

*А. И. Долгий, С. М. Ковалев, А. Н. Гуда*

## ИНТЕЛЛЕКТУАЛЬНЫЙ МОНИТОРИНГ ПЕРЕВОЗОЧНЫХ ПРОЦЕССОВ НА ОСНОВЕ ДИНАМИЧЕСКОГО МЕТОДА ГЛАВНЫХ КОМПОНЕНТ

**Аннотация.** Рассматривается новая технология интеллектуального мониторинга процессов железнодорожных перевозок с использованием динамического метода главных компонент. Она включает рекурсивный алгоритм вычисления главных признаков и три статистических критерия, используемых в механизме принятия решений. Применение предложенной схемы демонстрирует реализуемость и эффективность рекурсивных алгоритмов адаптивного мониторинга сложных слабоформализованных процессов в онлайн-режиме.

Поскольку в большинстве технологических процессов происходят медленные, эволюционирующие изменения, такие как старение напольного оборудования, дрейфы датчиков, периодическое обслуживание и модернизация технических средств, ожидается, что предложенная в статье схема адаптивного мониторинга найдет широкое применение на железнодорожном транспорте.

**Ключевые слова:** интеллектуальный мониторинг, рекурсивный алгоритм вычисления, потоковые данные, слабоформализованные процессы, сортировочные станции, интеллектуальный анализ, машинное обучение, объем перевозок, пропускная способность.

**Для цитирования:** Долгий, А. И. Интеллектуальный мониторинг перевозочных процессов на основе динамического метода главных компонент / А. И. Долгий, С. М. Ковалев, А. Н. Гуда // Вестник Ростовского государственного университета путей сообщения. – 2023. – № 2. – С. 240–251. – DOI 10.46973/0201-727X\_2023\_2\_240.

### **Введение**

Технологии мониторинга возникли в результате эволюции ряда научных направлений в области контроля и диагностики, и в настоящее время широко используются для получения достоверных данных о поведении контролируемого объекта с целью повышения эффективности управления им. Интеллектуальный мониторинг (ИМ) отличается наличием дополнительной функции – извлечением знаний об объекте с целью использования их для прогнозирования его поведения при изменяющихся условиях функционирования. Основу ИМ составляют технологии интеллектуального анализа данных, машинного обучения и мягких вычислений [1–4].

Наиболее эффективным приложением ИМ являются слабоформализованные технологические процессы, для которых невозможно построение точных аналитических моделей в силу высокой степени динамичности и неопределенности исходной информации, изменчивости условий функционирования, нелинейности параметров процесса и необходимости обработки потоковых данных в онлайн-режиме. Характерными примерами слабоформализованных процессов являются процессы управления железнодорожными перевозками (ПП) и, в частности, технологические процессы, протекающие на железнодорожных сортировочных станциях.

Основной задачей управления сортировочной станцией является поддержание оптимального режима работы станции путем регулирования интенсивности подвода поездов, процессов расформирования составов на сортировочной горке, а также путем планирования и корректировки процессов составаобразования. При этом выделяют две стадии управления ПП – планирование и оперативное управление [5]. На стадии планирования важно сбалансировать объем перевозок с пропускной способностью «ниток», а на стадии оперативного управления основной задачей является поддержание оптимальных режимов работы станции при различных изменяющихся условиях и состояниях ПП.

Решение поставленных задач возлагается на автоматизированные системы управления сортировочными станциями, которые обеспечивают контроль выполнения нормативных планов формирования и решают задачи по реализации этих планов. Однако основной проблемой здесь является то, что реальная эксплуатационная обстановка существенно отличается от нормативных условий: колеблются размеры вагонопотоков на прилегающих участках, изменяются объемы переработки на станции, возникают незапланированные перерывы в движении поездов, не обеспечивается готовность локомоти-

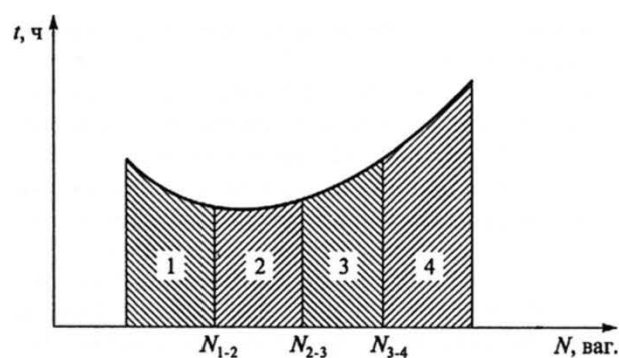
вов, колеблются продолжительности технологических операций и т. д. Все это предопределяет «неоптимальность» управления на основе сформированных ранее планов формирования и необходимость разработки новых моделей управления для подсистем АСУ ТП, обладающих способностью адаптации к реальным оперативным условиям. Поэтому принятый ОАО «РЖД» курс на повышение эффективности ПП диктует необходимость не ограничиваться разработкой нормативно-технологических документов и типовых методик организации ПП, необходимо добиваться их адаптации к реальной поездной обстановке и непрерывно изменяющимся условиям функционирования контролируемого объекта. Следует разрабатывать методики и алгоритмы управления, способные оперативно реагировать на изменения расчетных нормативов ПП в соответствии с изменяющимися технологическими ситуациями и состояниями ПП.

В настоящей статье рассматриваются концептуальные основы новой адаптивной технологии интеллектуального мониторинга слабоформализованных технологических процессов в изменяющихся условиях функционирования объекта автоматизации.

### 1 Объекты интеллектуального мониторинга

Условия работы сортировочной станции характеризуются рядом режимов или состояний, определяющих способность станции перерабатывать поступающий на ее вход вагонопоток [5]. Текущее состояние ПП на станции зависит от множества количественных и качественных факторов: содержания рабочего парка вагонов, интенсивности вагонопотоков на прилегающих участках, своевременности обеспечения сформированных составов локомотивами, наличия межоперационных простоев вагонов, состояния технических устройств и оборудования, квалификации работников и др. Достаточно объективной характеристикой режима работы станции является зависимость между рабочим парком вагонов на станции и временем их переработки. Качественный характер этой зависимости приведен на рис. 1. На основе данной зависимости выделяют четыре основных режима работы станции и, соответственно, четыре состояния ПП на станции.

*Нормальный режим* (см. рис. 1) характеризует своевременное выполнение технологических операций при отсутствии задержек поездов и межоперационных простоев вагонов. *Оптимальный режим* характеризуется теми же условиями, но при этом дополнительно обеспечивается минимальное время нахождения вагонов на станции. *Тяжелый режим* характеризуется содержанием избытка вагонного парка и наличием межоперационных простоев вагонов. *Критический (нештатный) режим* кроме содержания избытка вагонного парка и наличия межоперационных простоев вагонов отличают задержки поездов по неприему.



**Рис. 1. Режимы работы сортировочной станции:**  
1 – оптимальный, 2 – нормальный, 3 – тяжелый, 4 – критический

Одной из важных задач оперативного управления ПП является управление вагонопотоками путем регулирования насыщения участков поездами. Состояния ПП на участках характеризуются рядом параметров, среди которых важнейшими являются степень насыщенности участков поездами, интенсивности входных-выходных потоков и размеры движения. Поэтому для объективной категоризации состояний ПП на участках движения целесообразно использовать зависимости интенсивностей входных и выходных вагонопотоков и зависимость размеров движения от насыщенности участка поездами (рис. 2).



Рис. 2. Зависимость размеров движения от насыщенности участка поездами

На основе приведенных зависимостей можно выделить основные режимы поездной работы и, соответственно, основные состояния ПП на участке. Нормальный режим (область 1) характеризуется выполнением нормативного графика движения поездов. В оптимальном режиме (область 2) к тому же реализуются максимальные размеры движения. Тяжелый режим (область 3) характеризуется перенасыщением участка поездами. В критическом режиме (область 4) перенасыщение участка поездами приводит к дефициту локомотивных бригад и необходимости «бросания» поездов на промежуточных станциях.

В зависимости от состояний ПП решаются различные задачи управления поездной работой. В нормальном и оптимальном режимах требуется обеспечение установленных нормативов графиков движения, предотвращение перенасыщения участков поездами и станций вагонным парком. Тяжелые и критические режимы соответствуют особым классам нештатных состояний ПП, требующих быстрой ликвидации перенасыщения участков поездами путем предотвращения распространения сбоев движения поездов и восстановления нормального режима.

Очевидно, что в нештатных состояниях наиболее сложно принимать оптимальные решения, поэтому важнейшей задачей ИМ является предсказание появления особых классов критических или нештатных состояний ПП, негативно влияющих на эффективность управления.

*Интеллектуальный мониторинг, осуществляемый на основе извлечения знаний о состояниях ПП и динамики их развития в изменяющихся условиях, реализует новое интегративное качество, позволяющее прогнозировать и предупреждать негативные варианты развития ПП. Отсюда вытекает основная функция интеллектуального мониторинга – прогнозирование, а основными объектами прогнозирования являются состояния ПП.*

В настоящее время часть задач по прогнозированию ПП решается в интегрированной системе организации вагонопотоков СЕТЬ-2, являющейся одной из подсистем автоматизированной системы организации движения поездов (АСОВ). Однако на сегодня эффективность прогностических моделей, реализованных в АСОВ, оказывается недостаточной, в первую очередь, в силу названных выше причин, связанных с изменчивостью внешних условий и существенными колебаниями параметров ПП. Для решения этих задач представляется целесообразным дополнить АСОВ новым классом прогностических моделей, реализованных в подсистеме интеллектуального мониторинга ПП.

## 2 Постановка задачи

Как было отмечено, реальный ПП характеризуется множеством нештатных состояний, поэтому одной из важнейших задач ИМ является обнаружение в онлайн-режиме аномальных (нештатных) состояний, нарушений и иных сбоев в мониторируемом объекте.

Для диагностирования нарушений важно располагать математической моделью ПП, однако, в силу чрезвычайной сложности технологических процессов перевозок построение для них каких-либо аналитических мониторинговых моделей практически невозможно. Ситуацию облегчает то, что для подобного рода процессов имеется возможность собрать большое количество данных и привлечь для их обработки методы искусственного интеллекта с целью построения подходящих прогностических или мониторинговых моделей. Анализ главных компонент (РСА) является наиболее популярным методом многофакторного анализа, используемым для этих целей и успешно применяемым во многих приложениях [6].

Основная идея РСА состоит в том, чтобы уменьшить размерность набора данных, состоящего из большого количества взаимосвязанных переменных, сохраняя при этом как можно больше вариаций, присутствующих в исходном наборе данных, и сокращая малозначимые переменные. Чтобы использовать РСА для ИМ, вначале создается модель РСА на основе собранных данных в нормальных

условиях протекания контролируемого процесса. После этого рассчитывается контрольный мониторинговый интервал на основе одного из критериев (например,  $T^2$  или SPE). На основе анализа полученных критериев обеспечивается возможность отслеживать поведение технологического процесса в онлайн-режиме с использованием статистических методов.

Однако, несмотря на очевидные успехи данной технологии, стандартный метод мониторинга на основе PCA имеет существенный недостаток – его нельзя использовать для мониторинга процессов с изменяющимися во времени параметрами. Когда происходит естественный дрейф или изменение рабочей области, возникает большое число ложноположительных «диагнозов», что требует организации динамической модели PCA, обладающей способностью эволюционировать во времени и подстраиваться под изменяющиеся условия.

### 3 Состояние проблемы

В последнее время все чаще появляются исследования по динамизации методов многофакторного анализа, включая PCA. Например, перспективный подход, сочетающий скользящее окно с рекурсивным обновлением модели PCA, предложен в [7]. В результате было показано, что рекурсия со скользящим по данным окном больше подходит для изменяющихся во времени процессов. Такой подход к адаптации получил название скользящее окно PCA (MWPCA). Быстрый MWPCA подходит для онлайн-приложений, однако до настоящего времени эффективный алгоритм обновления модели PCA не рассматривался. Один из перспективных вариантов PCA с движущимся окном был предложен в [8] для адаптивного мониторинга нелинейных процессов, но он требует больших вычислений, поэтому практически не применим в онлайн-режиме. Относительно недавняя разработка динамического мониторинга процессов на основе PCA (DPCA) предложена в Ригопулос [9], где представлена схема движущегося окна для идентификации адаптивной модели профиля бумагоделочной машины. Цинь [10] предложил несколько рекурсивных алгоритмов частичных наименьших квадратов (RPLS) для онлайн-моделирования динамических процессов и процессов управления автономными работами с большим количеством выборок данных. В [11] также рассматривается рекурсивный PCA для адаптивного мониторинга промышленных процессов с использованием модификации первого ранга и диагонализации Ланцоша. В [12] представлено два алгоритма RPCA, направленных на снижение стоимости вычислений без вычисления корреляционной матрицы. Но это также требует больших вычислительных затрат, поскольку рекурсивное вычисление и вычисление индексов DPCA достаточно сложны. Хорошие результаты в области динамизации PCA-технологии на основе новых двух статистических критериев представлены в [13].

Настоящее исследование, учитывающее проблемы, возникающие при использовании динамических PCA для мониторинга ПП, сосредоточено на разработке новой схемы адаптивного мониторинга изменяющихся во времени процессов с использованием преимуществ Dynamic PCA (DPCA). Для этого вводится модификация PCA на основе трех новых статистик и рекурсивного алгоритма.

### 4 Линейный PCA-анализ

Стандартный метод анализа главных компонент (PCA-анализ) основан на ортогональном разложении ковариационной матрицы переменных контролируемого процесса по направлениям, имеющим максимальные вариации данных. Целью при этом является поиск минимального числа факторов, способных правильно описать основные тенденции в исходном наборе данных.

Пусть  $p$  – количество измеряемых переменных;  $X$  –  $(n \times p)$ -матрица, представляющая нормированные с использованием уравнения (4.1) измерения;  $\Sigma$  – ковариационная  $(p \times p)$ -матрица для  $X$ .

$$x_j = \frac{x_j - c_j}{\sigma_j}, \quad (4.1)$$

где  $c_j$  и  $\sigma_j$  – соответственно среднее значение и дисперсия переменной  $x_j$ .

Строками  $X$  являются  $p$ -мерные векторы, соответствующие наблюдениям, а столбцами –  $n$ -мерные векторы, соответствующие переменным. Известно, что матрица  $\Sigma$  может быть преобразована в диагональную матрицу  $L$  с помощью ортонормированной  $(p \times p)$ -матрицы  $U$ , а именно,  $\Sigma = ULU^T$ . Столбцы  $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_p$  матрицы  $U$  известны как векторы загрузки главных компонент. Диагональные элементы  $\lambda_1, \lambda_2, \dots, \lambda_p$  матрицы  $L$  являются упорядоченными собственными значениями матрицы  $\Sigma$ . Они представляют дисперсии переменных  $x_j$  в новом ортонормированном базисе, определяемом собственными векторами матрицы  $\Sigma$ . PCA-преобразование определяется выражением

$$T = XU \text{ или } \theta_i = Xu_i,$$

которое может быть представлено в виде

$$X = TU' = \sum_{i=1}^p \theta_i u_i', \quad (4.2)$$

где  $(n \times p)$ -матрица  $T = \theta_1, \theta_2, \dots, \theta_p$  содержит так называемые оценки главных компонент, которые определяются как наблюдаемые значения главных компонент для всех  $n$  наблюдений. Пары  $\theta_i, u_i$  в (4.2) расположены в порядке убывания соответствующих  $\lambda_i$ .

На практике обычно не требуется вычислять все  $p$  собственных векторов, поскольку большая часть вариаций данных может быть зафиксирована в нескольких первых PCA-компонентах. Было установлено, что обычно достаточно первых двух-трех компонент для описания основных закономерностей в данных, что принципиально упрощает мониторинг.

Для  $a < p$  получаем разложение:

$$X = \theta_1 u_1^T + \theta_2 u_2^T + \theta_a u_a^T + X_{rez} = X_{pc} + X_{rez},$$

где  $X_{rez}$  – остаточный член.

Использование PCA-анализа в ИМ реализуется в несколько этапов. Вначале на основе множества данных  $X$ , соответствующих нормальному состоянию ТП, с использованием PCA-анализа формируется минимальный набор новых оценочных переменных  $\theta_1, \theta_2, \dots, \theta_p$ , описывающих основные тенденции в  $X$ . Затем формируется статистика вариаций переменных в пространстве  $X_{pc}$  или  $X_{rez}$  для целей диагностики. Диагностика осуществляется путем сравнения статистических PCA-критериев с пороговыми значениями, как будет рассмотрено далее.

### 5 Динамический PCA-анализ

Основным инструментом ИМ является динамический PCA-анализ (DPCA) [13], ориентированный на анализ потоковых данных, представленных в виде многомерных временных рядов  $X = \{x_i\}$ . Элементами временного ряда  $X$  являются векторы числовых значений  $x_i = (x_{i1}, x_{i2}, \dots, x_{im})$ , описывающих параметры контролируемого объекта (ТП) в  $i$ -й момент времени.

В основу разработки DPCA положен принцип «скользящего окна» – трансформация исходного потока данных  $\{x_i\}$  в последовательность коротких наблюдений – временных рядов  $\{x_i, x_{i+1}, \dots, x_{i+s+1}\}$ . Последняя является окном анализа размерностью  $s$ , зависящей от специфики задачи. Поступающий на вход DPCA поток данных преобразуется в матрицу наблюдений:

$$X_s = \begin{bmatrix} x_1^T & x_2^T & \dots & x_s^T \\ x_2^T & x_3^T & \dots & x_{s+1}^T \\ \vdots & \vdots & \ddots & \vdots \\ x_N^T & x_{N+1}^T & \dots & x_{N+s-1}^T \end{bmatrix} \in \mathbb{R}^{N \times sm}$$

Матрица наблюдений за потоком данных  $x(t)$  с окном анализа  $s$ , где  $x_i \in \mathbb{R}^m$  ( $i = 1, \dots, N + s + 1$ ) обозначает нормализованный вектор наблюдений из  $m$  параметров ТСТП. Уравнение нормализации выглядит следующим образом:

$$x_j = \frac{x_j^0 - b_j^0}{\eta_j^0}, \quad (5.1)$$

где  $b_j^0$  и  $\eta_j^0$  – соответственно среднее значение и дисперсия  $j$ -й переменной  $x_j^0$ ;  $x_j^0$  – исходные данные;  $j = 1, \dots, m$ .

На основе (5.1) формируется корреляционная  $(s \times s)$ -матрица:

$$R_X = \frac{1}{n-1} X^T \times X. \quad (5.2)$$

Для корреляционной матрицы  $R_X$  вычислим матрицу собственных векторов-столбцов  $P$  с соответствующим множеством собственных значений  $\lambda_i$  ( $i = 1, \dots, s$ ). Упорядочим столбцы матрицы  $P$  по мере убывания собственных значений и выберем  $k$  первых векторов с наибольшими значениями

$\lambda_i (k < s)$ . В этом случае упорядоченную матрицу собственных векторов  $P_{ord}$  можно представить в виде объединения двух матриц:

$$P_{ord} = [P_{pc} \ P_{res}] \in \mathbb{R}^{s \times s}, \quad (5.3)$$

где  $P_{pc} \in \mathbb{R}^{s \times k}$  – матрица главных компонент;  $P_{res} \in \mathbb{R}^{s \times (s-k)}$  – матрица «остатков».

Матрица  $P_{pc}$  определяет для исходного пространства  $X \subset \mathbb{R}^s$  новое редуцированное пространство переменных  $Z_{pc} \subset \mathbb{R}^k$  путем преобразования  $Z_{pc} = X \times P_{pc}$ , а матрица  $P_{res}$  представляет собой «остаточное пространство»  $Z_{res} = X \times P_{res}$ , характеризующее ошибку аппроксимации исходных данных  $X$ . Диагональная матрица  $\Lambda$ , содержащая упорядоченные по убыванию дисперсии  $\sigma_i^2$  переменных наблюдений  $x_i$ , определяется следующим образом:

$$\Lambda = P_{ord}^T \times R_X \times P_{ord}. \quad (5.4)$$

По аналогии с (2.3) дисперсии новых переменных можно представить в виде объединения диагональных матриц  $\Lambda_{pc}$  и  $\Lambda_{res}$ :

$$\begin{aligned} \Lambda &= \begin{bmatrix} \Lambda_{pc} & \\ & \Lambda_{res} \end{bmatrix}, \\ \Lambda_{pc} &= \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_k^2) \in \mathbb{R}^{k \times k}, \\ \Lambda_{res} &= \text{diag}(\sigma_{k+1}^2, \dots, \sigma_s^2) \in \mathbb{R}^{(s-k) \times (s-k)}, \end{aligned} \quad (5.5)$$

где  $\sigma_1^2, \sigma_2^2, \dots, \sigma_s^2$  упорядочены следующим образом:  $\sigma_1^2 > \sigma_2^2 > \dots > \sigma_s^2$ .

Таким образом, в основу DPCA-анализа положены выражения (5.2)–(5.5), на основании которых осуществляется преобразование входного потока данных  $X$  в новое редуцированное пространство переменных  $Z_{pc}$ . Вновь образованные на основе DPCA пространства переменных  $Z_{pc}$  и  $Z_{res}$  дают возможность на их основе формирование нескольких важных статистик для переменных  $z \in Z_{pc}$  и  $z \in Z_{res}$  в целях ИМ.

### 6 Три статистики DPCA-анализа в интеллектуальном мониторинге

Для обнаружения и идентификации нарушений на основе технологий DPCA-анализа используются диагностические статистики – вероятностные распределения целевых параметров контролируемого объекта. На практике наиболее часто используются две статистики:  $T^2$  – статистика, контролирующая отклонения параметров  $x_t$  в пространстве главных компонент  $Z_{pc}$ , и  $SPE$  – статистика, контролирующая отклонения параметров  $x_t$  в пространстве невязок  $Z_{res}$ . Статистики  $T^2$  и  $SPE$  формируются на данных, полученных в нормальных состояниях контролируемого ТП. При превышении значениями  $x_t$  пороговых оценок хотя бы для одной из статистик принимается гипотеза о возникновении нештатной ситуации или нештатного состояния ТП.

В нормальных условиях функционирования ТП матрица главных компонент  $P_{pc}$  в силу свойств PCA-разложения несет основную информацию о процессе, а следовательно, при стабильных параметрах ТП, находящегося в нормальном состоянии, значения новых параметров  $\mathbf{z}_{pc}$ , извлеченных путем PCA-редукции из исходных параметров  $\mathbf{x}$ , подчиняются нормальному закону распределения:

$$\mathbf{z}_{pc} = \mathbf{P}_{pc}^T \mathbf{x} \in \mathbb{R}^k, \quad \mathbf{z}_{pc} \sim N(0, \mathbf{P}_{pc}^T \mathbf{R} \mathbf{P}_{pc}) = N(0, \Lambda_{pc}). \quad (6.1)$$

По аналогии, для переменных  $\mathbf{z}_{res}$  в остаточном пространстве невязок  $Z_{res}$  также имеет место нормальный закон распределения:

$$\mathbf{z}_{res} = \mathbf{P}'_{res} \mathbf{x} \in \mathbb{R}^{(s-k)}, \quad \mathbf{z}_{res} \sim N(0, \mathbf{P}'_{res} \times \mathbf{R} \times \mathbf{P}_{res}) = N(0, \Lambda_{res}). \quad (6.2)$$

Для оперативно поступающих на вход мониторинговой системы данных  $x \in \mathbb{R}^m$  критерии  $T^2$  и  $SPE$  рассчитываются в режиме онлайн следующим образом:

$$\begin{aligned} T^2 &= x^T \mathbf{P}_{pc} \Lambda_{pc} \mathbf{P}_{pc}^T x, \\ SPE &= \|(I - \mathbf{P}_{pc} \mathbf{P}_{pc}^T) x\|^2 = x^T (I - \mathbf{P}_{pc} \mathbf{P}_{pc}^T)^2 x. \end{aligned}$$

Помимо указанных двух статистик для целей мониторинга авторы вводят новую  $E$ -статистику, характеризующую ошибку предсказания системной предиктивной модели.

Предиктивная модель, являющаяся неотъемлемым элементом любой мониторинговой системы, предназначена для прогнозирования целевой переменной. В рассматриваемой предметной области в качестве целевых переменных выступают темпоральные переменные, характеризующие времена выполнения технологических операций, и/или силовые переменные, характеризующие интенсивность вагонопотоков, плотность или численность подвижных единиц, находящихся в вагонных парках или на отдельных участках движения.

Предиктивная модель относится к классу адаптивных эволюционирующих систем, основанных на гибридизации нечетких TS-моделей с методами машинного обучения и специальным механизмом инкрементного обновления базы знаний [14]. Механизм онлайн-обучения гибридных предиктивных моделей ( $eTS$ ) обеспечивает способность  $eTS$  в пошаговом (инкрементном) режиме подстраиваться под изменяющийся поток входных данных. Эффективность функционирования предиктивной  $eTS$  оценивается достоверностью вырабатываемых на ее основе прогностических решений.

Прогнозирование целевой переменной осуществляется в режиме онлайн на основе потоковых данных, представленных в виде пар числовых значений  $\mathbf{z}_t = (\mathbf{x}_t, \tau_t)$ . Первая компонента  $\mathbf{x}_t$  в кортеже  $\mathbf{z}_t$ , характеризует вектор текущих параметров ТП, а вторая – фактическое значение  $\tau_t$  целевого темпорального параметра, которое модель пытается предсказать. Цель инкрементного обучения состоит в том, чтобы по мере поступления образцов данных  $\mathbf{x}_t$  ( $t = 1, 2, \dots$ ) как можно точнее предсказывать значения целевой переменной  $\tau_t$ . Предсказание  $\hat{\tau}_t = F(\mathbf{x}_t, eTS_{t-1})$  выполняется исключительно на основе текущего вектора  $\mathbf{x}_t$  и ранее сформированной модели  $eTS_{t-1}$ , после чего фактическая оценка  $\tau_t$  целевой переменной сравнивается с предсказанным теоретическим значением  $\hat{\tau}_t$  и вычисляются потери  $\mathcal{L}(\tau_t, \hat{\tau}_t)$ . Обычно потери определяются через квадрат разности между фактическими и теоретическими оценками целевой переменной.

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (\tau_t - \hat{\tau}_t)^2}. \quad (6.3)$$

На практике для оценки потерь часто используется безразмерный индекс ошибок (NDEI) [10], определяемый как отношение среднеквадратичной ошибки к стандартному отклонению целевой переменной:

$$NDEI = \frac{RMSE}{\sigma_\tau}. \quad (6.4)$$

В нормальных условиях протекания ТП индекс ошибки NDEI, являющийся случайной величиной, так же как и два выше рассмотренных статистических индекса  $T^2$  и  $SPE$ , подчиняется нормальному закону распределения:

$$\varepsilon \in \mathbb{R}, \quad \varepsilon \sim N\left(C, \frac{RMSE}{\sigma_\tau}\right). \quad (6.5)$$

$\varepsilon$  – ошибка предсказания, вычисляемая на основании (),  $C$  – усредненное значение индекса ошибки за  $N$  измерений.

При возникновении нештатных технологических ситуаций или в преддверии аномального состояния контролируемого технологического процесса (ТП) следует ожидать появления дрейфа во входном потоке данных, сопровождающие течение ТП. Дрейф приводит к изменению статистических законов  $T^2$ ,  $SPE$ ,  $NDEI$ , что формально определяется следующим образом:

$$\exists t \in T \mid N_t(z_{pc}) \neq N_{t+1}(z_{pc}) \vee N_t(z_{rez}) \neq N_{t+1}(z_{rez}) \vee N_t(\varepsilon) \neq N_{t+1}(\varepsilon). \quad (6.6)$$

Обнаружение дрейфа является одной из основных задач ИМ, поэтому выражение (6.6) положено в основу одного из основных диагностических правил мониторинговой системы.

### 7 Рекурсивный DPCA-анализ

Для реализации ИМ в онлайн-режиме необходим механизм «быстрого» DPCA-анализа, подобно механизмам быстрого Фурье-преобразований, используемых при цифровой обработке сигналов. Для решения этой задачи ниже предлагается рекурсивная схема DPCA-анализа.

Для реализации рекурсивных вычислений в первую очередь необходимо иметь возможность вычислять корреляционную матрицу  $R_t$  для любого момента времени  $t$ . Однако затраты на вычисление и обновление структуры корреляционной матрицы достаточно велики, что неприемлемо для онлайн-приложений. Поэтому для обновления модели рассмотрим рекурсивную процедуру [13].

Пусть  $x_t^0 \in \mathfrak{R}^{sm}$  – входные данные в момент времени  $t$ , среднее значение в момент времени  $t-1$  равно:

$$c_{t-1} = \sum_{i=1}^{t-1} x_i^0 / (t-1). \quad (7.1)$$

Аналогично,  $c_t$  представляет собой среднее значение в момент времени  $t$ :

$$c_t = \sum_{i=1}^t x_i^0 / t. \quad (7.2)$$

Стоит отметить, что,

$$tc_t = (t-1)c_{t-1} + x_t^{0T}. \quad (7.3)$$

Далее уравнение (7.1) можно переписать как

$$c_{t-1} = \frac{t}{t-1} c_t - \frac{1}{t-1} x_t^{0T}. \quad (7.4)$$

Заметим, что,

$$\Delta c_t = c_t - c_{t-1}.$$

Опуская дальнейшие очевидные преобразования, получим итоговое выражение:

$$\Delta c_t = \frac{1}{t-1} (x_{t+1}^0 - c_{t+1}^T). \quad (7.5)$$

Из (7.4) вытекает следующее выражение:

$$R_t = \mu \Lambda_t^{-1} (\Lambda_{t-1} R_{t-1} \Lambda_{t-1} + \Delta c_t \Delta c_t^T) \Lambda_t^{-1} + (1-\mu) x_t^T x_t. \quad (7.6)$$

Если дисперсия существенно не меняется, мы можем использовать начальную дисперсию для масштабирования данных и не обновлять дисперсию. Тогда равнение (7.6) можно преобразовать в формулу:

$$R_t = \mu R_{t-1} + \mu \Lambda_t^{-1} \Delta c_t \Delta c_t^T \Lambda_t^{-1} + (1-\mu) x_t^T x_t, \quad (7.7)$$

где  $\mu = \frac{t-1}{t}$ ,  $x_t \in \mathfrak{R}^{sm}$  обозначает вектор в момент времени  $t$ .

Для дальнейшего обсуждения уравнение (7.7) можно переписать следующим образом:

$$R_t = \frac{t-1}{t} R_{t-1} + \frac{1}{t-1} x_t^T x_t, \quad (7.8)$$

Согласно алгоритму, предложенному в [13], корреляционная матрица может быть рекурсивно обновлена:

$$R_t = \varepsilon R_{t-1} + (1-\varepsilon) x_t^T x_t, \quad (7.9)$$

где множитель забывания  $\varepsilon$  – небольшое положительное число ( $\varepsilon \rightarrow 0$ ).

Далее, сингулярные значения и собственные векторы обновленной матрицы можно описать следующим образом:

$$\sigma_{t,i}^2 = \varepsilon \sigma_{t-1,i}^2 + (1-\varepsilon) P_{t-1,i}^T x_t x_t^T P_{t-1,i}, \quad (7.10)$$

$$P_{t,i} = P_{t-1,i} + \sum_{j=1}^m \lambda_{ji} P_{t-1,i}, \quad (7.11)$$

где  $i, j = 1, \dots, m$ ;  $c_{ii} = 0$ .

Собственные значения обновляются следующим образом:

$$\lambda_{ji} = \frac{P_{t-1}^T x_{t-1} x_{t-1}^T P_{t-1}}{\sigma_{t-1,i}^2 - \sigma_{t-1,j}^2}. \quad (7.12)$$

Уравнения (7.1–7.12) составляют основу рекурсивного механизма DPCA-анализа.

### 8 Технология интеллектуального мониторинга

Технология ИМ в значительной мере сводится к детектированию нарушений. Обнаружение нарушений или нештатных состояний в поведении ТП обычно приводит к изменениям статистик: либо SPE, либо в T2, либо E-статистик. В этом случае данные статистики превышают пороговые оценки (контрольные пределы). Идентификация и реконструкция нарушений является более сложной задачей, которая в статье не рассматривается.

Пусть  $X$  – матрица исходных данных (наблюдений) размера  $n \times m$ , в которой строками являются отдельные выборки данных, а столбцами – переменные. Предполагается, что значения в  $X$  центрированы к нулевому среднему значению. PCA разлагает  $X$  на две компоненты:

$$X = TP^T + E = TP^T + \tilde{T}\tilde{P}^T \quad (8.1)$$

где  $T \in R^{n \times I}$  и  $P \in R^{m \times I}$  – матрицы оценок и нагрузок соответственно, а  $I$  – количество главных компонент, сохраненных в модели.

Матрица остатков  $E$ , в свою очередь, может быть представлена в виде произведения остаточных матриц оценок  $\tilde{T}$  и нагрузок  $\tilde{P}$ . Область значений  $P$  является подпространством главных компонент  $P_{pc}$  размерностью  $I$ , а область значений  $\tilde{P}$  образует остаточное подпространство  $P_{res}$  размерностью  $m-I$ .  $P$  и  $\tilde{P}$  также можно интерпретировать как собственные вектора ковариационной матрицы  $S = X \times X^T / (n - 1)$ , связанные с главными собственными значениями  $\Lambda = T' \times T$  и остаточными собственными значениями  $\tilde{\Lambda} = \tilde{T}' \times \tilde{T} / (n - 1)$  соответственно.

Вновь поступивший вектор данных  $x$  допускает разбиение на две части:

$$x = \hat{x} + \tilde{x}, \quad (8.2)$$

где

$$\hat{x} = PP^T x \in P_{pc} \quad (8.3)$$

и

$$\tilde{x} = (I - PP^T)x \in P_{res} \quad (8.4)$$

– проекции вектора  $x$  на пространства главных компонент PC и невязок RS соответственно.

Когда возникает нарушение, соответствующий вектор данных  $x$  может быть представлен как

$$x = x^* + \Xi_i f, \quad (8.5)$$

где  $\Xi_i \in R^{m \times I}$  – матрица, представляющая подпространство нарушений размерностью  $I$ , а  $\|f\|$  представляет величину нарушения.

При появлении нарушения вызвавший его образец данных  $x$ , очевидно, отклоняется от области нормальных значений параметров ТП, что сопровождается увеличением проекции  $x$  на пространства PC и/или RS. Диагностирование дрейфа осуществляется с использованием ранее рассмотренных статистик SPE, T<sup>2</sup> и E-статистики.

Одна из них, SPE, отражает вариации в пространстве невязок RS и характеризуется индексом:

$$SPE \equiv \|\tilde{x}\|^2 = \|(I - PP^T)x\|^2 \equiv \|\tilde{C}x\|^2 \quad (8.6)$$

Другая T<sup>2</sup>-статистика представлена индексом Хеттелинга:

$$T^2 = x^T P \Delta P^T x. \quad (8.7)$$

Третья статистика, E-статистика, отражает вариации ошибки предсказания eTS-модели.

Логика обнаружения дрейфа на основе DPCA-анализа представляется следующим продукционным правилом:

$$SPE > \delta^2 \vee T^2 > \chi_I^2 \vee \varepsilon > \sigma_\varepsilon \Rightarrow Dr, \quad (8.8)$$

где  $\delta^2$ ,  $\chi_I^2$  и  $\sigma_\varepsilon$  обозначают доверительные пороги для диагностических статистик  $T^2$ ,  $SPE$  и E-критерия, соответственно рассчитанные для нормальных состояний ТП.

### Заключение

В статье предложена новая технология интеллектуального мониторинга на основе рекурсивного динамического PCA-анализа. Она базируется на динамическом PCA-анализе, рекурсивной схеме вычислений главных компонент и адаптивной модели эволюционирующей нечеткой системы eTS, разработка которой подробно изложена в [14] поэтому в настоящей статье не приводится.

Применение предложенной схемы ИМ демонстрирует реализуемость и эффективность рекурсивных алгоритмов адаптивного мониторинга ТП. Алгоритм значительно снижает стоимость онлайн-вычислений.

Поскольку в большинстве технологических процессов происходят медленные, эволюционирующие изменения, такие как старение напольного оборудования, дрейфы датчиков, периодическое обслуживание и модернизация технических средств, ожидается, что предложенная в статье схема адаптивного мониторинга найдет широкое применение на железнодорожном транспорте.

### Список литературы

- 1 Аналитический обзор трудов конференции ИТИ'19 / С. М. Ковалев, В. Снашел, А. Н. Гуда [и др.] // Вестник Ростовского государственного университета путей сообщения. – 2020. – № 3. – С. 86–105. – DOI 10.46973/0201-727X\_2020\_3\_86.
- 2 Dolgiy, A. Intelligent Models for State Assessment and Behavior Prediction in Railway Processes Based on Descriptive Analytics and Soft Computing / A. Dolgiy, A. Khramtsov, S. Kovalev // Proceedings of the Sixth International Scientific Conference “Intelligent Information Technologies for Industry” (IITI'22). – Cham : Springer International Publishing, 2022. – P. 358–368. – ISBN 978-3-031-19619-5.
- 3 Khatlamadzhiyan, A. E. Cognitive Measurements and Predictive Analytics for Railway Infrastructure Components / A. E. Khatlamadzhiyan, S. M. Kovalev, V. B. Tarassov // International Conference on Intelligent Information Technologies for Industry. – Springer, Cham, 2021. – P. 513–526. – ISSN 2367-3370.
- 4 Laiton-Bonadiez, C. Industry 4.0 technologies applied to the rail transportation industry : A systematic review / C. Laiton-Bonadiez // Sensors. – 2022. – T. 22. – No. 7. – P. 2491. – DOI 10.3390/s22072491.
- 5 Levin, D. Yu. Dispatch control of car flows / D. Yu. Levin // Intelligent control systems in railway transport. Computer and mathematical modeling (ISUZhT–2019). – 2019. – P. 51–58. – ISSN 1992-3252.

### References

- 1 Analytical review of the proceedings of the IITI'19 conference / S. M. Kovalev, V. Snashel, A. N. Guda [et al.] // Vestnik Rostovskogo Gosudarstvennogo Universiteta Putey Soobshcheniya. – 2020. – No. 3. – P. 86–105. – DOI 10.46973/0201-727X\_2020\_3\_86.
- 2 Dolgiy, A. Intelligent Models for State Assessment and Behavior Prediction in Railway Processes Based on Descriptive Analytics and Soft Computing / A. Dolgiy, A. Khramtsov, S. Kovalev // Proceedings of the Sixth International Scientific Conference “Intelligent Information Technologies for Industry” (IITI'22). – Cham: Springer International Publishing, 2022. – P. 358–368. – ISBN 978-3-031-19619-5.
- 3 Khatlamadzhiyan, A. E. Cognitive Measurements and Predictive Analytics for Railway Infrastructure Components / A. E. Khatlamadzhiyan, S. M. Kovalev, V. B. Tarassov // International Conference on Intelligent Information Technologies for Industry. – Springer, Cham, 2021. – P. 513–526. – ISSN 2367-3370.
- 4 Laiton-Bonadiez, C. Industry 4.0 technologies applied to the rail transportation industry: A systematic review / C. Laiton-Bonadiez // Sensors. – 2022. – T. 22. – No. 7. – P. 2491. – DOI 10.3390/s22072491.
- 5 Levin, D. Yu. Dispatch control of car flows / D. Yu. Levin // Intelligent control systems in railway transport. Computer and mathematical modeling (ISUZhT–2019). – 2019. – P. 51–58. – ISSN 1992-3252.

6 PCA-SVM-based automated fault detection and diagnosis (AFDD) for vapor-compression refrigeration systems / H. Han, Z. Cao, B. Gu, N. Ren // HVAC&R Res. 16 (2010). – P. 295–313. – DOI 10.1080/10789669.2010.10390906.

7 Wang, J. A new subspace identification approach based on principle component analysis / J. Wang and S. J. Qin // Journal of Process Control. – 2002. – Vol. 12, No. 8. – P. 841–855. – DOI 10.1016/S0959-1524(02)00016-1.

8 Moving window kernel PCA for adaptive monitoring of nonlinear processes / X. Liu, U. Kruger, T. Littler [et al.] // Chemometrics and Intelligent Laboratory Systems. – 2009. – Vol. 96, No. 2. – P. 132–143. – DOI 10.1016/j.chemolab.2009.01.002.

9 Rannar, S. Adaptive batch monitoring using hierarchical PCA / S. Rannar, J. MacGregor and S. Wold // Chemometrics and Intelligent Laboratory Systems. – 1998. – Vol. 41, No. 1. – P. 73–81. – DOI 10.1002/cem.678.

10 Qin, S. J. Recursive PLS algorithms for adaptive data modeling / S. J. Qin // Computers & Chemical Engineering. – 1998. – Vol. 22, No. 4–5. – P. 503–514. – DOI 10.1016/S0098-1354(97)00262-7.

11 Recursive PCA for adaptive process monitoring / W. Li, H. Yue, S. Valle-Cervantes and S. Qin. Journal of Process Control. – 2000. – Vol. 10, No. 5. – P. 471–486. – DOI 10.1016/S0959-1524(00)00022-6.

12 Efficient recursive PCA algorithms for process monitoring / L. Elshenawy, S. Yin, A. Naik and S. Ding // Industrial Engineering Research. – 2010. – Vol. 49, No. 1. – P. 252–259. – DOI 10.1021/ie900720w.

13 A simplified recursive dynamic PCA based monitoring scheme for imperial smelting process / Z. Hu [et al.] // International Journal of Innovative Computing, Information and Control. – 2012. – V. 8, No. 4. – P. 2551–2561 – ISSN 1349-4198.

14 Kovalev, S. Incremental Structure-Evolving Intelligent Systems with Advanced Interpretational Properties / S. Kovalev, A. Kolodenkova, A. Sukhanov // Artificial Intelligence. RCAI 2020. Lecture Notes in Computer Science, Vol 12412. – 2020. – Springer, Cham. – ISSN 0302-9743.

6 PCA-SVM-based automated fault detection and diagnosis (AFDD) for vapor-compression refrigeration systems / H. Han, Z. Cao, B. Gu, N. Ren // HVAC&R Res. 16 (2010). – P. 295–313. – DOI 10.1080/10789669.2010.10390906.

7 Wang, J. A new subspace identification approach based on principle component analysis / J. Wang and S. J. Qin // Journal of Process Control. – 2002. – Vol. 12, No. 8. – P. 841–855. – DOI 10.1016/S0959-1524(02)00016-1.

8 Moving window kernel PCA for adaptive monitoring of nonlinear processes / X. Liu, U. Kruger, T. Littler [et al.] // Chemometrics and Intelligent Laboratory Systems. – 2009. – Vol. 96, No. 2. – P. 132–143. – DOI 10.1016/j.chemolab.2009.01.002.

9 Rannar, S. Adaptive batch monitoring using hierarchical PCA / S. Rannar, J. MacGregor and S. Wold // Chemometrics and Intelligent Laboratory Systems. – 1998. – Vol. 41, No. 1. – P. 73–81. – DOI 10.1002/cem.678.

10 Qin, S. J. Recursive PLS algorithms for adaptive data modeling / S. J. Qin // Computers & Chemical Engineering. – 1998. – Vol. 22, No. 4–5. – P. 503–514. – DOI 10.1016/S0098-1354(97)00262-7.

11 Recursive PCA for adaptive process monitoring / W. Li, H. Yue, S. Valle-Cervantes and S. Qin. Journal of Process Control. – 2000. – Vol. 10, No. 5. – P. 471–486. – DOI 10.1016/S0959-1524(00)00022-6.

12 Efficient recursive PCA algorithms for process monitoring / L. Elshenawy, S. Yin, A. Naik and S. Ding // Industrial Engineering Research. – 2010. – Vol. 49, No. 1. – P. 252–259. – DOI 10.1021/ie900720w.

13 A simplified recursive dynamic PCA based monitoring scheme for imperial smelting process / Z. Hu [et al.] // International Journal of Innovative Computing, Information and Control. – 2012. – V. 8, No. 4. – P. 2551–2561 – ISSN 1349-4198.

14 Kovalev, S. Incremental Structure-Evolving Intelligent Systems with Advanced Interpretational Properties / S. Kovalev, A. Kolodenkova, A. Sukhanov // Artificial Intelligence. RCAI 2020. Lecture Notes in Computer Science, Vol. 12412. – 2020. – Springer, Cham. – ISSN 0302-9743.

*A. I. Dolgiy, S. M. Kovalev, A. N. Guda*

## INTELLIGENT MONITORING OF THE TRANSPORTATION PROCESSES BASED ON THE DYNAMIC METHOD OF PRINCIPAL COMPONENTS

**Abstract.** The paper considers a new technology for intelligent monitoring of the railway transportation processes using the dynamic method of principal components. It includes a recursive principal feature calculation algorithm and three statistical criteria used in the decision engine. The application of the proposed scheme demonstrates the feasibility and efficiency of

recursive algorithms for adaptive monitoring of complex poorly formalized processes in on-line mode.

Whereas the most technological processes undergo slow, evolving changes, such as aging of floor equipment, sensor drifts, periodic maintenance and modernization of technical equipment, it is expected that the adaptive monitoring scheme proposed in the article will be widely used in railway transport.

**Keywords:** intelligent monitoring, recursive calculation algorithm, streaming data, poorly formalized processes, marshalling yards, intelligent analysis, machine learning, traffic volume, throughput.

**For citation:** Dolgiy, A. I. Intelligent monitoring of the transportation processes based on the dynamic method of principal components / A. I. Dolgiy, S. M. Kovalev, A. N. Guda // Vestnik Rostovskogo Gosudarstvennogo Universiteta Putey Soobshcheniya. – 2023. – No. 2. – P. 240–251. – DOI 10.46973/0201-727X\_2023\_2\_240.

#### Сведения об авторах

##### Долгий Александр Игоревич

АО «Научно-исследовательский и проектно-конструкторский институт информатизации, автоматизации и связи на железнодорожном транспорте» (НИИАС), кандидат технических наук, доцент, генеральный директор, e-mail: info@vniias.ru

##### Ковалев Сергей Михайлович

Ростовский государственный университет путей сообщения (РГУПС), кафедра «Автоматика и телемеханика на железнодорожном транспорте», профессор, Ростовский филиал АО «Научно-исследовательский и проектно-конструкторский институт информатизации, автоматизации и связи на железнодорожном транспорте» (РостФ НИИАС), главный научный сотрудник, доктор технических наук, профессор, e-mail: ksm@rfniias.ru

##### Гуда Александр Николаевич

Ростовский государственный университет путей сообщения (РГУПС), кафедра «Информатика», доктор технических наук, профессор, заведующий кафедрой, проректор по научной работе, e-mail: guda@rgups.ru

#### Information about the authors

##### Dolgiy Alexander Igorevich

JSC «NIAS», Candidate of Engineering Sciences, Associate Professor, General Manager, e-mail: info@vniias.ru

##### Kovalev Sergey Mikhaylovich

Rostov State Transport University (RSTU), Chair «Automatics and Remote Control on Railway Transport», Professor, JSC «NIAS», Rostov Branch, Chief Scientific Researcher, Doctor of Engineering Sciences, Professor, e-mail: ksm@rfniias.ru

##### Guda Alexander Nikolayevich

Rostov State Transport University (RSTU), Chair «Informatics», Doctor of Engineering Sciences, Professor, Head of the Chair, Vice Rector for Scientific Research, e-mail: guda@rgups.ru