

ПРИМЕНЕНИЕ ПОТОКОВОЙ КЛАСТЕРИЗАЦИИ ДЛЯ ИДЕНТИФИКАЦИИ ГИБРИДНЫХ ТЕМПОРАЛЬНЫХ АВТОМАТОВ НА АНАЛОГОВЫХ ДАННЫХ ПОТ*

Ключевые слова: промышленный интернет вещей, киберфизические производственные системы, выявление аномалий, гибридный темпоральный автомат, идентификация систем, потоковая кластеризация.

Введение

Industrial Internet of Things (IIoT) предоставляет систему технологий, которая расширяет возможности промышленной автоматизации за счет использования растущего набора сенсоров, инструментов, вычислительных узлов и сетевой инфраструктуры [1, 2]. Центральное место в IIoT занимает технология киберфизических производственных систем (Cyber-Physical Production Systems — CPPS), в рамках которой решаются задачи управления, диагностики и оптимизации в производственных системах нового поколения [3, 4]. CPPS ставит целью — интегрировать динамику физического процесса с динамикой информационно-программной составляющей, которая в свою очередь обеспечивает средства абстракции, моделирования, синтеза и анализа для физической системы [5]. В этом контексте задача динамического моделирования процессов IIoT обретает особую значимость. Основные же трудности в большинстве приложений связаны с представлением временных признаков процесса [6, 7], а также с идентификацией модели из наблюдений системы [8].

В рамках парадигмы темпоральных автоматов (ТА), предложенной в [9], имеется удобный формализм для моделирования CPPS, а также методы идентификации автомата для полностью наблюдаемых дискретных систем [10]. Модель гибридного темпорального автомата (Hybrid Timed Automata — HTA) [11] специализирована для применения в условиях IIoT, и имеет успешные практические приложения [12–15]. Однако для систем с непрерывной динамикой в отсутствие дискретных событий эффективность HTA оказывается низкой [16, 17]. Так, в [16] качество выявления аномалий в аналоговых данных CPPS не превышает 30,8 %, что недостаточно для внедрения HTA на практике, а более высокие показатели получены лишь для специально смоделированных аномалий [18].

Модель HTA дискретная, поэтому главным ограничением ее использования в задачах IIoT и CPPS остается отсутствие эффективных методов выявления дискретных событий в непрерывных временных рядах наблюдений аналогового процесса [19, 16]. Здесь рассматривается возможность снять это ограничение за счет применения инкрементного модель-ориентированного алгоритма кластеризации (IMCF) [20].

* Работа выполнена благодаря проекту IMPROVE, который финансировался программой исследований и инноваций Европейского Союза «Horizon 2020» и предоставил открытые данные для исследования новейших методов диагностики в CPPS.

Методология

Поскольку модели класса ТА дискретны и не могут применяться непосредственно к наблюдениям непрерывного процесса ПоТ, в таких случаях приложения ТА [16–18] строятся по общей схеме, показанной на рис. 1. В ней потоковые данные ПоТ подвергаются предобработке и классификации для перехода от аналоговых наблюдений к дискретному набору категорий или классов наблюдений. Известны применения в качестве классификатора самоорганизующихся карт (SOM) [16, 17] и глубоких сетей доверия (DBN) [18], а предобработка обычно заключается в снижении размерности.

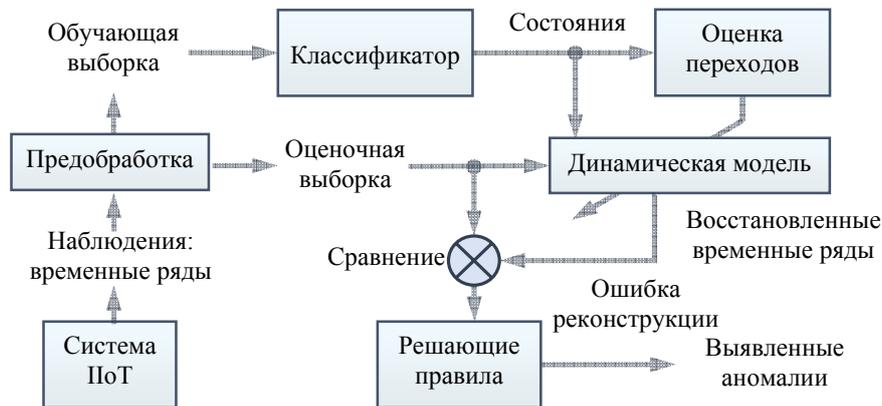


Рис. 1

ТА здесь представляет динамическую модель системы. Автомат обучают без учителя на временных рядах наблюдений физической системы, в результате он формирует пространственно-временные признаки наблюдаемого процесса. Полученная модель обладает внутренней динамикой, т.е. может выполняться параллельно с наблюдаемым физическим процессом. Сопоставление этих двух процессов дает основу для решения задач управления, мониторинга и выявления аномалий.

В задаче выявления аномалий автомат обучают лишь на примерах нормальной работы системы и затем применяют к новым временным рядам наблюдений, которые могут содержать аномальное поведение. Предполагается, что способность автомата описывать аномальные наблюдения существенно ниже, поскольку аномалии отсутствовали в обучающей выборке. Это может выражаться как неспособность модели обработать такие наблюдения, либо как скачок ошибки предсказания наблюдений. Таким образом, схема на рис. 1 позволяет в реальном времени обнаружить аномалии и локализовать их с точностью до одного шага наблюдений. Эффективность при этом определяется величиной статистического различия между откликами модели на нормальные и аномальные наблюдения. Именно достижение хорошего разделения представляет основную проблему на практике [16].

Здесь выдвинута гипотеза, что данная проблема возникает из-за низкой информативности состояний и переходов, выявленных с помощью SOM и DBN, для идентификации ТА. Для ее преодоления предложен более эффективный метод построения классификатора на основе потокового алгоритма кластеризации.

Требования к идентификации модели

В задачах ПоТ и CPPS как динамическая модель (ТА), так и классификатор должны формироваться путем обучения на временных рядах наблюдений физической системы, а на алгоритм обучения накладываются следующие требования [21, 22, 19]:

1) алгоритм должен работать в режиме онлайн, т.е. на потоковых данных, которые обрабатываются в один проход;

2) обучение должно использовать лишь положительные примеры, т.е. наблюдения нормального режима работы системы, поскольку множество возможных аномальных ситуаций обычно априори неизвестно;

3) обучение должно быть пассивным, так как в большинстве случаев недопустимо оказывать произвольные влияния на работающую систему для исследования ее динамики;

4) входными данными должны быть аналоговые наблюдения непрерывного процесса; т.е. идентификация НТА должна выполняться в отсутствие дискретных событий и независимо от шага дискретизации наблюдений.

Формализм НТА отвечает первым трем требованиям, в то время как требование 4) во всех существующих исследованиях достигается за счет дополнительной предобработки данных.

Модели и алгоритмы

А. Гибридный темпоральный автомат (НТА). Темпоральный автомат — это конечный автомат, в котором каждый переход между состояниями имеет таймер и временное ограничение (обычно в виде интервала, в пределах которого переход доступен) [9]. За счет этого автомат способен идентифицировать дискретное поведение системы. НТА [11–13] адаптированы для использования аналоговых данных (требование 4), однако способны представить непрерывный процесс лишь в пределах дискретных режимов при условии, что переходы между состояниями нарушают непрерывность. Насколько известно автору, единственная модель НТА, поддерживающая пассивное онлайн-обучение на положительных примерах (требования 1)–3)), предложена в [14, 19] под названием State-based Timed Automaton (STA). Именно формализм STA использован в этом исследовании.

Согласно [16] НТА (STA) — это кортеж $A = (S, \Sigma, T, \delta)$, где:

- S — конечное множество состояний вида (id, u) , u — дискретный код состояния;
- Σ — множество событий (s, s') , где s, s' — состояния, т.е. событие определяется как смена классов наблюдений;
- T — множество переходов (s, a, δ, s') , где $a \in \Sigma$ — событие и δ — временное ограничение; при событии a автомат переходит из состояния s в s' , если удовлетворено ограничение δ ;
- $\delta: T \rightarrow I$ — временные ограничения переходов, где I — множество интервалов.

Данная модель имеет два принципиальных отличия от предшествующих НТА: 1) каждому состоянию s_j через код u взаимно-однозначно соответствует класс наблюдений C_j , т.е. внутреннее состояние модели полностью наблюдаемо; 2) используется локальный счетчик времени, и таким образом ограничения δ всегда относятся ко времени с момента последнего перехода. При этих условиях идентификация модели в режиме онлайн выполняется с помощью алгоритма OTALA [14].

Б. Алгоритм выявления аномалий с помощью НТА. Пусть даны обученный автомат A и последовательность событий (a, t) , где $a \in \Sigma$, и t — время локального таймера. Тогда автомат A можно использовать для выявления аномалий согласно схеме на рис. 1: наблюдаемому поведению физической системы соответствует путь через автомат; если же путь содержит недопустимые со-

стояния или переходы, то фиксируется аномалия. Этот процесс формализован в алгоритме ANODA [23, 19], который обнаруживает аномалии трех видов: неизвестное состояние, неверный переход и неверный тайминг перехода. Для некоторых систем в алгоритм вносится дополнительный вид аномалий — неверное начальное состояние.

Алгоритм 1. ANODA.

Вход: автомат $A = (S, \Sigma, T, \delta)$, наблюдение $o = (a, t)$, текущее состояние $s \in S$.

Выход: новое состояние автомата s_{new} , либо аномалия.

- 1: **if exists** $e \in T : e = (s, a, *, s')$:
- 2: **if** t satisfies $\delta(e)$:
- 3: $s_{new} = s'$ |
- 4: **else: return** anomaly: «wrong timing»
- 5: **else: return** anomaly: «unknown event»
- 6: **return** s_{new}

Алгоритм ANODA выявляет аномалии лишь в моменты переходов между состояниями. Однако в пределах каждого состояния наблюдаемый процесс может описываться локальной статистической моделью (например, NNPCA [16]), и тогда дополнительный вид аномалий фиксируется при выходе наблюдения за пределы модели.

В. Поточковый алгоритм кластеризации IMCF. Нечеткий инкрементный модель-ориентированный алгоритм кластеризации (incremental model-based clustering for fuzzy data — IMCF) впервые предложен автором в работе [20]. Здесь он адаптирован для обработки аналоговых данных IoT и CPPS и используется для перехода от аналоговых временных рядов IoT к дискретной последовательности классов наблюдений. При этом порядок и тайминг смены классов сохраняют информацию о динамике наблюдаемого процесса.

Пусть имеется последовательность аналоговых входных образов — предобработанных наблюдений из пространства наблюдений D . Предполагается, что

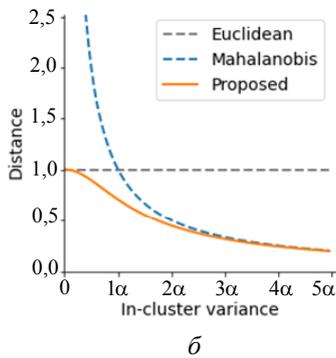
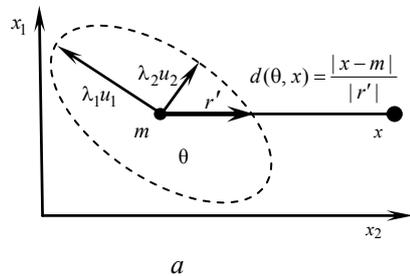


Рис. 2

в пределах каждого класса образы $x(t)$ занимают компактную область на D , согласно некоторой оценке расстояния $d : D^2 \rightarrow [0; \infty)$. Алгоритм IMCF строит разбиение D на четкие либо нечеткие подмножества (кластеры) C_k , которые соответствуют различным классам. Каждый кластер C_k описывается статистической моделью распределения его элементов $\theta(C_k) = (w, m, S)$, где w — количество наблюдений элементов кластера; m — оценка ожидания распределения; S — оценка матрицы ковариации. На рис. 2, а показана геометрическая интерпретация модели кластера $\theta(C)$: m — центр, u_1, u_2 — главные направления вариации, r' — размер кластера вдоль заданного направления. Алгоритм опирается на специальную оценку соответствия между

моделью и наблюдением $d(\theta, x)$ [20], которая объединяет полезные свойства евклидова расстояния и статистического расстояния Махаланобиса [24]. На рис. 2, \bar{b} зависимость оценки $d(\theta, x)$ от внутрикласовой вариации: оценка совпадает с евклидовым расстоянием в случае точечных моделей и асимптотически приближаться к расстоянию Махаланобиса при увеличении вариации.

IMCF работает в режиме онлайн, т.е. обрабатывает входные данные последовательно, в один проход, обновляя модели кластеров с каждым новым наблюдением (шаги 14–16). Расстояние $d(\theta, x)$ используется для оценки степени принадлежности входного образа кластеру (шаг 5). Количество кластеров оценивается автоматически, исходя из распределения входных данных (шаги 9, 10). Наконец, выход алгоритма для каждого наблюдения x есть нечеткое множество активных кластеров, заданное вектором $y \in [0; 1]^N$, а также расстояние до ближайшей модели кластера $d_* = d(\theta_J, x) \in [0; 1]$, где $J = \arg \max(y)$.

Алгоритм 2. IMCF.

```

1:  $Y \leftarrow$  function IMCF( $X$ )
2: .....  $M \leftarrow 1, C_1 \leftarrow \theta(x_1)$ 
3:   for all  $x \in X$  do
4:     for all  $k \in \overline{1, M}$  do
5:        $y_k \leftarrow 0, d_k \leftarrow d(C_k, x)$  using  $invS_k = S_k^{-1}$ 
6:        $\mu_k \leftarrow d_k^{-p} / \sum_{j=1}^M d_j^{-p}$ 
7:     end for
8:      $\mu \leftarrow$  search( $\mu$ )
9:     if  $\min(d_k) > 1 - \rho$  then
10:       $M \leftarrow M + 1, C_M \leftarrow \theta(x)$ 
11:     else
12:      for all  $k \in \overline{1, M} : \mu_k \geq T_{\min}$  do
13:         $y_k \leftarrow \mu_k$ 
14:         $w_k \leftarrow w_k + \mu_k, \beta \leftarrow \max\{\mu_k / w_k, \mu_k \cdot \beta_{\min}\}$ 
15:         $m_k \leftarrow (1 - \beta) \cdot m_k + \beta \cdot x$ 
16:         $S_k \leftarrow (1 - \beta) \cdot (S_k + \beta(x - m_k)(x - m_k)^T)$ 
17:         $invS_k \leftarrow (I + \alpha^{-2} S_k)^{-1}$ 
18:      end for
19:     end if
20:      $Y \leftarrow (Y, y)$ 
21:   end for
22: end function

```

IMCF — модификация быстрого инкрементного алгоритма кластеризации [25] (далее — EICA), и также структурно близок к современным модификациям алгоритма sequential k -means (SKM) [26]. В отличие от [25] и [26], IMCF поддерживает нечеткую кластеризацию и учитывает форму кластеров, что позволяет разделять пересекающиеся вытянутые кластеры, типичные для данных CPPS. Параметр $p \geq 1$ задает степень нечеткости кластеризации (жесткой кластеризации соответствует $p \rightarrow \infty$). Для предотвращения неконтролируемого роста и размывания нечетких кластеров использованы приемы ART [27]: сжатие множества активных кластеров (code compression, шаг 6); ограничение подмножества обновляемых на каждом шаге кластеров с помощью процедуры поиска (шаг 8) и порога активации $T_{\min} \in (0; 1)$ (шаг 12); забывание предыдущих наблюдений, скорость которого задается параметром $\beta_{\min} \in [0; 1)$.

Процедура поиска направлена на достижение стабильности обучения в случае, когда нечеткие кластеры пересекаются. Перед каждой стадией обучения она отбрасывает некоторые из активных кластеров C_k согласно минимальному порогу величины $\|S_a n_a^{-1} - S_k n_k^{-1}\|_F$, где: a — номер кластера-лидера; $n_i = \|S_i\|_F$, $i = \overline{1, M}$; $\|S_i\|_F$ — норма Фробениуса. Такой порог задает минимальное различие в форме кластеров, которые могут обновляться одновременно, и таким образом предотвращает их конвергенцию.

Идентификация темпорального автомата

Для идентификации НТА на данных IoT необходимо преобразовать аналоговые временные ряды сенсорных данных в последовательность дискретных событий, пригодную для дальнейшей обработки с помощью OTALA. В этом исследовании такую дискретизацию обеспечивал алгоритм IMCF. В схеме на рис. 1 IMCF выполнял роль классификатора наблюдений, в то время как НТА представлял динамическую модель процесса. Информативность кластеров IMCF для идентификации темпорального автомата оценивалась согласно следующим критериям: сложность полученной модели, оцениваемая как степень насыщенности графа автомата; степень неопределенности оценки текущего состояния и переходов; устойчивость к вариации в пределах нормального режима работы системы; наличие существенных качественных изменений на выходе классификатора при аномалиях.

Пред подачей на вход классификатора сенсорные данные подвергались предобработке, которая включала: снижения размерности методом главных компонент, устранение шумов сглаживающими фильтрами и нормализацию. Результат нечеткой классификации $y \in [0; 1]^N$ для использования в OTALA преобразовывался в унитарный код (one-hot encoding) $y' \in \{0, 1\}^N : |y'| = 1$. Подобно исследованиям [16–18], при каждой смене кластера-лидера J генерировалось новое событие для обучения НТА: $o = (s, s', t)$, где $s, s' \in \overline{1, N}$, — номера предыдущего и нового кластеров.

Использованы два вида временных ограничений, поддерживаемые НТА [14, 19]:

$$\delta_1 = [E(\tau) - k \cdot \sigma(\tau), E(\tau) + k \cdot \sigma(\tau)], \quad (1)$$

$$\delta_2 = [\inf(\tau) - \varepsilon, \sup(\tau) + \varepsilon], \quad (2)$$

где τ — множество значений таймера, из которых формировалось ограничение, k, ε — допуск.

В отличие от предыдущих исследований здесь автомат непосредственно использует статистическую модель кластера-лидера $\theta(C_J)$ для описания допустимой вариации наблюдений в состоянии s_J . Тогда расстояние $d(\theta_J, x)$ — мера несоответствия наблюдения x текущему состоянию НТА — отражает, насколько хорошо наблюдение x можно описать моделью без учета контекста.

Алгоритм ANODA также усовершенствован (алгоритм 3). В отличие от [14, 19], при обнаружении аномалии автомат переходит в новое наблюдаемое состояние (шаг 2), поскольку иначе он неспособен восстанавливать нормальную работу после аномалий. Для моделирования систем, которые работают циклами подобно HRSS, добавлена возможность сброса состояния автомата и таймера при переходе к новому рабочему циклу (аргумент CR), а в модель НТА добавлены множества допустимых начальных и конечных состояний S_0, S_f (шаги 4–6). Также учтены

новые состояния, которые алгоритм IMCF может создавать во время работы (шаг 3). Наконец, вне алгоритма ANODA, дополнительно фиксируется аномалия «задержка», если в текущем состоянии s превышены временные ограничения всех возможных переходов $\delta(s, *, *)$. За счет этого расширены возможности выявления аномалий в промежутках времени между дискретными переходами НТА.

Алгоритм 3. Модификация ANODA.

Вход: гибридный темпоральный автомат $A = (S, S_0, S_f, \Sigma, T, \delta)$;

текущее состояние s ; наблюдение $o = (a, t)$, где $a = (s, s')$; сброс $CR \in \{True, False\}$.

Выход: новое состояние автомата s_{new} , аномалия.

```

1: if  $s' \in S$  :
2:    $s_{new} = s'$ 
3: else: return anomaly: «unknown state»
4: if CR:
5:   if  $s \notin S_f$  : return anomaly: «wrong end state»
6:   if  $s' \notin S_0$  : return anomaly: «wrong start state»
7: if exists  $e \in T$  :  $e = (s, a, *, s')$  :
8:   if  $t$  satisfies  $\delta(e)$  :
9:     return anomaly: «none»
10:  else: return anomaly: «wrong timing»
11: else: return anomaly: «unknown event»
12: return  $s_{new}$ 

```

Экспериментальное исследование

А. Система HRSS. Для апробации предложенного метода идентификации НТА выбрана система High Rack Storage System — HRSS [28]. В ней существующий метод на базе самоорганизующихся карт (SOM) и преобразования водораздела [16] неэффективен, обеспечивая качество выявления аномалий 30,8 % (F1-мера), точность 36,3 % и полноту 26,7 %. В другом исследовании [29] к этой же системе применялись модели глубокого обучения, однако эффективность модели для выявления аномалий оставалась низкой (25,6 %), что свидетельствует о сложности данной системы для моделирования.

HRSS — демонстрационный кейс CPPS, созданный в SmartFactoryOWL, Германия, и специализированный для исследования новейших методов диагностики в IoT и Industry 4.0. HRSS выполняет циклическое перемещение изделий в двух измерениях и состоит из горизонтальных лент-транспортеров и вертикальных подъемников (рис. 3, схема HRSS: «BLO», «BRU», «BHL», «BHR» — транспортерные ленты, «HL», «HR» — вертикальные подъемники. Стрелками показаны три из возможных путей транспортирования [30]).

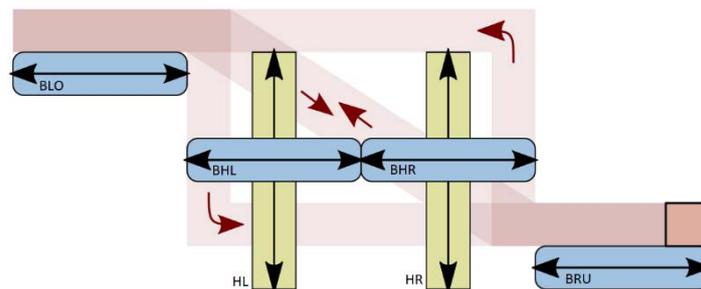


Рис. 3

Данные, собранные в рамках проекта IMPROVE [30], включают показатели положения, мощности и напряжения с шести моторов системы, и организованы в виде 18-мерных аналоговых временных рядов. Часть циклов транспортирования

содержат отмеченные аномалии, и основной задачей в HRSS является выявление таких аномалий с точной их локализацией во времени. При этом необходимо учитывать, что HRSS имеет два типа аномалий, которые оказывают различное влияние на работу моделей диагностики [31]:

Тип 1: преждевременная остановка либо задержка, пауза, нарушение длительности, тайминга, либо последовательности стадий процесса — такие аномалии могут быть длительными (до 90 % длительности цикла) и присутствуют в 48 циклах из 106.

Тип 2: выход измерений за пределы диапазона, типичного для конкретной стадии процесса, без нарушения временных ограничений — такие аномалии присутствуют в 56 циклах и занимают не более 10–15 % их длительности.

Б. Условия эксперимента. В экспериментальном исследовании предложенный метод идентификации НТА применялся к данным HRSS. Предобработка наблюдений перед подачей на вход классификатора включала следующие шаги:

- расширение набора признаков за счет скоростей, оцененных с помощью центральных конечных разностей второго порядка (шесть дополнительных признаков);
- снижение размерности методом главных компонент с 24 до 8, которое позволило сохранить 93,6 % вариации данных;
- нормализация и масштабирование признаков к интервалу [0; 1];
- сглаживание временных рядов с гауссовой маской ширины 15 и СКО 3.

Для обучения моделей IMCF и НТА использовались данные 50 циклов работы системы в нормальном режиме (12242 наблюдения), а эффективность обученной модели НТА оценивалась на 106 циклах с аномалиями, которые не использовались при обучении. Во всех случаях данные обрабатывались последовательно, в один проход, согласно требованиям потоковой обработки данных в CPPS.

Для модели НТА эмпирически выбраны оптимальные значения мета-параметров временных ограничений $k = 2, 2$ и $e = 10^{-3}$, а также ширина окна для определения сходимости обучения $f_{conv} = 20$ [19]. Эмпирически выбранные параметры классификатора IMCF приведены в табл. 1: p — степень нечеткости; $d_{max} = 1 - p$ — порог отнесения наблюдения к кластеру; T_{min} — порог активации кластеров; β_{min} — скорость забывания.

Таблица 1

Тип модели	Параметры модели			
	p	d_{max}	T_{min}	β_{min}
Нечеткий	2	0,14–0,19	0,05	0,005
Жесткий	∞	0,12–0,18	–	0,01

Поскольку оценочный набор данных не сбалансирован и содержал лишь 14 % аномальных наблюдений, в качестве критериев эффективности совместно использовались точность (precision), полнота (recall) и F1-мера. Эти критерии также позволили провести прямое сравнение с результатами предыдущих исследований для той же системы [16–18, 31].

В. Результаты. Как указывалось ранее [31], классы нормальных и аномальных наблюдений в признаковом пространстве HRSS статистически неразличимы. В экспериментах величина расстояния $d(\theta_j, x)$, полученного на выходе IMCF, также не позволяет статистически разделить эти классы (рис. 4, распределения $d(\theta_j, x)$ для нормальных и аномальных наблюдений).

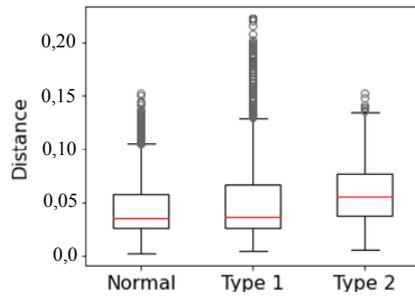


Рис. 4

Тем не менее совместное применение IMCF и НТА позволило выявить аномалии в HRSS. Так, в случае нечеткой кластеризации $d_{\max} = 0,16$ и ограничений вида (1) получен автомат с 11 состояниями и 16 переходами (рис. 5, а), который обеспечивает эффективность выявления аномалий (F1) 38,5 %, точность 64,2 % и полноту 27,4 %. В случае жесткой кластеризации и $d_{\max} = 0,14$ полученный автомат имеет 13 состояний и 16 переходов (рис. 5, б), демонстрируя эффективность выявления аномалий (F1) 37,8 %, точность 61,8 % и полноту 27,2 % (табл. 2, оценки эффективности выявления аномалий в HRSS; табл. 3, матрица несоответствий при выявлении аномалий).

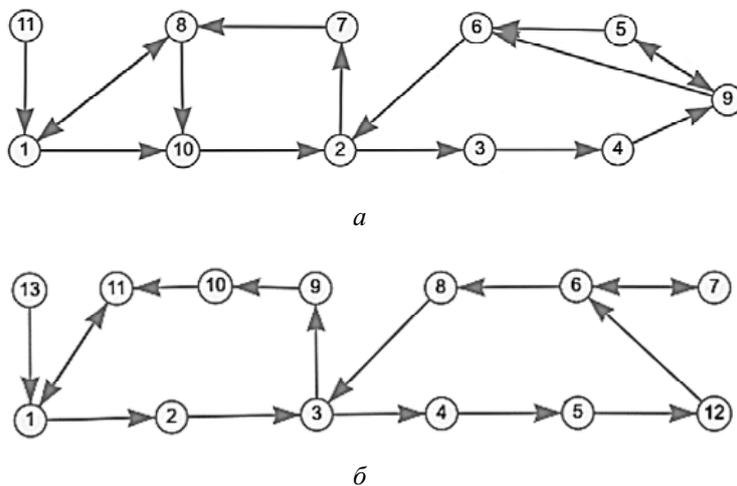


Рис. 5

Таблица 2

№	Параметры алгоритма IMCF		N состояний / переходов	Эффективность выявления аномалий, %, в виде: F1 мера (точность, полнота)		
	тип	d_{\max}		в целом	1-й тип	2-й тип
1	нечеткий	0,16	11 / 16	38,5 (64,2; 27,4)	47,5 (88,4; 32,5)	14,0 (18,3; 11,3)
2	жесткий	0,14	13 / 16	37,8 (61,8; 27,2)	47,3 (89,9; 32,1)	13,7 (16,5; 11,7)

Таблица 3

Экземпляры	Предсказание модели 1		Предсказание модели 2	
	Отрицательное	Положительное	Отрицательное	Положительное
Отрицательные	17108	867	17022	953
Положительные	4114	1556	4126	1544

В других экспериментах оценивалось влияние параметров IMCF на показатели обученного автомата (рис. 6, влияние количества состояний автомата на точность (слева) и полноту выявления аномалий (справа)). За счет изменения d_{\max} количество состояний N варьировалось от 6 до 20. Во всех случаях граф автомата остается разреженным со средней степенью вершин в пределах 1,18–1,67. Это указывает на низкую неопределенность выученных переходов, которая является одним из условий эффективности модели НТА. При снижении значения d_{\max} количество состояний N увеличивается — за счет этого повышается точность модели и достигает максимума при $N=11-13$, при этом, однако, существенно снижается полнота. Как и в большинстве исследований, при выборе моделей в табл. 2 приоритет отдавался точности.

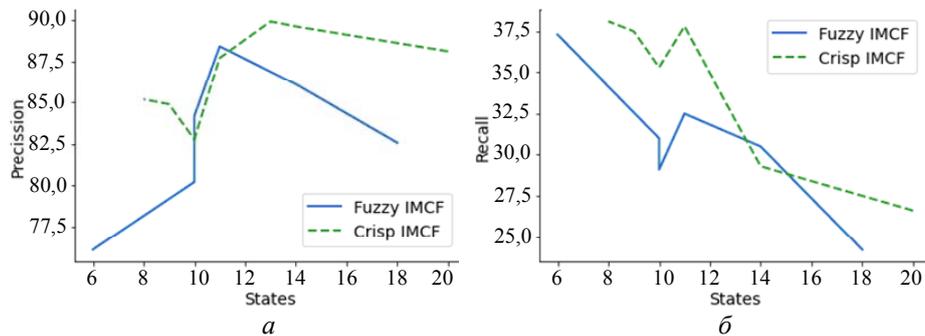


Рис. 6

Выбор параметров временных ограничений в НТА нетривиален. Например, уменьшение допуска ограничений k приводит к повышению полноты и F1-меры на 1–2 %, однако, при этом точность снижается на 5–7 %. Это означает, что дополнительные срабатывания модели, полученные за счет меньшего допуска, слабо коррелируют с аномалиями в наблюдаемом сигнале, и уменьшение допуска k нецелесообразно.

Основным недостатком модели остается высокое количество ложно-негативных результатов (см. табл. 3), которое объясняется двумя факторами. Большинство ложно-негативных результатов (до 75 %) связано с длительными аномалиями первого типа. В таких случаях (рис. 7, *a*, *б*) (отклик модели на аномалии первого типа) видно, что модель реагирует на начало аномалии, но быстро возвращается к нормальному состоянию, в то время как наблюдаемый процесс остается смещенным относительно нормы. Оставшиеся ложно-негативные результаты объясняются низкой долей выявленных аномалий второго типа (не более 13 %), однако этот показатель может не быть репрезентативным, поскольку относительно малая вариация сигнала, связанная с аномалиями второго типа, могла быть отброшена при снижении размерности методом главных компонент.

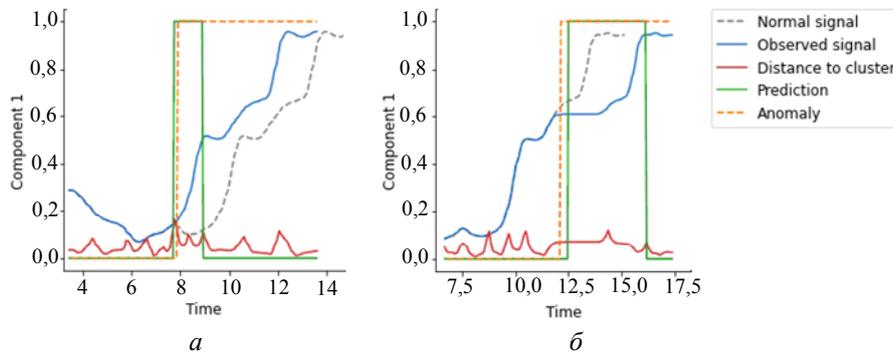


Рис. 7

Значение результатов

В данном исследовании показано, что использование IMCF совместно с НТА позволяет уверенно выявлять аномалии в аналоговых временных рядах IoT: для аномалий первого типа точность достигает 89,9 %, а общая точность 61,8–64,2 %. По сравнению с аналогом на базе SOM [16, 17], достигнуто повышение эффективности выявления аномалий (F1-меры) на 24,9 % и точности на 76,8 %. По сравнению с DL моделью [29] общая эффективность повышена на 50,4 %. В то же время полнота выявления аномалий остается низкой (до 27,4 %), что, в основном объясняется нечувствительностью модели к длительным аномалиям первого типа. Поэтому НТА не достигают показателей, полученных автором ранее с помощью моделей глубокого обучения [31].

Наблюдаемое ограничение эффективности вытекает из трех свойств модели НТА:

- 1) оцениваются лишь временные отношения между соседними переходами, в результате модель не обнаруживает отклонение, которое накапливается в течение протяженного времени, за несколько переходов модели между состояниями;
- 2) отсутствует долговременная память для хранения истории переходов, поэтому в длительных аномалиях первый переход с нормальным таймингом возвращает модель в нормальное состояние, как в случаях на рис. 7;
- 3) переходы в НТА остаются дискретными, поэтому точность локализации аномалий во времени ограничена количеством состояний модели.

В HRSS за счет свойства 2 длительность выявленных аномалий первого типа ограничивается одним-двумя последовательными состояниями. Для модели с малым количеством состояний N этот промежуток длиннее, соответственно выше доля выявленных аномалий, что объясняет наблюдаемый тренд для полноты модели (рис. 6, б). В то же время для высокой точности необходимо большее значение N (свойство 3). Такой конфликт между точностью и полнотой модели не позволяет существенно повышать эффективность модели путем адаптации и выбора параметров. Поэтому новые исследования должны быть направлены на дальнейшее усовершенствование модели НТА и преодоление описанных ограничений НТА.

Заключение

Для идентификации динамики производственного процесса Industrial IoT в виде НТА необходимо выявить дискретные состояния и события в аналоговых временных рядах наблюдений непрерывного процесса. Для этого предложено использовать инкрементный модель-ориентированный алгоритм кластеризации (IMCF). В задаче выявления аномалий в производственной системе транспортирования такое решение позволило повысить общую эффективность модели НТА на 24,9 % и точность на 76,8 %. Тем самым расширены возможности применения моделей класса темпоральных автоматов в контексте задач мониторинга и управления в Industrial IoT. Однако для практических приложений эффективность НТА остается недостаточной из-за трех принципиальных ограничений: дискретности переходов между состояниями, отсутствия длительных временных ограничений и отсутствия долговременной памяти предыдущих переходов, для их устранения требуются новые подходы к формализации НТА.

К.К. Кадомський

ЗАСТОСУВАННЯ ПОТОКОВОЇ КЛАСТЕРИЗАЦІЇ ДЛЯ ІДЕНТИФІКАЦІЇ ГІБРИДНИХ ТЕМПОРАЛЬНИХ АВТОМАТІВ ЗА АНАЛОГОВИМИ ДАНИМИ ІОТ

Моделі класу темпоральних автоматів надають зручну абстракцію для вирішення завдань діагностики та управління у системах промислового Інтернету

речей (ПоТ). Для їхнього застосування необхідно виконувати ідентифікацію автомата шляхом пасивного навчання онлайн, використовуючи лише позитивні зразки. Такий тип навчання можливий лише для гібридних темпоральних автоматів (НТА) із алгоритмом OTALA. Однак для навчання НТА необхідна послідовність дискретних подій замість безперервних аналогових часових рядів, які зазвичай зустрічаються в ПоТ. А. von Birgelen, O. Niggemann та інші робили спроби заповнити цю прогалину за рахунок попередньої обробки спостережень самоорганізаційними картами (SOM) із перетворенням вододілу, проте отримані моделі часто неефективні в реальних умовах. У даній статті завдання ідентифікації темпорального автомата за аналоговими даними ПоТ вирішується із застосуванням інкрементного алгоритму кластеризації на основі моделей (IMCF). IMCF — це потоковий алгоритм, який обробляє вхідні часові ряди в режимі онлайн і перетворює їх на послідовність дискретних станів із чіткими або нечіткими переходами між ними. Такі переходи далі використовуються як події, необхідні для ідентифікації НТА за алгоритмом OTALA. Отримані моделі експериментально досліджено на прикладі системи ПоТ, яка раніше представляла складність для моделювання. Досягнуте підвищення ефективності на 24,9–76,8 % демонструє, що дискретизація за допомогою IMCF більш інформативна для ідентифікації НТА. Також обговорюються ширші перспективи застосування НТА в системах ПоТ і визначено обмеження, що залишаються актуальними для подібних практичних застосувань: дискретність переходів між станами НТА і відсутність довготривалої пам'яті переходів.

Ключові слова: промисловий інтернет речей, кіберфізичні виробничі системи, виявлення аномалій, гібридний темпоральний автомат, ідентифікація систем, потокова кластеризація.

K.K. Kadomskiy

USING SEQUENTIAL CLUSTERING TO IDENTIFICATION OF HYBRID TIMED AUTOMATA FROM ANALOG IIOT DATA

In Industrial IoT (IIoT) systems, timed automata provide a highly useful abstraction for diagnosis and control tasks. Applying them requires automaton to be learned in passive online manner using positive samples only. Such kind of learning is supported by Hybrid Timed Automata (HTA) and algorithm OTALA, but requires a sequence of discrete events rather than continuous analog time series typically found in IIoT. Recent attempts to cover this gap, taken by A. von Birgelen, O. Niggemann, and others, involved pre-processing observations with a self-organized map (SOM) and watershed transform, yet resulting models have proven ineffective in some real-world systems. In this paper, incremental model-based clustering (IMCF) is employed to learn timed automaton from analog IIoT data. IMCF is a sequential algorithm that processes observed time-series online and splits them into a sequence of discrete states with either crisp or fuzzy transitions between them. Such transitions are then treated as events required for HTA identification with OTALA. Obtained models are evaluated in a case of IIoT system that has proved to be challenging for existing modelling techniques. Experimental results show 24,9–76,8% increase in model's performance and suggest that discretizing obtained with IMCF has higher informativeness for HTA identification. Finally, wider perspectives of applying HTA in IIoT are discussed, and remaining principal limitations are identified as discrete nature of state transitions, and lack of long-term memory for transitions.

Keywords: industrial IoT (IIoT), cyber-physical production systems (CPPS), anomaly detection, hybrid timed automata (HTA), model identification, sequential clustering.

1. Factories of the future: multi-annual roadmap for the contractual PPP under HORIZON 2020. Publications Office of the European Union. Luxembourg, 2013. 128 p. DOI: 10.2777/29815
2. Lu Y. Industry 4.0: A survey on technologies, applications and open research issues. *Journal of industrial information integration*. 2017. **6**. P. 1–10. DOI: 10.1016/j.jii.2017.04.005.
3. Kushmaro P., 5 ways industrial AI is revolutionizing manufacturing. 2018. URL: <https://www.cio.com/article/3309058/5-ways-industrial-ai-is-revolutionizing-manufacturing.html>.
4. Lee E.A. Cyber physical systems: design challenges. *The 11th IEEE international symposium of object oriented real-time distributed computing (ISORC)*: proc. of. Orlando, FL. 2008. P. 363–369. DOI: 10.1109/ISORC.2008.25.
5. Boyes H., Hallaq B., Cunningham J., Watson T. The industrial internet of things (IIoT): an analysis framework. *Computers in industry*. 2018. **101**. P. 1–12. DOI: 10.1016/j.compind.2018.04.015.
6. Långkvist M., Karlsson L., Loutfi A. A review of unsupervised feature learning and deep learning for time-series modeling. *Pattern recognition letters*. 2014. **42**. P. 11–24. DOI: 10.1016/j.patrec.2014.01.008.
7. Zhou P.-Y., Chan K.C.C. A feature extraction method for multivariate time series classification using temporal patterns. *Advances in knowledge discovery and Data Mining (PAKDD 2015)*: proc. of 19th Pacific-Asia conference, Ho Chi Minh City, Vietnam, May 19–22, 2015. Springer, Cham, 2015. Part II. P. 409–421. DOI: 10.1007/978-3-319-18032-8_32.
8. Challenges for software engineering in automation. B. Vogel-Heuser, C. Diedrich, A. Fay, S. Jeschke, M. Kowalewski, S. Wollschlaeger, P. Goehner. *Journal of software engineering and applications*. 2014. **7**. P. 440–451. DOI: 10.4236/jsea.2014.75041.
9. Alur R., Dill D.L. A theory of timed automata. *Theoretical Computer Science*. 1994. **126**. N 2. P. 183–235. DOI: 10.1016/0304-3975(94)90010-8.
10. Verwer S. Efficient identification of timed automata: theory and practice: Doctoral thesis. Delft University of Technology. Delft, Netherlands, 2010. 252 p.
11. The algorithmic analysis of hybrid systems. Alur R., Courcoubetis C., Halbwachs N., Henzinger T.A., Ho P.-H., Nicollin X., Olivero A., Sifakis J., Yovine S. *Theoretical Computer Science*, 1995. **138**. N 1. P. 3–34. DOI: 10.1016/0304-3975(94)00202-T.
12. Bemporad A., Di Cairano S. Model-predictive control of discrete hybrid stochastic automata. *IEEE trans. on automatic control*. 2011. **56**, N 6. P. 1307–1321. DOI: 10.1109/TAC.2010.2084810.
13. Vodenčarević A. Identifying behavior models for hybrid production systems: Dissertation in Computer Science. University of Paderborn. Paderborn, Germany, 2013. 167 p.
14. Maier A. Online passive learning of timed automata for cyber-physical production systems. *Industrial informatics (INDIN)*: proc. of 12th IEEE international conference on, Porto Alegre, Brazil, July 27–30, 2014. IEEE, 2014. P. 60–66. DOI: 10.1109/INDIN.2014.6945484.
15. Maier A., Niggemann O., Eickmeyer J. On the learning of timing behavior for anomaly detection in cyber-physical production systems. *Principles of diagnosis (DX)*: proc. of the 26th international workshop on, Paris, France, August 31–September 3, 2015. Paris, France, 2015. P. 217–224.
16. von Birgelen A., Niggemann O., Using self-organizing maps to learn hybrid timed automata in absence of discrete events. *Emerging technologies and factory automation, ETFA*: proc. of the 22nd IEEE international conference on, Limassol, Cyprus, 2017. P. 1–8. DOI: 10.1109/ETFA.2017.8247695.
17. von Birgelen A., Niggemann O. Enable learning of hybrid timed automata in absence of discrete events through self-organizing maps. *IMPROVE — innovative modelling approaches for production systems to raise validatable efficiency* / O. Niggemann, P. Schüller (eds.). Springer Vieweg, Berlin, Heidelberg, 2008. P. 37–54. DOI: 10.1007/978-3-662-57805-6_3.
18. Hranisavljevic N., Niggemann O., Maier A. A novel anomaly detection algorithm for hybrid production systems based on deep learning and timed automata. *Principles of diagnosis (DX)*: proc. of the 27th international workshop on, Denver, Colorado, October 4–7, 2016.
19. Maier A. Identification of timed behavior models for diagnosis in production systems: Dissertation in Computer Science. University of Paderborn. Paderborn, Germany, 2015. 171 p.
20. Кадомский К. К. Повышение эффективности инкрементной кластеризации нечетких данных. *Труды ИПММ НАН Украины*. 2012. **24**. С. 124–133.

21. Cao F., Estert M., Qian W., Zhou A. Density-based clustering over an evolving data stream with noise. *The 2006 SIAM International conference on data mining: proc. of*, Bethesda, MD, 2006. pp. 328–339. DOI: 10.1137/1.9781611972764.29.
22. Chen Y., Tu L. Density-based clustering for real-time stream data. *Knowledge discovery and data mining: proc. of the 13th ACM SIGKDD international conf. on*, San Jose, CA, August 2007. Association for Computing Machinery, New York, NY, 2007. P. 133–142. DOI: 10.1145/1281192.1281210.
23. Maier A., Niggemann O., Just R., Jäger M., Vodenčarević A. Anomaly detection in production plants using timed automata: automated learning of models from observations. *Informatics in control, automation and robotics (ICINCO): proc. of 8th international conf. on*, Noordwijkerhout, The Netherlands, Jul 2011. SciTePress, 2011. **2**. P. 363–369. DOI: 10.5220/0003538903630369.
24. de Maesschalck R., Jouan-Rimbaud D., Massart D.L. The Mahalanobis distance. *Chemometrics and intelligent laboratory systems*. 2000. **50**, N 1. P. 1–18. DOI: 10.1016/S0169-7439(99)00047-7.
25. Gupta N., Ujjwal R.L. An efficient incremental clustering algorithm. *World of Computer Science and Information Technology Journal*. 2013. **3**, N 5. P. 97–99.
26. Young S., Arel I., Karnowski T.P., Rose D. A fast and stable incremental clustering algorithm. *2010 Seventh International Conference on Information Technology: New Generations*. Las Vegas, NV, 2010. P. 204–209. DOI: 10.1109/ITNG.2010.148.
27. Carpenter G.A., Grossberg S., Rosen D.B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. *Neural networks*. 1991. **4**. P. 759–771. DOI: 10.1016/0893-6080(91)90056-B.
28. Physical factory / demonstrators IMPROVE. 2016. URL: <http://improve-vfof.eu/background/physical-factory-demonstrators>.
29. Cerliani M. Predictive maintenance with LSTM Siamese network. 2019. URL: <https://towardsdatascience.com/predictive-maintenance-with-lstm-siamese-network-51ee7df29767>.
30. High storage system data for energy optimization. 2018. URL: <https://www.kaggle.com/inIT-OWL/high-storage-system-data-for-energy-optimization>.
31. Kadomskiy K. Evaluating Deep Learning models for anomaly detection in an industrial transporting system. *CEUR workshop proceedings*. 2021. **2845**. P. 11–21. ISSN 1613-0073. URL: http://ceur-ws.org/Vol-2845/Paper_2.pdf.

Получено 24.05.2021