail.com, muzrobjumaniyozov653@gmail.com

Annotatsiya. Avtonom IoT tugunlarida diagnostikani doimiy yuqori jadallikda bajarish nosozliklarni tez aniqlash imkonini beradi, biroq batareya energiyasini sezilarli sarflaydi. Ushbu tezisda batareya holati va nosozlik xavfini birgalikda hisobga olib, diagnostikani tejamkor, muvozanatli va kuchaytirilgan rejimlar orasida boshqarish yondashuvi ko'rib chiqildi. 100 ta 30 kunlik Monte-Karlo tajribasida adaptiv usul doimiy muvozanatli rejimga nisbatan energiya sarfini 56,2 % kamaytirdi, nosozliklarni aniqlash darajasi esa 0,697 ni tashkil etdi.

Kalit so'zlar: avtonom IoT tuguni, energiya holati, nosozlik xavfi, adaptiv diagnostika, edge hisoblash, Monte-Karlo.

Kirish

Uzoq hududlarda ishlaydigan IoT tugunlari ko'pincha cheklangan batareya zaxirasiga ega bo'lib, uzoq vaqt operator aralashuvisiz ishlashi kerak. Sensorlardan ma'lumot olish, mahalliy hisoblash, radioaloqa va qurilmaning texnik holatini tekshirish bir xil darajada energiya talab qilmaydi. Ayniqsa, diagnostikani tez-tez bajarish nosozliklarni erta aniqlashga yordam bersa-da, tugunning ishlash muddatini qisqartirishi mumkin. Diagnostika oralig'ini haddan tashqari uzaytirish esa qisqa muddatli yoki asta-sekin rivojlanayotgan nosozliklarning o'z vaqtida aniqlanmasligiga olib keladi.

Shu sababli diagnostika rejimini faqat batareya quvvatiga qarab emas, balki qurilmada kuzatilayotgan nosozlik xavfi bilan birgalikda tanlash maqsadga muvofiq. Edge hisoblash va TinyML yondashuvlari ma'lumotlarni qurilmaning o'zida tahlil qilish imkonini beradi, biroq mahalliy tahlilning o'zi ham energiya sarflaydi [1, 2]. Mazkur ishning maqsadi energiya holati va nosozlik xavfiga qarab diagnostika jadalligini avtomatik o'zgartiruvchi uch rejimli boshqaruv yondashuvini baholashdan iborat [3–6].

Taklif etilgan yondashuv

IoT tugunining joriy holatini baholashda batareya zaryadi $E(t)$, sensor holati $H_s(t)$, edge tugun holati $H_e(t)$, aloqa sifati $C(t)$, qurilma yuklamasi $L(t)$ va anomaliya ko'rsatkichi $A(t)$ hisobga olinadi. Ushbu ko'rsatkichlar yagona holat vektorida birlashtiriladi:

$$x(t) = [E(t), Hs(t), He(t), C(t), L(t), A(t)].$$

Sensor, hisoblash va aloqa qismlarida olingan haqiqiy qiymatlar kutilayotgan qiymatlar bilan solishtiriladi. Ular orasidagi farq $r_i(t)$ orqali ifodalanadi. Aloqa sifati paket yo'qolishi, qayta uzatish va signal holatini hisobga oluvchi $Q(t)$ ko'rsatkichi bilan to'ldiriladi. Umumiy xavf darajasi quyidagicha aniqlanadi:

$$R(t) = \sum w_i \cdot \min(1, |r_i(t)|/\tau_i) + w_q \cdot Q(t), \quad \sum w_i + w_q = 1.$$

$R(t)$ kichik bo'lganda M0 tejamkor rejimi tanlanadi: ma'lumot olish davri 10 minut bo'lib, EWMA va chegaraviy tekshiruvdan foydalaniladi hamda har olti namunada bitta paket uzatiladi. Xavf o'rta yoki noaniq bo'lsa, M1 muvozanatli rejimiga o'tiladi; bunda namuna davri 3 minut va uzatish har to'rt namunada amalga oshiriladi. Yuqori xavfda M2 kuchaytirilgan rejimi ishga tushib, namuna davri 1 minutgacha qisqaradi va batafsil sabab tekshiruvi bajariladi.

Rejimlarning shovqin yoki kichik o'zgarishlar sababli tez-tez almashib ketmasligi uchun gisterezis qo'llanadi. Yuqori rejimga o'tish chegarasi $\theta \uparrow$, avvalgi rejimga qaytish chegarasi $\theta \downarrow$ qilib belgilanadi va $\theta \uparrow > \theta \downarrow$ sharti bajariladi. Batareya kritik darajada kamayganda M0 rejimiga ustunlik beriladi, biroq xavf favqulodda darajaga yetsa, diagnostika kuchaytiriladi.

Tajriba va natijalar

Usul matematik model asosida 100 ta mustaqil Monte-Karlo tajribasida baholandi. Har bir tajriba IoT tugunining 30 kunlik ishlashini, ya'ni 43 200 ta bir daqiqalik vaqt qadamini qamrab oldi. Har bir tajribaga 30–180 minut davom etuvchi 24 ta nosozlik epizodi kiritildi. Adaptiv yondashuv doimiy yuqori, doimiy muvozanatli va doimiy past diagnostika rejimlari bilan bir xil boshlang'ich sharoitlarda taqqoslandi.

Doimiy muvozanatli rejimda 30 kunlik energiya sarfi 14904,0 mJ, nosozliklarni aniqlash darajasi $0,709 \pm 0,097$ va o'rtacha aniqlash kechikishi $14,4 \pm 3,9$ minutni tashkil etdi. Adaptiv usulda energiya sarfi $6520,6 \pm 652,0$ mJ gacha kamaydi, ya'ni 56,2 % energiya tejaldi. Bunda recall $0,697 \pm 0,102$ bo'lib, muvozanatli rejimdan atigi 0,012 ga past bo'ldi. Aniqlash kechikishi $21,2 \pm 4,4$ minutni tashkil etdi.

Adaptiv usul umumiy vaqtning 95,1 % ida M0, 1,6 % ida M1 va 3,3 % ida M2 rejimida ishladi. Natija energiya sarfini kamaytirishning asosiy manbai tugunni ko'p vaqt tejamkor rejimda ushlab turish, xavf oshgandagina diagnostikani kuchaytirish ekanini ko'rsatadi. Shu bilan birga, aniqlash kechikishining ortishi xavfsizlik talabi yuqori obyektlarda rejim chegaralarini ehtiyotkorlik bilan tanlash zarurligini ko'rsatadi.

Xulosa

Energiya holati va nosozlik xavfiga mos uch rejimli diagnostika boshqaruvi avtonom IoT tugunida energiya sarfi bilan nosozliklarni aniqlash o'rtasidagi muvozanatni boshqarish imkonini berdi. Imitatsion tajribada adaptiv usul doimiy muvozanatli rejimga nisbatan energiyani 56,2 % tejadi va recall ko'rsatkichini 0,697

darajada saqladi. Ushbu natijalar matematik model asosida olingan bo'lib, keyingi bosqichda ESP32 yoki STM32 asosidagi prototipda energiya sarfi va diagnostika ko'rsatkichlarini real o'lchash talab etiladi.

Foydalanilgan adabiyotlar:

1. Shi W., Cao J., Zhang Q., Li Y., Xu L. Edge Computing: Vision and Challenges. IEEE Internet of Things Journal. 2016;3(5):637–646. <https://doi.org/10.1109/JIOT.2016.2579198>
2. Abadade Y. et al. A Comprehensive Survey on TinyML. IEEE Access. 2023;11:96892–96922. <https://doi.org/10.1109/ACCESS.2023.3294111>
3. Giordano M. et al. Energy-Aware Adaptive Sampling for Self-Sustainability in Resource-Constrained IoT Devices. ENSys 2023. pp. 65–71. <https://doi.org/10.1145/3628353.3628545>
4. Heo S., Mayer P., Magno M. Predictive Energy-Aware Adaptive Sampling with Deep Reinforcement Learning. IEEE ICECS 2022. <https://doi.org/10.1109/ICECS202256217.2022.9971120>
5. Ait Aoudia F., Gautier M., Berder O. RLMan: An Energy Manager Based on Reinforcement Learning for Energy Harvesting Wireless Sensor Networks. IEEE Transactions on Green Communications and Networking. 2018;2(2):408–417. <https://doi.org/10.1109/TGCN.2018.2801725>
6. Srbinovski B., Magno M., O'Flynn B., Pakrashi V., Popovici E. Energy Aware Adaptive Sampling Algorithm for Energy Harvesting Wireless Sensor Networks. IEEE SAS 2015. <https://doi.org/10.1109/SAS.2015.7133582>