

**ВИЯВЛЕННЯ АНОМАЛЬНИХ ДАНИХ У ПРОЦЕСІ
КАЛІБРУВАННЯ ВИМІРЮВАЛЬНОЇ ТЕХНІКИ ЗА ДОПОМОГОЮ
АВТОЕНКОДЕРІВ**

Довгополий С.О.

e-mail: serhii.dovhopolyi@nure.ua

Науковий керівник – к.т.н., доц. Запорожець О.В.

Харківський національний університет радіоелектроніки, каф. ІВТ
м. Харків, Україна

The article considers the problem of automated detection of anomalous values in data arrays generated during the calibration of measuring instruments. A method based on neural networks of the “autoencoder” type is proposed for effective filtering of outliers in measurement data. The theoretical foundations of the functioning of autoencoders, their architectural features, and training algorithms are considered. The nature of the occurrence of anomalies in the calibration process is analyzed in detail, their types are classified, and statistical methods of preliminary data processing are described.

У реальних умовах дані, отримані в процесі калібрування, неминуче містять аномальні значення – викиди, що суттєво спотворюють результати оброблення та знижують точність побудованих калібрувальних характеристик. Під викидом у метрологічній практиці розуміють результат вимірювання або елемент набору даних, який істотно відрізняється від інших значень вибірки. Формально, у статистичному сенсі, значення x_i вважається викидом, якщо воно виходить за межі допустимого інтервалу, що визначається характеристиками розподілу генеральної сукупності.

Однак таке скалярне визначення є надто спрощеним для реальних вимірювальних систем, де важливо враховувати не лише окремі значення параметрів, а й взаємозв'язки між ними.

За механізмом формування аномалії в калібрувальних даних доцільно класифікувати на три основних типи: точкові аномалії, контекстуальні аномалії та колективні аномалії.

Класичні підходи до виявлення викидів базуються на параметричних і непараметричних статистичних методах. До параметричних належать критерії Граббса, Діксона, Романовського, а також підходи, засновані на аналізі залишків регресійних моделей. Непараметричні методи включають, зокрема, метод міжквартильного розмаху (IQR), критерій медіани абсолютного відхилення (MAD) та підходи, засновані на оцінюванні густини розподілу. Попри простоту та інтерпретованість, зазначені методи мають низку обмежень: вони переважно застосовуються до одновимірних або низьковимірних даних, часто потребують припущень щодо форми розподілу та можуть бути чутливими до ефекту «маскування», коли один викид приховує наявність іншого.

Автоенкодер – це клас несупервізованих штучних нейронних мереж, архітектура яких складається з двох функціональних блоків: енкодера та декодера. Енкодер виконує відображення вхідного вектора $x \in R^n$ у латентний простір меншої розмірності:

$$z = f(x), \quad z \in R^m, \quad m < n.$$

Декодер здійснює зворотнє відображення латентного представлення у реконструйований вектор:

$$\hat{x} = g(z), \quad \hat{x} \approx x.$$

Процес навчання автоенкодера полягає у мінімізації функції втрат реконструкції $L(x, \hat{x})$, яка найчастіше визначається як середньоквадратична похибка (MSE)

$$L(x, \hat{x}) = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2.$$

Таким чином, мережа навчається виділяти найбільш інформативні ознаки вхідних даних, формуючи компактне латентне представлення та відкидаючи надлишкову інформацію і шум.

З точки зору виявлення аномалій ключовим є те, що автоенкодер навчається виключно на нормальних (неаномальних) даних і, отже, стає «спеціалізованим» саме для їх реконструкції. Коли на вхід мережі надходить аномальне спостереження, воно не відповідає вивченому розподілу нормальних даних, і мережа не може якісно відновити його – значення похибки реконструкції суттєво зростає. Таким чином, порогове значення похибки реконструкції ε^* використовується як критерій розмежування нормальних та аномальних спостережень. Класифікація здійснюється за правилом:

$$L(x, \hat{x}) > \varepsilon^* \Rightarrow x \text{ вважається аномальним.}$$

Відповідно,

$$L(x, \hat{x}) \leq \varepsilon^* \Rightarrow x \text{ належить до нормальних спостережень.}$$

Архітектура автоенкодера може варіюватись залежно від природи вхідних даних. Для табличних часових рядів вимірювань, характерних для задач калібрування, використовують конволюційні автоенкодери (CAE), рекурентні автоенкодери на основі LSTM або GRU шарів (для даних із часовими залежностями), а також трансформерні автоенкодери. Особливого значення набули варіаційні автоенкодери (VAE – Variational Autoencoder), які навчаються не детермінованому латентному вектору, а параметрам його розподілу – середньому значенню μ та дисперсії σ^2 . Такий підхід забезпечує більш стійкий та «гладкий» латентний простір, а аномальність спостереження можна оцінити через ймовірність отримання відповідного латентного коду згідно з вивченим розподілом.

Важливим аспектом практичного застосування є правильний вибір ступеня стиснення латентного простору. Занадто великий латентний простір призводить до того, що мережа навчається «пам'ятати» навіть аномальні патерни і реконструює їх з невеликою похибкою – явище відоме

як «надмірна потужність». Занадто малий латентний простір, навпаки, знижує здатність мережі точно реконструювати навіть нормальні складні патерни, що збільшує хибно-позитивні спрацьовування детектора аномалій. Оптимальний розмір латентного простору визначається емпірично або шляхом аналізу інформаційної ємності даних методами зниження розмірності (РСА).

Присутність аномальних точок безпосередньо впливає на якість апроксимації: навіть одиничний викид може суттєво змінити нахил лінії регресії, ввести систематичну похибку або збільшити невизначеність калібрування.

На першому етапі виконується попереднє оброблення даних: нормалізація або стандартизація значень з метою приведення всіх вхідних ознак до єдиного масштабу, усунення детермінованого тренду для часових рядів, а також вікна вибірки для отримання послідовностей заданої довжини у разі використання рекурентних архітектур. На другому етапі відбувається навчання автоенкодера на «чистій» підвибірці даних – або вручну відібраний, або визначений за допомогою консервативних статистичних тестів.

Третій етап полягає у визначенні порогу аномальності ε^* . Критичним тут є вибір стратегії: статистичний поріг (наприклад, $\mu_{err} + 3\sigma_{err}$, де μ_{err} та σ_{err} – середнє і стандартне відхилення похибки реконструкції на тренувальній вибірці), поріг, що максимізує F1-метрику на валідаційній вибірці з розміченими аномаліями, або адаптивний поріг, що змінюється залежно від поточного стану системи. На четвертому, фінальному, етапі всі спостереження з похибкою реконструкції, що перевищує встановлений поріг, позначаються як аномальні й виключаються з подальшого оброблення або замінюються інтерпольованими значеннями.

Автоенкодери являють собою дієвий і гнучкий інструмент для виявлення аномальних даних у процесі калібрування вимірювальної техніки. Їх ключовою перевагою є здатність до несупервізованого навчання нормативних патернів у багатовимірних даних без необхідності ручного розмічення аномалій.

Список використаних джерел:

1. Chandola V., Banerjee A., Kumar V. Anomaly Detection: A Survey. ACM Computing Surveys. 2009. Vol. 41, No. 3. P. 1–58.
2. Hinton G. E., Salakhutdinov R. R. Reducing the Dimensionality of Data with Neural Networks. Science. 2006. Vol. 313. P. 504–507.
3. Kingma D. P., Welling M. Auto-Encoding Variational Bayes. Proceedings of ICLR. 2014.