

### СЕКЦИЯ 3. ПРИБОРОСТРОЕНИЕ И РОБОТОТЕХНИКА

УДК 621.865.8, 004.896

#### ПРИМЕНЕНИЕ АЛГОРИТМОВ ARL ДЛЯ АНАЛИЗА ДАННЫХ И ДИАГНОСТИКИ РОБОТОТЕХНИЧЕСКИХ КОМПЛЕКСОВ

Вершкович Д. Ю., студент,

Пивень Н. Д., студент

Белорусский национальный технический университет

Минск, Республика Беларусь

Научный руководитель: ассистент Скуратова Д. А.

**Аннотация.** В данной статье будет рассмотрено применение Association Rule Learning (ARL) для решения задач диагностики и прогнозирования отказов в робототехнических комплексах – (РТК).

Технология ARL, или обучение ассоциативным правилам, представляет собой метод анализа данных для поиска частных взаимосвязей между событиями. Ее суть заключается в выявлении правил типа «если, то», которые связываются по статистическим метрикам, таким как Support, Confidence, Lift. Этот подход можно применить для повышения интеллекта робототехнических комплексов. Вместо того, чтобы следовать жестким алгоритмам, робот, получая данные с датчиков и анализируя их используя ARL. Это позволяет выявлять нелинейные, комбинаторные предвестники отказов, которые не улавливаются пороговыми или регрессионными моделями. Также стоит отметить, что правила остаются интерпретируемыми – это важно для принятия решений инженерами.

Математическая модель ARL для диагностики РТК можно представить следующим образом. Сначала идет формализации данных и пространства признаков. Предположим, у нас есть множество всех дискредитируемых параметров системы  $I$ .

$$I = \{i_1; i_2; \dots; i_m\},$$

где каждый элемент  $i_k$  представляет собой категориальное значение, например, температура\_двигателя = «высокая», уровень\_вибраций = «критический», скорость = «низкая» и т. д. А  $m$  – количество параметров.

Далее идет представление состояния системы. Состояние РТК в определенный момент времени представляется как транзакция  $T$ , которая является подмножеством всех возможных параметров ( $T \subseteq I$ ). Полный набор данных за период наблюдений представляет собой базу транзакций  $D$ , где  $n$  – общее количество наблюдений.

$$D = \{T_1; T_2; \dots; T_n\}.$$

Следующим этапом будет составление ассоциативных правил вида

$$X \Rightarrow Y$$

где  $X$  – условие,  $Y$  – следствие. После для количественной оценки надежности правил вводятся три ключевые метрики:

– Поддержка (Support):

$$supp(X \Rightarrow Y) = \frac{count(X \cup Y)}{|D|}.$$

– Достоверность (Confidence):

$$conf(X \Rightarrow Y) = \frac{supp(X \cup Y)}{supp(X)}.$$

– Лифт (Lift):

$$lift(X \Rightarrow Y) = \frac{supp(X \cup Y)}{supp(X) * supp(Y)}.$$

Вычислив метрики реализуем решение задачи по нахождению всех правил  $X \Rightarrow Y$ , для которых выполняются условия:

$$\begin{aligned}supp(X \Rightarrow Y) &> supp_{min}; \\ conf(X \Rightarrow Y) &> conf_{min}.\end{aligned}$$

Цель – найти множество всех значимых и надежных правил  $R$ .

$$R = \{X \Rightarrow Y \mid supp(X \cup Y) \geq supp_{min}, conf(X \cup Y) \geq conf_{min}\}.$$

Функция прогнозирования отказа для нового состояния системы, представленного транзакцией  $T_{new}$ , может быть описана так:

$$P(T_{new}) = \{Y \mid (X \Rightarrow Y) \in R, X \subseteq T_{new}, Y \cap T_{new} = \emptyset\},$$

где  $P(T_{new})$  – множество всех потенциальных отказов, для которых в текущем состоянии  $T_{new}$  выполнены условия соответствующих ассоциативных правил из модели.

Алгоритм основан на методе ассоциативных правил (ARL, например – Apriori), адаптированном к промышленным данным. Он преобразует разнородные потоки (от датчиков, ЧПУ, MES) в транзакции – законченные эпизоды (цикл изготовления, окно перед сбоем), дискретизирует непрерывные параметры по технологическим порогам и кодирует их в бинарные признаки. Далее выявляются устойчивые правила вида «набор признаков  $\rightarrow$  инцидент» с контролем поддержки, достоверности и lift. Актуализация правил происходит периодически на накопленных данных; срабатывание antecedenta в реальном времени инициирует прогнозную диагностику.

Вывод. Предложенный подход обеспечивает переход от реактивного к предиктивному обслуживанию робототехнических систем, повышая надежность и снижая риски внезапных простоев. Прототип на  $R$  подтверждает его работоспособность; архитектура сбора данных (OPC UA  $\rightarrow$  Kafka/Flink  $\rightarrow$  хранилище) гарантирует масштабируемость и соответствие промышленным стандартам.

#### Список использованных источников

1. Agrawal, R. Mining Association Rules Between Sets of Items in Large Databases / R. Agrawal, T. Imieliński, A. Swami // Proceedings of the 1993 ACM SIGMOD International Conference on Management of Data. – Washington, D.C., 1993. – P. 207–216.

2. Han, J. Data Mining: Concepts and Techniques / J. Han, M. Kamber, J. Pei. – 3rd ed. – Morgan Kaufmann, 2011. – 702 p.

3. IEC 62541-1:2020 OPC Unified Architecture. – Part 1: Overview and Concepts. – Geneva: IEC, 2020.