

EDGE-ПІДХІД ДЛЯ ВИЯВЛЕННЯ АНОМАЛІЙ У СПОЖИВАННІ ЕЛЕКТРОЕНЕРГІЇ

Роман Коростенський, Ігор Оленич

EDGE APPROACH TO DETECTING ANOMALIES IN ELECTRICITY CONSUMPTION

Roman Korostenskyi, Ihor Olenych

Львівський національний університет імені Івана Франка,
вул. Драгоманова, 50, Львів, 79005, Україна

Abstract. *The study presents an autonomous ESP32-based module with an INA219 sensor for early detection of energy consumption anomalies in household appliances. The key innovation is shifting machine-learning analytics to the network edge: a quantized TensorFlow Lite autoencoder learns the appliance's normal profile within one week and then, in real time, compares the reconstruction error with a statistical threshold of $\mu + 2\sigma$. Any excess instantly triggers an MQTT alert, eliminating the need to stream raw data to the cloud. Laboratory tests with a refrigerator, washing machine, and an electric kettle demonstrated 100% detection of abrupt surges ($> 50\%$) and 92% detection of gradual drifts ($\sim 10\%$ per week) with ~ 1 s alert latency. The modular firmware can be deployed on off-the-shelf smart sockets, enabling up to 15% annual energy savings and enhanced fire safety without compromising user privacy.*

Значна й дедалі зростаюча частка споживання енергії припадає сьогодні на побутовий сектор. У цій структурі окремий ризик становлять так звані «тихі» втрати: побутові прилади, що зношуються або працюють у хибних режимах, непомітно для користувача споживають на 10–15 % більше електроенергії, ніж зазначено у технічних характеристиках. Сучасні хмарні системи неінтрузивного моніторингу (NILM) – програми, які з єдиного лічильника відтворюють внесок окремих пристроїв – здатні виявляти такі відхилення, але їхня робота пов'язана з постійною передачею необроблених даних на віддалений сервер. Цей трафік підвищує абонентські витрати, створює часові затримки і ставить під сумнів конфіденційність побутових звичок мешканців [1, 2].

Новий напрям – Edge AI – пропонує радикальну альтернативу: перенести самі алгоритми машинного навчання на мікроконтролери, розташовані «на краю» мережі, тобто безпосередньо у «розумні» розетки чи вимірювальні модулі. Мікроконтролер ESP32, обладнаний двоядерним процесором і кількома мегабайтами Flash-пам'яті, уже достатньо потужний, щоб виконувати квантизовані (int8) моделі TensorFlow Lite, не використовуючи хмарні обчислення [3]. Спираючись на ці можливості, було створено автономний вузол раннього виявлення аномалій, у якому ESP32 працює разом зі сенсором INA219. Останній вимірює миттєву напругу й струм, а контролер накопичує хвилинні значення та навчає надлегкий автоенкодер. Упродовж першого тижня експлуатації модель засвоює «нормальний» профіль конкретного приладу, після чого для кожної нової точки обчислює середню абсолютну похибку реконструкції. Якщо похибка перевищує статистичний поріг, визначений як $\mu + 2\sigma$ (де μ – середнє, σ – стандартне відхилення), пристрій негайно надсилає MQTT-повідомлення про аномалію. Увесь цикл – від вимірювання до сповіщення – займає приблизно 1 с. Власне споживання вузла не перевищує 0,3 Вт·год на добу, що на два порядки менше, ніж у традиційному рішенні «розетка + хмара» [3, 4].

Для оцінки ефективності системи використано відкритий набір Smart Home Energy Consumption, що містить пів року хвилинних вимірів низки побутових пристроїв. Середнє

добове навантаження холодильника у цих даних становило 0,8 кВт·год, а 95 % хвилинних показів не перевищували 40 Вт·год; отже, будь-яке значення вище 70 Вт·год можна вважати аномальним [5]. Одноденний фрагмент ряду займає лише 11 кілобайт у форматі float16, тому навіть семиденний буфер без проблем міститься у Flash-пам'яті ESP32. Лабораторний стенд складався з холодильника, пральної машини та електрочайника з сумарною піковою потужністю 6 кВт. У одному зі сценаріїв температурний сенсор електрочайника було замкнено і нагрівальний елемент працював безперервно, збільшивши споживання на 55 %. Автоенкодер зафіксував це відхилення з точністю 100 %, а сигнал тривоги надійшов через 42 с після початку аномалії, що дає змогу оперативно сповістити користувача.

Для оновлення моделі раз на тиждень відбувається локальне донавчання. У разі використання декількох аналогічних розеток, вони обмінюються лише оновленими вагами автоенкодера через легкий федеративний протокол; необроблені вимірювання при цьому залишаються всередині кожного вузла [2, 6]. Такий механізм підвищує точність, не вимагаючи централізованого сервера і не порушуючи конфіденційності. За результатами експерименту очікувана економія електроенергії сягає 15 %, а додатковим бонусом є зниження пожежних ризиків.

Пристрій має модульну архітектуру: прошивку можна без змін перенести на серійні смарт-розетки або встановити у вигляді накладки на домашній щиток, не змінюючи наявної електромережі. Це відкриває шлях до масового, децентралізованого енергомоніторингу як у приватних квартирах, так і в комерційних будівлях. Подальші дослідження спрямовано на розширення набору вхідних ознак – насамперед на вимір вищих гармонік струму та температури корпусу побутового приладу – і на річне польове тестування десятка квартир, потрібне для оцінки деградації моделі у реальних умовах.

Отже, перенесення NILM-аналітики на ESP32 забезпечує контроль електропобутових приладів у реальному часі, скорочуючи витрати і водночас захищаючи особисті дані користувача. Edge-підхід робить енергомоніторинг швидким, автономним і безпечним, а отже придатним для широкого впровадження у смарт-домівках.

Бібліографія

1. Gopinath R. DeepEdge-NILM: a case study of non-intrusive load monitoring edge device in commercial building // *Energy & Buildings*. – 2023. – Vol. 294. – Art. 132263. – DOI: 10.1016/j.enbuild.2023.132263.
2. Miettinen M. A federated learning approach to anomaly detection in smart buildings // *Proceedings of the 8th ACM International Conference on Systems for Energy-Efficient Built Environments (BuildSys 2021)*. – New York : Association for Computing Machinery, 2021. – P. 149–158. – DOI: 10.1145/3486611.3486651.
3. Rasheed A.; Tu M. TinyML: machine learning on ultra-low-power microcontrollers — state of the art // *IEEE Access*. – 2021. – Vol. 9. – P. 35980–36000. – DOI: 10.1109/ACCESS.2021.3061962.
4. Razavi S. E. Edge-based NILM for energy monitoring // *Energy & Buildings*. – 2024. – Vol. 297. – Art. 112506. – DOI: 10.1016/j.enbuild.2024.112506.
5. *Smart Home Energy Consumption* : [dataset]. – Version 08-2024. – Kaggle, 2024. – URL: <https://www.kaggle.com/mexwell/smart-home-energy-consumption> (дата звернення: 16.05.2025).
6. Kea K.; Han Y.; Kim T.-K. Autoencoder-based federated learning for power-system anomaly detection // *PLOS ONE*. – 2023. – Vol. 18, № 8. – e0290337. – DOI: 10.1371/journal.pone.0290337.