

где  $x_i$  – значение  $i$ -го входа нейрона;  $w_i$  – вес  $i$ -й связи;  $n$  – число входов нейрона;  $f$  – функция активации (в данном примере используется сигмоида).

В результате обучения был получен классификатор на нейросетевом принципе, использование которого позволило безошибочно разграничивать режимы короткого замыкания на различных вводах.

#### Литература

1. Дементий Ю. А., Маслов А. Н. Нейросетевой классификатор режимов работы энергообъекта и оценка его распознающей способности при различном количестве прецедентов // Вестник Чувашского университета. 2021. № 3. С. 45–52.

2. Дементий Ю. А., Маслов А. Н., Николаев К. П. Нейросетевая классификация режимов // Современные тенденции развития цифровых систем релейной защиты и автоматики: материалы науч.-техн. конф. молодых специалистов форума «РЕЛАВЭКСПО-2021». Чебоксары: Изд-во Чуваш. ун-та, 2021. С. 147–152.

3. Круглов В. В., Борисов В. В. Искусственные нейронные сети. Теория и практика. М.: Горячая линия–Телеком, 2001. 382 с.

Шорников Е.В.  
(Чебоксары, ООО «Релематика»)

### ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА ВЫЯВЛЕНИЯ АНОМАЛЬНЫХ РЕЖИМОВ РАБОТЫ ЭНЕРГОСИСТЕМЫ\*

В связи с всеобщей цифровизацией энергетики, выражающейся в повсеместном внедрении стандарта МЭК 61850, появляется возможность масштабного сбора и хранения данных о работе энергосистемы. Неполное использование полученной информации может привести к упущенной прибыли, вызванной

---

\* Работа выполнена в рамках гранта фонда содействия инновациям в научно-технической сфере договор №17325ГУ/2022 от 14.04.2022.

простое оборудования, недоотдачей электроэнергии и дорогостоящим ремонтом.

Решением данной проблемы выступает интеллектуальная система выявления аномальных режимов работы энергосистемы. Система представляет собой программный продукт, способный определить аномальный режим работы энергосистемы, а также найти её «слабые места» на основании текущих и прошлых измерений параметров. Такую программу возможно рассмотреть как функциональный блок (рис. 1), интегрируемый в существующее программное обеспечение (ПО).



Рис. 1. Функциональный блок выявления аномалий

Данная система будет востребована в первую очередь в диспетчерских управлениях, а также в компаниях занимающихся эксплуатацией энергосистем, разработкой автоматизированных систем управления (АСУ) и оперативно-информационных комплексов. Система имеет возможность оценки режима работы энергосистемы не только на основании отдельных параметров и их выходов за допустимые границы, но и на основании их комбинаций в случае, когда все отдельно взятые параметры лежат в допустимых пределах.

Для выявления аномальных режимов используются методы машинного обучения, основанные на анализе плотности расположения прецедентов в пространстве, образованном наблюдаемыми величинами (например, амплитудами токов, напряжений, их фазами и т.д.). Аномальные (не происходившие ранее или маловероятные) режимы изначально считаются потенциально опасными до тех пор, пока не будет получено подтверждение

того, что они не приводили к аварийной ситуации. Поиск «слабых мест» энергосистемы производится путем выявления элементов энергосистемы, вносящих наибольший вклад в результирующую величину риска.

Для своей работы система не использует имитационную модель объекта, вместо нее строится статистическая модель на основе исторических наблюдений, после этого определяется, с какой вероятностью наблюдаемое состояние соответствует нормальному. Системе требуется информация об энергосистеме, для этого применяется прецедентный подход, предполагающий извлечение информации из истории наблюдения за объектом (энергосистемой). Системе необходимо решить задачу обработки большого количества параметров в совокупности (многомерный анализ), в противовес классическому анализу отдельных параметров. Для этого в системе используются методы искусственного интеллекта и машинного обучения [1] вследствие того, что они доказали свою применимость в задачах высокой размерности и в задачах оценки риска.

Методами, подходящими для решения подобной задачи [3], являются: метод опорных векторов с одним классом (One-Class SVM) и метод изолирующего леса (Isolation Forest). Метод One-Class SVM заключается в поиске такой гиперплоскости, которая способна линейно разделить выборку данных на классы «+1» и «-1», так чтобы элементы каждого класса находились на наибольшем расстоянии от разделяющей плоскости (рис. 2). Для задания гиперплоскости используется квадратическая функция [4]

$$\min_{\omega, \xi_i} \frac{1}{2} \|\omega\|^2 + \frac{1}{\nu n} \sum_{i=1}^n \xi_i,$$

при условии

$$\begin{aligned} (\omega \Phi(x_i)) &\geq \xi_i \rightarrow \forall i = 1, 2, \dots, n \\ \xi_i &\geq 0 \rightarrow \forall i = 1, 2, \dots, n \end{aligned}$$

где  $\nu \in (0, 1)$  – параметр, регулирующий долю выбросов в выборке;  $\xi_i$  – ослабляющие переменные для преобразования неравенства в равенство;  $\omega$  – коэффициент регуляризации.

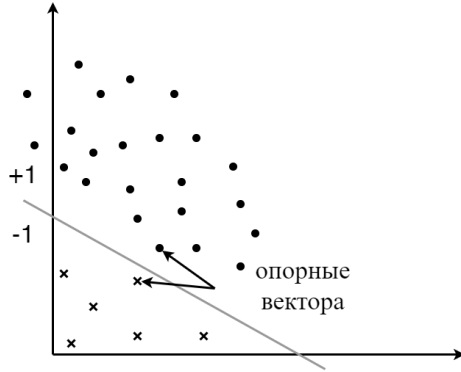


Рис. 2. Разделение метода One Class SVM

При этом существует обобщение для случая, когда выборка не является линейно разделимой. Подход заключается в предположении, что существует пространство большей размерности, при переходе в которое выборка станет линейно разделимой. Такое пространство будет являться спрямляющим

Метод Isolation Forest [2] заключается в построении случайных бинарных решающих деревьев [5] (рис. 3). Корнем бинарного дерева является все признаковое пространство. В каждом узле выбирается случайный признак и порог разбиения, полученный из равномерного распределения в диапазоне значений выбранного признака.

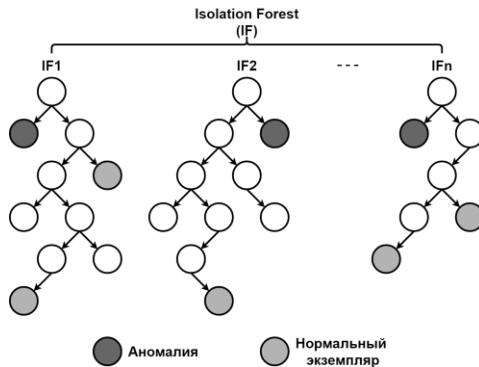


Рис. 3. Работа метода Isolation Forest

Поиск аномалий по методу Isolation Forest состоит из двух этапов: построение бинарных деревьев с помощью обучающей выборки; оценка аномалий на обученной модели при помощи тестовой выборки. Оценка аномалий выполняется следующим алгоритмом:

$$c(m) = \begin{cases} 2H(m-1) - \frac{2(m-1)}{n}, & m > 2, \\ 1, & m = 2, \\ 0, & m < 2, \end{cases}$$

$$H(i) = \ln(i) + \gamma,$$

где  $n$  – размер тестовой выборки;  $m$  – количество внешних узлов;  $m-1$  – количество внутренних узлов;  $2(m-1)$  – общее количество узлов Isolation Forest;  $\gamma$  – постоянная Эйлера.

$$s(x, m) = 2^{-\frac{E(h(x))}{c(m)}},$$

где  $E(h(x))$  – среднее значение глубины корня построенных деревьев, для любого экземпляра: если  $s \approx 1$  – аномалия; если  $s < 0,5$  – не аномалия; если для всей выборки  $s \approx 0,5$  – в выборке нет аномалий.

Система имеет возможность масштабирования и модернизации за счет включения новых параметров и информации о системе без необходимости изменения кода программного продукта вследствие универсальности используемых алгоритмов.

Система предъявляет требования к квалификации конечного пользователя. Для работы с системой пользователь должен понимать основные принципы работы элементов энергосистемы и энергосистемы в целом, уметь работать с электрическими схемами, понимать, как формируются схемы замещения элементов энергосистем и как определяются их параметры. Необходимость данных требований обусловлена тем, что именно конечный пользователь является лицом, принимающим решения.

#### Литература

1. *Asuncion A., Newman D.* UCI machine learning repository, 2007.

2. *Liu Fei Tony, Kai Ming Ting, Zhi-Hua Zhou*. Isolation forest. Data Mining, 2008. ICDM'08. Eighth IEEE International Conference on. IEEE, 2008.

3. *Abe N, Zadrozny B, Langford J*. Outlier detection by active learning. In Proceedings of the 12th ACM SIGKDD international conference on Knowledge discovery and data mining, pages 504–509. ACM Press, 2006.

4. Support vector method for novelty detection / B Schölkopf [et al.] // Advances in neural information processing systems, 1999.

5. *Shi T, Horvath S*. Unsupervised learning with random forest predictors. Journal of Computational and Graphical Statistics, 15(1):118–138, March 2006.

Дементий Ю.А., Николаев К.П.  
(Чебоксары, ООО «Релематика»)

## МЕТОД ПОВЫШЕНИЯ ИНФОРМАТИВНОСТИ ОБУЧАЮЩЕЙ ВЫБОРКИ КЛАССИФИКАТОРА РЕЖИМОВ РАБОТЫ ОБЪЕКТА

Одной из важнейших задач релейной защиты является задача разграничения режимов работы объекта. Разграничению подлежат режимы, в которых защита должна срабатывать – контролируемые режимы ( $\alpha$ -режимы) и режимы, в которых срабатывание запрещено – альтернативные режимы ( $\beta$ -режимы) [1]. Релейная защита (РЗ), в свою очередь, представляет собой классификатор, который принимает решение об отключении.

В статье [2] обсуждалось применение концепции активного обучения для построения классификаторов режимов работы объекта. Была показана зависимость распознающей способности классификатора от информативности обучающей выборки. Метод, представленный в данном докладе, направлен на составление выборки прецедентов, обладающей максимально возможной информативностью.

В информационной теории РЗ [1] режим работы объекта описывается вектором наблюдаемых величин  $\mathbf{v}$ , который полу-