

УДК 004.896

ПОДХОД К ОБНАРУЖЕНИЮ АНОМАЛИЙ В ТЕХНОЛОГИЧЕСКИХ СИГНАЛАХ С ПРИМЕНЕНИЕМ ПРЕОБРАЗОВАНИЯ ГИЛЬБЕРТА — ХУАНГА

© Д. А. Мурзагулов, А. В. Замятин, О. В. Романович

*Томский государственный университет,
634050, г. Томск, просп. Ленина, 36
E-mail: murzagulov.damir@gmail.com*

В рамках исследования рассмотрена задача обнаружения в нестационарных технологических сигналах аномалий как ранних признаков отказов и поломок оборудования. Представлен подход к обнаружению аномалий с использованием преобразования Гильберта — Хуанга совместно со статистической моделью. Основная идея подхода заключается в анализе статистических показателей элементов разложения Гильберта — Хуанга, которое обладает адаптивностью разложения в случае нестационарных данных и обеспечивает высокую детализацию в частотно-временной области. Представлены принципиальная схема и алгоритм подхода, описание статистической модели классификации, численные расчёты на модельных и реальных данных, сравнительный анализ с другими методами обнаружения аномалий в сигналах.

Ключевые слова: аномалия, технологический сигнал, спектральный анализ, статистическая модель, предиктивная аналитика.

DOI: 10.15372/AUT20210104

Введение. В рамках всеобщей цифровизации промышленных предприятий особое место занимают методы анализа и обработки промышленных данных, основная часть которых представляет собой технологические сигналы (ТС) [1], являющиеся основными показателями качества работы объектов, и на основе анализа таких сигналов принимаются бизнес-решения [2]. Поломки, отказы, аварии, нарушение этапов технологического процесса напрямую отражаются в сигналах. Подобные нарушения могут трактоваться как аномалии в ТС, и задача сводится к их выявлению (типовая задача в анализе данных) [3]. Отличительными характеристиками технологических сигналов являются: нестационарность, сложная структура с локально сосредоточенными информативными участками, непредсказуемость — такие данные плохо поддаются строгому математическому описанию и требуют адаптивных методов анализа и обработки [4]. Кроме того, ТС могут содержать помехи и наводки и спектр полезного сигнала может быть перекрыт искажениями [5, 6]. В таких условиях задача обнаружения технологических сигналов является нетривиальной и актуальной.

Нестационарное поведение сигнала выражается в том, что в нём присутствуют составляющие из разных частот спектра: короткоживущих высоких и долгоживущих низких, поэтому при анализе технологических сигналов необходимо учитывать частотно-временные характеристики сигнала [7].

Наиболее распространёнными подходами для частотно-временного анализа являются быстрое преобразование Фурье [8] и вейвлет-преобразование (ВП) [9]. Однако у обоих подходов существует общий недостаток — зависимость от базисных функций в преобразовании. Выбор базисной функции определяет степень выраженности локализации аномальных участков на сигнале, поскольку в основе обоих преобразований лежит операция свёртки. В общем случае качество обнаружения аномалий в сигнале будет зависеть от выбора базисной функции, в свою очередь, выбор базиса определяется структурой сигнала.

Согласно теории Шеннона [10] оптимальным является базис, обеспечивающий минимальную энтропию коэффициентов разложения, представляющих энергию сигнала. В случае ТС невозможно установить универсальный базис для всех сигналов, так как информативные участки могут иметь различную форму, структуру и протяжённость. Для обеспечения высокого качества выявления аномалий в ТС необходим специальный подход, обеспечивающий адаптивное преобразование для каждого исследуемого сигнала. Подобный подход к разложению сигналов на частотные спектры реализуется в преобразовании Гильберта — Хуанга (ПГХ) — методе анализа нелинейных и нестационарных данных [11]. Основной отличительной чертой ПГХ является адаптивное формирование базисных функций для частотно-временного разложения. Предлагается использовать ПГХ в качестве инструмента для создания входных данных для некоторой статистической модели, оценивающей частотно-временные характеристики сигнала по заданному алгоритму.

Цель данной работы — описать подход обнаружения аномалий в технологических сигналах с применением ПГХ и статистической модели и продемонстрировать эффективность и преимущество подхода перед аналогами.

Постановка задачи. Технологический сигнал представляет собой одномерный временной вещественный ряд

$$X(t) = \{x_1, x_2, \dots, x_N\}, \quad (1)$$

где N — количество измерений, $x_n \in \mathbb{R}$.

Под аномалией далее подразумевается отрезок ряда $\{x_n, \dots, x_{n+k}\}'$, для которого набор некоторых статистических показателей отличается от показателей эталонного ряда в заданной мере. Допускается, что эталонный ряд описывает нормальное штатное течение технологического сигнала. Таким образом, задача заключается в построении алгоритма, который на основании показателей эталонного ряда оценивает параметры произвольного ряда на наличие в нём аномалий. В представленной работе эталонный ряд будем называть обучающим ($X_{\text{train}}(t)$), а произвольный исследуемый ряд — тестовым ($X_{\text{test}}(t)$).

Предлагаемый подход к обнаружению аномалий на основе преобразования Гильберта — Хуанга. Преобразование Гильберта — Хуанга является методом анализа нелинейных и нестационарных данных. Он представляет собой эмпирический метод декомпозиции данных на модальные взаимно ортогональные функции и применим к полученным модам преобразования Гильберта [12]. В некоторой степени ПГХ сходно с вейвлетным анализом данных, но с более высоким частотно-временным разрешением за счёт использования разложения нелинейного нестационарного сигнала на набор монокомпонентных составляющих, каждая из которых описывает собственный процесс с последующим анализом частотно-временного распределения монокомпонентных составляющих с помощью преобразования Гильберта [13].

Разложение базируется на предположении, что любые данные состоят из разнообразных простых внутренних видов колебаний. Каждый встроенный вид, линейный или нелинейный, представляет собой простое колебание, которое будет иметь одинаковое число экстремумов и нулевых пересечений. Каждое из этих колебаний представляется существенной функцией режима IMF (Intrinsic Mode Function) со следующим определением:

1. В наборе данных числа экстремумов и нулевых пересечений должны быть равными или отличаться максимум на единицу.

2. В любой точке данных среднее значение огибающих, определённых локальными максимумами и локальными минимумами, является нулём.

Алгоритм декомпозиции сигнала IMF происходит в следующей последовательности.

Итерация 1. В рассматриваемом сигнале $X(t)$ находятся положения всех локальных экстремумов, максимумов и минимумов процесса (номера точек экстремумов $t_{i \text{ext}}$) и

значения $X(t_{i\text{ext}})$ в этих точках. Далее группируются отдельно для максимумов и для минимумов массивы координат $t_{i\text{ext}}$ и соответствующих им амплитудных значений $X(t_{i\text{ext}})$. Число строк в массивах максимумов и минимумов не должно отличаться более чем на 1.

Итерация 2. Кубическим сплайном (возможно применение других методов) вычисляется верхняя $u_{\min}(t)$ и нижняя $u_{\max}(t)$ огибающие процесса соответственно по максимумам и минимумам. Определяем функцию средних значений $m_1(t)$ между огибающими:

$$m_1(t) = (u_{\min}(t) + u_{\max}(t))/2.$$

Разность между сигналом $X(t)$ и функцией $m_1(t)$ даёт первую компоненту отсеивания — функцию $h_1(t)$, которая является первым приближением к первой функции IMF:

$$h_1(t) = X(t) - m_1(t).$$

Итерация 3. Повторяем итерации 1 и 2, принимая вместо $X(t)$ функцию $h_1(t)$, и находим второе приближение к первой функции IMF — функцию $h_2(t)$:

$$h_2(t) = h_1(t) - m_2(t).$$

Последующие итерации выполняются аналогично. Алгоритм итераций нахождения первой функции IMF:

$$h_i(t) = h_{i-1}(t) - m_i(t).$$

По мере увеличения количества итераций функция $m_i(t)$ стремится к нулевому значению, а функция $h_i(t)$ — к неизменяемой форме. С учётом этого естественным критерием останова итераций является задание определённого предела по нормализованной квадратичной разности между двумя последовательными операциями приближения, определяемой как

$$\delta = \sum_t |h_{i-1}(t) - h_i(t)|^2 / \sum_t h_{i-1}^2(t).$$

Последнее значение $h_i(t)$ итераций принимается за наиболее высокочастотную функцию $c_1(t) = h_i(t)$ семейства IMF, которая непосредственно входит в состав исходного сигнала $X(t)$. Это позволяет вычесть $c_1(t)$ из состава сигнала и оставить в нём более низкочастотную составляющую:

$$r_1(t) = X(t) - c_1(t).$$

Функция $r_1(t)$ обрабатывается как новые данные в такой же последовательности с нахождением второй функции IMF ($c_2(t)$), после чего процесс продолжается:

$$r_2(t) = r_1(t) - c_2(t).$$

Таким образом, достигается декомпозиция сигнала в n -эмпирическом приближении:

$$X(t) = \sum c_i(t) + r_n(t).$$

На рис. 1, 2 представлены примеры разложения технологического сигнала на IMF.

Основная идея предлагаемого подхода заключается в создании модели обнаружения аномалий, которая в качестве входной информации принимает образ Гильберта мод сигнала, полученных в результате ПГХ, выполняет процедуру обнаружения аномалий по заданному алгоритму. Далее представлено формальное пошаговое описание подхода.




Рис. 1. Пример исследуемого технологического сигнала




Рис. 2. Некоторые уровни разложения IMF

Шаг 1. Технологический сигнал, описанный в (1), разделяется на обучающую $X_{\text{train}}(t)$ и тестовую $X_{\text{test}}(t)$ выборки.

Шаг 2. Для $X_{\text{train}}(t)$ и $X_{\text{test}}(t)$ выполняется процедура извлечения $\text{IMF}_{\text{train}}(t)$ и $\text{IMF}_{\text{test}}(t)$ таким образом, что

$$X(t) = \sum_{j=1}^n \text{IMF}_j(t) + r_j(t),$$

где n — количество эмпирических мод, $r_j = r_{j-1} - \text{IMF}_j(t)$.

Шаг 3. Выявляется минимальный уровень T_{min} разложения IMF через сравнение числа уровней разложения для $\text{IMF}_{\text{train}}(t)$ и $\text{IMF}_{\text{test}}(t)$:

$$T_{\text{min}} = \min(T_{\text{train}}, T_{\text{test}}).$$

Шаг 4. Для $\text{IMF}_{\text{train}}(t)$ и $\text{IMF}_{\text{test}}(t)$ применяется преобразование Гильберта, после чего получаются образы Гильберта $H_{\text{train}}(t)$ и $H_{\text{test}}(t)$:

$$H_{\text{train}}(t) = \frac{1}{\pi} \text{PV} \int_{-\infty}^{\infty} \frac{\text{IMF}_{\text{train}}(\tau)}{t - \tau} d\tau, \quad (2)$$

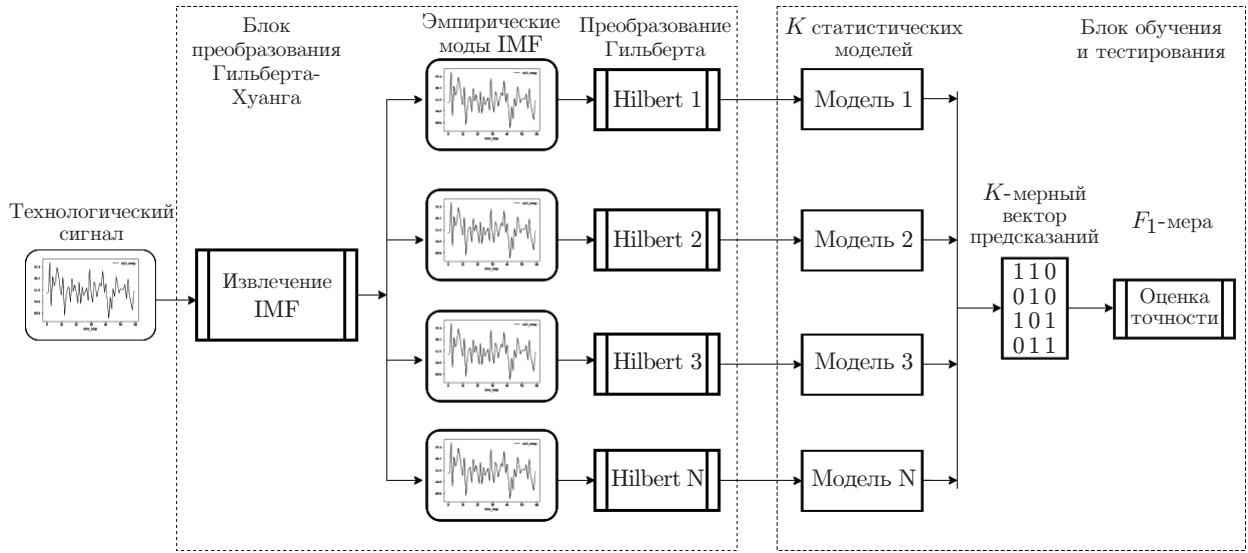


Рис. 3. Схема предложенного подхода к обнаружению аномалий

$$H_{\text{test}}(t) = \frac{1}{\pi} \text{PV} \int_{-\infty}^{\infty} \frac{\text{IMF}_{\text{test}}(\tau)}{t - \tau} d\tau, \quad (3)$$

где интегралы в (2), (3) понимаются в смысле главного (PV — principal value) значения Коши [14].

Шаг 5. На вход статистической модели M подаётся последовательно каждый $H_{\text{train}}(t)_n$, где $n = 1, \dots, T_{\text{min}}$:

$$M(\theta, H_{\text{train}}(t)) \xrightarrow{\text{обучение}} M',$$

где θ — параметры модели, M' — обученная модель.

Шаг 6. Далее для $H_{\text{test}}(t)$ выполняется процедура обнаружения аномалий и формируется матрица предсказаний $F = [\text{len}(X(t)), T_{\text{min}}]$:

$$M'(\theta, H_{\text{test}}(t)) \xrightarrow{\text{обнаружение}} F.$$

На рис. 3 графически представлен предложенный подход, который состоит из двух блоков. Первый блок выполняет процедуру ПГХ для анализируемого сигнала, второй блок обучает и тестирует модели для каждой полученной IMF. На выходе алгоритма предсказания каждой модели объединяются в общий вектор предсказаний.

Статистическая модель выявления аномалий. В данной работе предлагается использовать модель обнаружения аномалий, основанную на статистическом алгоритме, суть которого состоит в анализе набора некоторых статистик, вычисленных на технологическом сигнале по окну шириной w . Модель функционирует в двух режимах: «обучение» и «обнаружение аномалий». В режиме обучения модель вычисляет распределение исследуемых статистик для сигнала без аномалий, в качестве некоего эталонного образца, а в режиме обнаружения сопоставляет распределение тестируемого сигнала с эталоном через достигаемые уровни значимости для каждой статистики. В случае, когда достигаемый

уровень значимости p_{test} заданной статистики выходит за некоторый, заранее определённый, критический диапазон $[\alpha_{\text{low}}, \alpha_{\text{high}}]$, то алгоритм выдаёт сигнал «аномалия». Таким образом, процедура обнаружения аномалий сводится к проверке нулевой гипотезы, которая заключается в том, что рассматриваемый сигнал является «нормальным». Если полученное значение критерия оказывается в пределах $[\alpha_{\text{low}}, \alpha_{\text{high}}]$, то нулевая гипотеза не может быть отклонена — считается, что на заданном уровне значимости характеристики распределений совпадают, т. е. сигнал не содержит аномалий. Заметим, что при этом подходе оценивается двусторонняя альтернативная версия (более подробное описание такой оценки дано далее). Такой подход построения алгоритма позволяет обходиться без априорной информации об аномалиях, для правильного использования алгоритма необходимы экземпляры сигналов только в штатном режиме.

В алгоритме анализируются статистики, характеризующие безусловное совместное распределение элементов сигнала. Предварительно выборка из элементов сигнала преобразуется согласно следующей формуле:

$$u = Q^{-1}(x - \mu),$$

где u — преобразованная выборка; x — значения ряда в окне шириной w ; μ — среднее значение элементов сигнала; Q — разложение Холецкого [15] ковариационной симметричной матрицы $A = \text{cov}(A')$, где A' — матрица размера $w \times w$, полученная при движении по ряду окном w , так что $A'_{1j} = [x_1, x_2, \dots, x_w]$, $A'_{wj} = [x_{n-w}, x_{n-w+1}, \dots, x_n]$.

Элементы матрицы $Q = A^\top A$ выше диагонали находятся из соотношения

$$q_{ij} = \frac{1}{q_{ii}} \left(a_{ij} - \sum_{k=1}^{i-1} q_{ki} q_{kj} \right), \quad i \in [1, w-1], \quad j \in [i+1, w].$$

Следующее соотношение определяет диагональные элементы:

$$q_{ii} = \sqrt{a_{ii} - \sum_{k=1}^{i-1} q_{ki}^2}, \quad i \in [1, w].$$

Также необходимо доопределить матрицу элементами ниже диагонали:

$$q_{ij} = 0, \quad j \in [1, w-1], \quad i \in [i+1, w].$$

При этом матрица A должна быть положительно-определённой.

Преобразованная выборка u имеет нулевое среднее значение и единичную дисперсию. В этой выборке также единична автоковариация, что снижает количество статистик, необходимых для анализа выборки. Предполагается, что в ряду отсутствуют трендовые компоненты.

Затем вычисляются следующие статистики:

$$d = \sum_{i=1}^w u_i / \sqrt{w \sum_{i=1}^w (u_i - \bar{u})^2}, \quad \sigma^2 = u^\top u, \quad \bar{u} = \frac{1}{w} \sum_{i=1}^w u_i.$$

Поскольку априори закон совместного распределения w -членов ряда неизвестен, то распределения статистик d и σ^2 строятся по заранее заданному нормальному участку ряда. По нему же предварительно производится вычисление матрицы Q и среднего μ . Таким

образом, процесс обучения модели строится на восстановлении функции эмпирического распределения для d_{train} и σ_{train}^2 :

$$d_{\text{train}}, \sigma_{\text{train}}^2 \rightarrow S'_{\text{train}}\{d_{\text{train}}\}, S''_{\text{train}}\{\sigma_{\text{train}}^2\},$$

где $S'_{\text{train}}, S''_{\text{train}}$ — функции распределения для каждой из статистик соответственно.

Дальнейшая процедура алгоритма заключается в проверке нулевой гипотезы для статистик $d_{\text{test}}, \sigma_{\text{test}}^2$ с построенными функциями распределения $S'_{\text{train}}, S''_{\text{train}}$ для обучающего участка и вычислении уровней значимости $p'(d_{\text{test}}), p''(\sigma_{\text{test}}^2)$:

$$p'(d) = P(d_{\text{test}} | S'_{\text{train}}),$$

$$p''(d) = P(\sigma_{\text{test}}^2 | S''_{\text{train}}).$$

Далее полученные уровни значимости сравниваются с заранее определённым диапазоном, заданным через параметр α , и формируется оценка S :

$$S = \begin{cases} 0, & \text{если } \alpha/(2w) < p'(d) < 1 - \alpha/(2w); \\ 0, & \text{если } \alpha/(2w) < p''(\sigma_{\text{test}}^2) < 1 - \alpha/(2w); \\ 1 & \text{иначе,} \end{cases} \quad S = \{0; 1\}. \quad (4)$$

При движении окном шириной w по участку ряда длиной N такому, что $N > w$, некоторые точки получают более одной оценки S . Действительно, если даже $N = w + 1$, то будет получено две группы оценок для точек $2, \dots, w - 1$. Для увеличения стабильности итоговой оценки все имеющиеся оценки для каждой точки усредняются и сигнал «аномалия» выдаётся при превышении средней оценкой некоторого наперёд заданного критического значения параметра l . Таким образом,

$$s = \begin{cases} 0, & \text{если } \frac{1}{N} \sum_{i=1}^N S_i < l; \\ 1 & \text{иначе.} \end{cases} \quad (5)$$

Это позволяет регулировать чувствительность алгоритма и уменьшить количество ложноположительных предсказаний.

Алгоритм имеет следующие гиперпараметры: критическое значение достигаемого уровня значимости α , ширина окна w , порог оценки l . Обучение алгоритма производится на участке анализируемого ряда, который априори считается нормальным. Таким образом, данная реализация статистического алгоритма выявления аномалии имеет следующие преимущества:

- а) отсутствует необходимость в априорной информации об аномалиях;
- б) анализ характеристик в скользящем окне и усреднение оценок дают более стабильный уровень обнаружения;
- в) преобразование выборки позволяет анализировать минимальное количество статистик.

Результаты. В данной работе представлены результаты применения предложенного подхода к набору данных [15]. Для инициализации модели обнаружения $M(\theta, H_{\text{train}})$ использовались следующие параметры: $\theta = \{\alpha = 0,01, l = 0,9, w = [120-500]\}$. Параметр $\alpha = 0,01$ для проверки нулевой гипотезы по (4) выбран как стандартный в подобных статистических задачах. Порог формирования оценки по (5) $l = 0,9$ определён эмпирически как




Рис. 4. Зависимость F_1 от IMF при $w = 120$

локально оптимальный для баланса между ошибками первого и второго рода для набора данных, окно w анализа варьировалось в интервале [120–500] с шагом в 60 значений.

На рис. 3 показано, что для каждой полученной IMF рассчитываются собственная модель обнаружения и матрица предсказаний для каждого уровня разложения. Для расчёта итоговой точности модели необходимы предсказания только одного уровня разложения. Эксперименты показали, что для такого набора данных наиболее информативной является первая IMF — высокочастотная составляющая сигнала, которая содержит наибольшую информацию об аномалиях. На рис. 4 для упрощения представлен график зависимости метрики F_1 от уровня разложения IMF для некоторых сигналов. Метрика классификации определяется как

$$F_1 = \frac{tp}{tp + (fp + fn)/2},$$

где tp — истинно положительные, fp — ложноположительные, fn — ложноотрицательные срабатывания.

Тренд, представленный на графике, сохраняется для всех сигналов из рассматриваемого набора данных. Из графика (см. рис. 4) следует, что наиболее высокая точность обнаружения достигается при IMF_1 . Это обусловлено тем, что природа аномалий в этом наборе данных такова, что основная информация о них концентрируется в высокочастотной области. Для последующих IMF точность значительно снижается при окне анализа $w = 120$. При окне анализа $w = 500$ наблюдаются локальные улучшения точности с переходом IMF в низкочастотную область, однако в среднем IMF_1 также даёт более высокую точность.

С учётом данной информации был произведён расчёт точности для всего набора при IMF_1 . В табл. 1 представлены результаты следующих расчётов: STAT — статистическая модель без применения каких-либо преобразований сигнала; WWT — модель с предварительным применением ВП; ННТ — предложенный подход с применением модели с ПГХ.

Полученные результаты подтверждают эффективность и высокую точность предложенного подхода. Сравнительный анализ показывает не только высокую точность алгоритма, но и его преимущество перед другими подходами. Как видно из табл. 1, преимущество достигает **32,95** в максимальном случае и сопоставимо в худшем случае. Разница между ВП и ПГХ также свидетельствует в пользу предложенного подхода. Следует заметить, что для модели с ВП не производился поиск оптимальной базисной функции и параметров разложения. Именно в этом состоит и одно из преимуществ предложенного подхода.

Таблица 1

Оценка точности различных моделей обнаружения (%)

Номер сигнала	STAT F_1	WWT F_1	ННТ F_1	Разница ННТ – STAT	Разница ННТ – WWT	Разница WWT – STAT
1	90,76	96,00	99,45	+8,69	+3,45	+5,24
2	73,45	87,29	98,29	+24,84	+11,01	+13,84
3	62,51	62,88	92,80	+30,28	29,92	+0,37
4	92,61	99,55	95,71	+3,11	-3,83	+6,94
5	52,09	67,82	85,04	+32,95	17,22	+15,73
6	80,99	88,92	88,91	+7,92	-0,01	+7,93
7	98,21	94,33	98,50	+0,29	4,17	-3,88
8	64,73	77,81	94,69	+29,96	16,89	13,08
9	79,29	90,67	95,09	+15,80	4,42	11,38




Рис. 5. Визуализация результатов: *a* — обучающий сигнал; *b* — тестовый сигнал; *c* — предсказание моделей

На рис. 5 представлена визуализация работы подхода на примере сигнала 1. На этом примере показана аномалия типа «уменьшение дисперсии» — одна из самых сложных для выявления. Противоположный случай является более простым с точки зрения визуального выявления аномалии, так как амплитуда сигнала изменяется в широких пределах, отличных от штатного участка. Уменьшение дисперсии представляет более интересный случай, так как кривая, описывающая сигнал, становится более гладкой, оставаясь в пределах амплитуды обучающего сигнала (рис. 5, *c*). Однако после применения ПГХ аномальный участок выражено локализуется, тем самым давая возможность выявить этот случай при проверке левой альтернативной гипотезы по (4).

Рассмотрим также плотности распределений для исходных нормального и тестового сигналов и образов Гильберта для тех же сигналов после преобразования (2), (3). Для сигналов без каких-либо преобразований (рис. 6, *a*) распределения имеют достаточно одинаковую форму, но смещены относительно друг друга, однако «хвосты» распределений слева

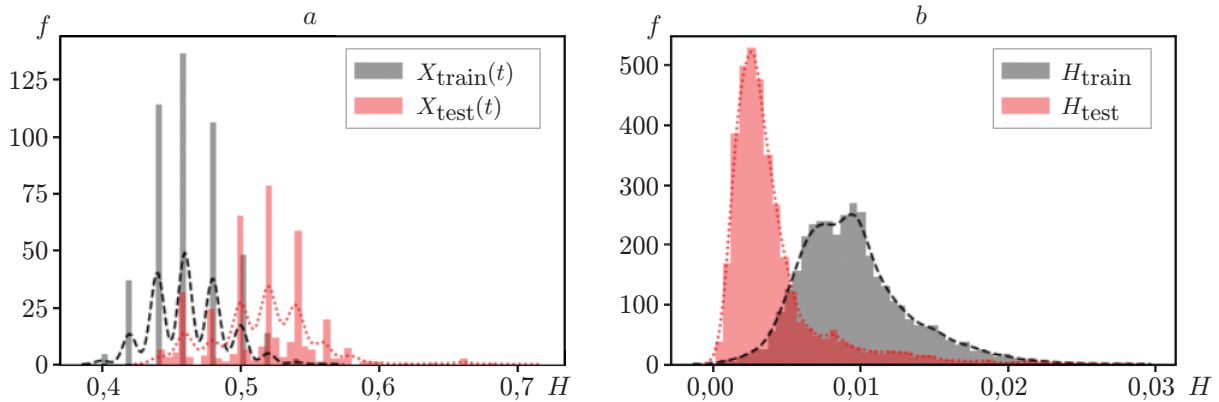


Рис. 6. Плотность распределения сигналов при уменьшении дисперсии: *a* — исходные нормальный и тестовый сигналы; *b* — образ Гильберта нормального и тестового сигналов

и справа совмещаются. Данное явление затрудняет обнаружение аномалий, так как при проверке двусторонней альтернативной гипотезы по (4) повышается вероятность ошибок первого рода. В случае с образами Гильберта тестовое распределение оказывается в левом «хвосте» нормального распределения и выявляется при проверке левой альтернативной гипотезы.

Даже визуально аномалии не всегда выражены отчётливо, однако плотности распределений дают более ясную картину. Таким образом объясняется преимущество спектральных методов обнаружения аномалий. Как было показано, в некоторых случаях невозможно обнаружить аномалию без частотно-временной информации, так как статистические показатели амплитуды сигнала практически не отличимы для тестового и обучающего сигналов.

Заключение. В данной работе предложен оригинальный подход к обнаружению аномалий в технологических сигналах с применением статистического классификатора и преобразования Гильберта — Хуанга. Суть подхода состоит в использовании свойств ПГХ для локализации аномальных участков в частотно-временной области сигнала и дальнейшей оценке статистик сигнала в плавающем окне.

Основными преимуществами предложенного подхода являются:

- 1) адаптивность разложения ПГХ, позволяющая получать высокую частотно-временную детализацию аномальных участков сигнала с учётом свойств его инерционности;
- 2) усреднённые и стабильные предсказания аномалий с минимальным количеством статистик за счёт оценки безусловного совместного распределения в скользящем окне;
- 3) реализация модели не требует априорных знаний об аномалиях в случае технологических объектов, которые большую часть времени работают в штатном режиме.

В результате численных экспериментов продемонстрирована высокая эффективность и точность предложенного подхода. Тестирование метода производилось на реальных технологических сигналах с моделированием разных типов аномалий. Средняя точность составила более 94 % по всему набору данных, что свидетельствует о пригодности подхода в реальных прикладных системах мониторинга технологических объектов. В работе также представлен сравнительный анализ предложенного подхода и метода с использованием вейвлет-преобразования. Новый подход продемонстрировал улучшение по метрике F_1 до 20 %.

Финансирование. Данная работа выполнена при поддержке Российского фонда фундаментальных исследований (проект № 19-37-90124), а также Томского государственного университета (проект № 8.1.62.2018).

СПИСОК ЛИТЕРАТУРЫ

1. Мурзагулов Д. А., Замятин А. В. Адаптивные алгоритмы машинного обучения в управлении технологическими процессами // Автоматизация. Современные технологии. 2018. **72**, № 8. С. 354–361.
2. Chuang S.-Y., Sahoo N., Lin H.-W., Chang Y.-H. Predictive maintenance with sensor data analytics on a raspberry Pi-based experimental platform // Sensors (Switzerland). 2019. **19**, N 18. 3884. DOI: 10.3390/s19183884.
3. Шваб К. Э. Четвертая промышленная революция. М.: Эксмо, 2016. 208 с.
4. Braei M., Wagner S. Anomaly Detection in Univariate Time-series: A Survey on the State-of-the-Art. URL: <https://arxiv.org/abs/2004.00433v1> (дата обращения: 13.08.2020).
5. Murzagulov D. A., Zamyatin A. V., Ostrast P. M. Approach to detection of anomalies of process signals using classification and wavelet transforms // Proc. of the Intern. Russian Automation Conference (RusAutoCon 2018). Sochi, 9–16 Sept., 2018. Vol. 1, 2. New York: IEEE, 2018. P. 492–495.
6. Дятлов Д. В., Димаки А. В., Светлаков А. А. Программный имитатор промышленных электрических помех, воздействующих на датчики измеряемых величин и каналы связи между аппаратными средствами АСУ ТП // Доклады ТУСУР. 2012. № 2–1. С. 205–213.
7. Жилияков Е. Г. Построение трендов отрезков временных рядов // Автоматика и телемеханика. 2017. Вып. 3. С. 80–95.
8. Айфичер Э., Джервис Б. Цифровая обработка сигналов. Практический подход. М.: Вильямс, 2004. 992 с.
9. Балакирев Н. Е., Гуснин С. Ю., Малков М. А., Червяков Л. М. Фильтрация речевого сигнала с помощью вейвлет-преобразования при решении задач распознавания речи // Изв. ЮЗГУ. 2012. № 5–2 (44). С. 44–50.
10. Шеннон К. Э. Математическая теория связи. Работы по теории информации и кибернетике. М.: Изд-во иностранной лит-ры, 1963. С. 243–333.
11. Huang N. E., Shen Z., Long S. R. et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis // Proc. of the Royal Soc. A. 1998. **454**. P. 903–995.
12. Huang N. E., Shen S. S. P. The Hilbert — Huang transform and its applications. Singapore: World Scientific Publishing Co. Pte. Ltd, 2005. 311 p.
13. Ястребов И. П. О свойствах и применениях преобразования Гильберта-Хуанга // Проектирование и технология электронных средств. 2016. № 1. С. 26–33.
14. Gavrin S., Murzagulov D., Zamyatin A. Anomaly detection in process signals within machine learning and data augmentation approach // Proc. of the 15th Intern. Conference on Machine Learning and Data Mining in Pattern Recognition (MLDM 2019). New York, USA, 20–25 July 2019. Vol. 2. Leipzig: Ibai-publishing, 2019. P. 585–598.
15. Фролов А. В., Воеводин В. В., Коньшин И. Г., Теплов А. М. Исследование структурных свойств алгоритма разложения Холецкого: от давно известных фактов до новых выводов // Вестн. УГАТУ. 2015. **19**, № 4 (70). С. 149–162.

Поступила в редакцию 13.08.2020

После доработки 08.10.2020

Принята к публикации 23.11.2020