



САНКТ-ПЕТЕРБУРГСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
ПРОМЫШЛЕННЫХ ТЕХНОЛОГИЙ
И ДИЗАЙНА




ВЫСШАЯ ШКОЛА
ТЕХНОЛОГИИ
И ЭНЕРГЕТИКИ
(ВШТЭ)

ISSN 3033-7852

ТЕХНОЛОГИЯ и ЭНЕРГЕТИКА

№01 (01) 2026

НАУЧНЫЙ ЖУРНАЛ



Поддерживаем
традиции качественного
образования

19 Разработка экспертной системы
для оптимизации режима сушки пиломатериалов
с целью минимизации брака в среде CLIPS

81 Автоматизация дозирования
и смешивания флокулянта

102 Расчет тепловых потерь через
скользящие опоры трубопроводов
тепловых сетей

Обзорная статья

УДК 66.096:004.04

DOI 10.46418/3033-7852_2026_1_1_73-80

ОПТИМИЗАЦИЯ СОСТАВА И РАСПОЛОЖЕНИЯ ДАТЧИКОВ ДЛЯ ДИАГНОСТИКИ НАРУШЕНИЙ СОСТОЯНИЯ ТЕХНОЛОГИЧЕСКИХ ПРОЦЕССОВ

Амаду Диалло¹, Дмитрий Александрович Ковалёв², Леон Абрамович Русинов¹¹Санкт-Петербургский государственный технологический институт (технический университет)²Санкт-Петербургский государственный университет промышленных технологий и дизайна

© Диалло А., Ковалёв Д. А., Русинов Л. А., 2026

Автор-корреспондент: Д. А. Ковалёв, e-mail: d.a.kovalyov@yandex.ru

АННОТАЦИЯ

Надежность и безопасность сложных технологических процессов (химических, целлюлозно-бумажных, нефтехимических и т. п.) в значительной степени зависят от возможности быстрого обнаружения, локализации и идентификации нарушений. Эффективность стратегий диагностики, будь то основанных на моделях или непосредственно на данных, неразрывно связана с конфигурацией сети датчиков. Задача заключается в определении оптимального количества и мест размещения датчиков, позволяющих гарантировать наблюдаемость, диагностируемость и информативность системы при минимизации инвестиционных и эксплуатационных затрат. В данной статье приведен сравнительный анализ основных методологий, используемых для определения оптимального состава и расположения датчиков на контролируемом технологическом процессе. Разнообразие методов отражает сложность и многомерность рассматриваемой проблемы, решение которой должно обеспечить высокую эффективность и надежные результаты диагностики, наблюдаемость, отказоустойчивость и минимизацию затрат. Анализ вывел фундаментальную разницу между методами, основанными на моделях, и методами, основанными на данных. Из анализа следует, что ни один метод не превосходит другие по всем характеристикам. Выбор зависит от контекста применения: наличия и качества доступной модели, размера и сложности системы, вычислительных ресурсов и времени, выделенного на оптимизацию, от природы диагностируемых нарушений и критичности требуемой эффективности и точности диагностики. Перспективным направлением представляется комбинирование этих методов для объединения их преимуществ. Например, простая модель может быть использована для предварительного отбора подмножества кандидатных датчиков, на котором будет применен более требовательный к вычислениям метод машинного обучения. Количественный анализ диагностируемости, который уже интегрирует стохастические аспекты, выиграл бы от совмещения с техниками кластеризации для сокращения пространства поиска конфигураций.

Ключевые слова: оптимальное размещение датчиков, диагностика нарушений, методы основанные на моделях, методы основанные на данных, генетические алгоритмы

Для цитирования: Диалло А., Ковалёв Д. А., Русинов Л. А. Оптимизация состава и расположения датчиков для диагностики нарушений состояния технологических процессов // Технология и энергетика. 2026. № 1 (1). С. 73–80. DOI: 10.46418/3033-7852_2026_1_1_73-80



OPTIMIZATION OF THE SENSOR SELECTION AND PLACEMENT FOR PROCESS FAULT DIAGNOSIS

Diallo Amadu¹, Kovalev Dmitriy Alexandrovich², Rusinov Leon Abramovich¹

¹Saint-Petersburg State Institute of Technology (Technical University),

²Saint-Petersburg State University of Industrial Technology and Design, St. Petersburg, Russia

Corresponding author: D. A. Kovalev, e-mail: d.a.kovalyov@yandex.ru

ABSTRACT

The reliability and safety of complex technological processes (chemical, pulp-and-paper, petrochemical, etc.) largely depend on the ability to quickly detect, localize, and identify faults. The effectiveness of diagnosis strategies, whether model-based or directly data-driven, is inextricably linked to the configuration of the sensor network. The task involves defining the optimal quantity and locations of sensors to guarantee system observability, fault detectability, and measurement informativeness, with simultaneous minimization of capital and operating expenses. This paper presents a comparative review of principal methodologies for optimal sensor selection and placement in process monitoring systems. The variety of methods reflects the complexity and multidimensionality of the problem being solved, the solution of which must ensure high diagnostic effectiveness, reliable results, observability, fault tolerance, and cost minimization. The analysis highlighted a fundamental difference between model-based methods and data-driven ones. The analysis shows that no single method outperforms the others in all characteristics. The choice depends on the application context: the availability and quality of an accessible model, the size and complexity of the system, the computational resources and time allocated for optimization, the nature of the faults being diagnosed, and the criticality of the required diagnostic efficacy and precision. A promising direction seems to be the combination of these methods to synergize their advantages. For example, a simple model can be used for the preliminary selection of a candidate sensor subset, on which a more computationally demanding machine learning method will then be applied. Quantitative fault diagnosability assessment that already accounts for stochastic elements could be enhanced by integration with clustering methods to prune the search space of possible configurations.

Keywords: optimal sensor placement, fault diagnosis, model-based methods, data-driven methods, genetic algorithms

For citation: Diallo A., Kovalev D. A., Rusinov L. A. Optimization of the sensor selection And placement for process fault diagnosis, Technology and Energy, vol. 1, no. 1, pp. 73–80. DOI: 10.46418/3033-7852_2026_1_1_73-80

ВВЕДЕНИЕ

Современная промышленность характеризуется растущей степенью автоматизации и повышенной сложностью технологических процессов [1]. К этим системам, будь то химические, целлюлозно-бумажные, нефтехимические или энергетические, предъявляются строгие требования к эффективности, качеству, безопасности и соблюдению экологических норм. В этом контексте любой отказ, вызванный деградацией компонента, неисправностью исполнительного механизма или аномальным отклонением переменной состояния (давление, температура, расход и т. д.), может иметь серьезные экономические и экологические последствия [2].

Для предотвращения этих рисков диагностика нарушений (Fault Diagnosis) стала важным элементом в системах управления технологическими процессами [3]. Ее цель тройственна: обнаружить возникновение нарушения, локализовать его и идентифицировать вышедший из строя компонент. Эффективность любой стратегии диагностики, будь то основанной на модели (model-based) или на данных (data-driven),

обусловлена доступной информацией. Эта информация предоставляется сетью датчиков, развернутой на процессе. Неисправный, неправильно размещенный или отсутствующий датчик может сделать нарушение необнаруживаемым или неидентифицируемым, сводя на нет эффективность алгоритмов диагностики.

Однако установка большого количества датчиков связана со значительными затратами на приобретение, установку и техническое обслуживание. И наоборот, недостаточное количество датчиков ставит под угрозу способность системы правильно обнаруживать, локализовать и идентифицировать нарушения. Проблема оптимальной установки датчиков как раз и направлена на нахождение компромисса между этими ограничениями путем определения минимального количества датчиков и их эффективного местоположения для обеспечения диагностируемости и надежности системы [4],[5] (1993, 1995). Таким образом, оптимальное количество датчиков — это наименьшее их число, которое одновременно удовлетворяет ограничениям наблюдаемости, диагностируемости



и требуемой точности, соблюдая при этом предопределенный бюджет.

В связи со сложностью этой проблемы было разработано множество методов. Их можно классифицировать на две основные группы. Первая объединяет методы, основанные на моделях, которые используют априорное знание о процессе в виде математических моделей (линейных или нелинейных, статических или динамических). В эту категорию входят классические подходы оптимизации, такие как алгоритм «ветвей и границ» (Branch and Bound), которые гарантируют оптимальное решение, но быстро становятся неприменимыми для больших систем. Метаэвристические методы, такие как генетические алгоритмы, позволяют решать задачи большей размерности, принимая субоптимальные решения. Наконец, более новые подходы, например, количественный анализ диагностируемости, вводят реалистичную меру достоверности, учитывая шум и неопределенности, что позволяет достичь компромисса между стоимостью и робастностью диагностики.

ОСНОВНАЯ ЧАСТЬ

Методы оптимального размещения датчиков варьируются в зависимости от конкретных целей, но их также можно объединить в две группы: методы, основанные на моделях, и безмодельные методы [6, 7]. В первом случае используется аналитическая модель (статическая или динамическая), а во втором — используются априорные знания. Некоторые методы размещения датчиков могут быть отнесены к обеим вышеупомянутым категориям, как, например, использование генетического алгоритма (ГА), т. е. фактически речь идет о комбинированных или гибридных методах.

Обнаружение и диагностика нарушений в значительной степени базируются на подходах, основанных на моделях, эффективность которых заключается в использовании предварительных знаний об исследуемой системе. Классическая методология обычно следует трем этапам:

- (i) сравнение реальных измерений и прогнозов, полученных по модели, вычисление на этой основе их разностей (остатков), которые и являются потенциальными индикаторами наличия нарушений в ходе процесса;
- (ii) анализ ненулевого значения этих остатков, чтобы различить отклонения, связанные с возмущениями, шумами или неточностями, от тех, которые вызваны реальными нарушениями;
- (iii) локализация и идентификация предполагаемых нарушений.

Этот подход, хотя и эффективный, основан на предположении о наличии моделей рассматриваемой системы, что на практике наблюдается не часто [6].

Вторая группа — это методы, основанные на данных (data-driven). Они становятся незаменимыми, когда аналитическое моделирование процесса слишком сложно, слишком дорого или просто невозможно. Они опираются на прямое использование операционных данных и алгоритмы машинного обучения (Machine Learning). Обучение с учителем может использоваться для оценки важности каждой переменной и каждого потенциального места установки датчика. Обучение без учителя с помощью техник кластеризации позволяет группировать датчики со схожими сигнатурами, что кардинально сокращает пространство поиска. Наконец, обучение с подкреплением предполагает автономное обучение оптимальной политике размещения путем взаимодействия с симулятором или реальной средой.

В данной статье приведен сравнительный обзор этих методов для проектирования эффективных систем диагностики.

Из безмодельных методов следует отметить, основанные на статистических подходах. Эти методы позволяют оценить согласованность данных и обнаружить аномальное поведение без требования исчерпывающих знаний о системе. Однако даже в этом случае большинство методов остаются зависимыми от некоторого моделирования или априорной информации об изучаемом процессе, что дополнительно подчеркивает важность подходов, основанных на моделях [7].

Генетический алгоритм (ГА) относится к метаэвристическим алгоритмам, которые основаны на имитации процессов биологической эволюции; он имитирует дарвиновскую теорию выживания в природе наиболее приспособленных [8]. Однако в большинстве применений использование ГА происходит при предварительном снижении размерности решаемой проблемы, что позволяет существенно увеличить скорость и надежность получения решения. Наиболее широко используемым для этого методом является метод главных компонент (МПК, PCA).

Такое сочетание ГА с МПК использовано, например, в работе [9], где рассмотрена установка, состоящая из реактора и стриппера, на которой было размещено 13 датчиков в местах, признанных важными, а затем измерялись 13 переменных при некоторых условиях проявления нарушений хода технологического процесса. Из 13 измеряемых переменных были выбраны 8, затронутые нарушениями. Затем пространство поиска было сокращено благодаря уникальному отбору возмущенных переменных процесса. Этот выбор был сделан, когда



было обнаружено, что датчики, размещенные в других точках, добавляли шум вместо информации. Алгоритм был применен с начальной популяцией из 130 особей. Лучшая особь последнего поколения была выбрана как решение.

Другой случай был решен в предположении, что стоимость датчиков близка к максимальной стоимости отказов. Решение заключается в размещении 4 датчиков, признанных достаточными для эффективного функционирования процесса. После завершения каждого варианта оптимизации результаты тестировались с помощью моделирования.

Разработанный метод для проектирования оптимальных сетей датчиков на основе МГК анализа и использования генетических алгоритмов имеет несколько значительных преимуществ, но также и некоторые ограничения.

Среди преимуществ отметим тот факт, что стратегия применения МГК нацелена не только на уменьшение затрат за счет минимизации числа используемых датчиков, но и на уменьшение потенциальных потерь, связанных с пропуском критических нарушений [9]. Такой целостный подход позволяет обеспечить лучшую окупаемость системы мониторинга. Кроме того, использование генетических алгоритмов предлагает эффективное решение при больших пространствах поиска. Это делает метод применимым к сложным системам со многими переменными [10].

Рассмотренный вариант опирается на статическую версию МГК, что ограничивает способность обнаруживать определенные типы развивающихся или переходных нарушений. Кроме того, определение порогов обнаружения основано на произвольной или внешней оценке (например, безопасности), что может сильно влиять на результаты. К этому добавляется отсутствие критериев для измерения степени возможной избыточности датчиков, что может привести к потере эффективности или ненужному дублированию [11]. Наконец, хотя генетические алгоритмы эффективны, их реализация может быть очень затратной по времени вычислений, особенно для очень больших систем с многочисленными комбинациями датчиков [12].

Расширение статической версии МГК до динамической позволило бы лучше улавливать переходные и развивающиеся нарушения. Также было бы целесообразно разработать явные метрики для количественной оценки избыточности датчиков, что позволило бы не допускать этого, гарантируя оптимальное покрытие.

Количественный анализ диагностируемости — это методология, которая позволяет присваивать численные

значения показателям диагностики нарушений протекания технологического процесса, предоставляя таким образом меру ее способности обнаруживать и изолировать нарушения сверх простой качественной оценки типа «да/нет». Она использует математические модели и методы, основанные на данных, для оценки сложности диагностики отказов в различных условиях, учитывая такие факторы, как шум и неопределенности модели. Это позволяет разработчикам принимать обоснованные решения относительно конфигурации системы управления и схемы размещения датчиков для достижения требуемого уровня диагностируемости, гарантируя таким образом надежность и эффективность [13, 14].

Рассмотрим некоторые варианты использования количественного анализа диагностируемости. В работе [13] этот анализ прямо использовался для определения оптимального размещения датчиков. Основная цель состояла в том, чтобы для заданной модели и доступного набора датчиков найти набор с минимальной стоимостью, который соблюдает требуемые показатели диагностируемости, определенные этой моделью. Для этого нужно было оценить, в какой степени нарушения являются «различимыми» и между собой, и с номинальным состоянием в зависимости от доступных измерений. Эта мера различимости опирается на статистическую разницу между распределениями сигналов остатков в каждом сценарии нарушения.

Конкретно, метод придает каждой конфигурации датчиков численное значение, которое отражает способность к дискриминации. Чем выше это значение, тем более способна система правильно идентифицировать нарушения даже при наличии шума. Оптимизация размещения становится таким образом проблемой поиска набора датчиков, который минимизирует стоимость, гарантируя при этом, что способность к идентификации превышает predetermined порог.

Для решения этой проблемы были предложены две стратегии. Первая — это полный перебор, который гарантирует оптимальность, но быстро становится неприемлемым, когда количество потенциальных датчиков велико. Вторая — это «жадный» (greedy) алгоритм, намного более эффективный с точки зрения вычислений: он выбирает датчики инкрементально, добавляя на каждом шаге тот, который приносит наибольший прирост диагностируемости, до достижения требуемого порога.

Эта методология, таким образом, вводит более реалистичные операционные рамки для оценки диагностируемости систем, поскольку она учитывает как качество датчиков, так и качество модели. Предложенный «жадный» алгоритм быстр и эффективен, что делает метод применимым к системам среднего размера [15]. Тем



не менее, несколько ограничений остаются: предположения о линейности и гауссовском шуме ограничивают применимость к определенным промышленным системам, зависимость от параметров (длина временного окна, профили нарушений) может влиять на результаты, т. е. «жадный» алгоритм, хотя и эффективный, не предоставляет гарантии оптимальности [16].

Наконец, намечаются перспективы расширения исследований, направленных на нелинейные системы [17] и негауссовский шум [18], на разработку робастной оптимизации при наличии неопределенностей различного рода, а также на интеграцию множественных целей (стоимость, надежность, энергопотребление и т. п.).

Алгоритмы branch-and-bound (B&B, «ветвей и границ») — это фундаментальная и широко используемая методология для получения точных решений NP-трудных (Non-deterministic Polynomial time) проблем оптимизации. Эта техника часто квалифицируется как алгоритм; однако, возможно, более уместно сказать, что B&B инкапсулирует семейство алгоритмов, которые все разделяют общую базовую процедуру решения. Эта процедура неявно перечисляет все возможные решения рассматриваемой проблемы, сохраняя частичные решения, называемые подзадачами, в древовидной структуре [19].

В работе [20] предложен метод оптимального размещения датчиков, основанный на алгоритме «ветвей и границ». Для реализации метода сначала было разработано математическое описание, которое характеризует номинальное поведение каждого компонента и определяет структуру и взаимосвязи. Затем было проведено построение Матрицы Сигнатур Нарушений (Fault Signature Matrix, FSM) и далее Гипотетической Матрицы Сигнатур (Hypothetical Signature Matrix, HSM) в предположении, что каждая не измеряемая переменная имеет гипотетический датчик. Затем были определены степени покрытия и дискриминативности датчиков и, наконец, было осуществлено проектирование алгоритма «ветвей и границ». Авторы [20] проверили алгоритм с помощью иллюстративного примера с простой системой (схема умножителя-сумматора).

Метод в первую очередь нацелен на базовый случай поиска минимального набора датчиков среди всех возможных (гипотетических) датчиков. Тем не менее, метод также способен учитывать другие критерии оптимальности размещения датчиков, такие как минимизация стоимости, а также предусмотрена возможность дополнительного добавления датчиков к уже функционирующей системе для улучшения диагностируемости.

Однако эти случаи требуют модификации предложенного метода, которая объяснена в статье неявно. Кроме того, валидация метода выполнена на простом примере;

эффективность работы системы на сложных промышленных системах не продемонстрирована. Метод имеет потенциально высокую сложность, если матрица HSM очень велика, и неявно обрабатывает случаи зашумленных или неопределенных измерений.

Таким образом, для улучшения метода представляется целесообразным провести интеграцию критериев многоцелевой оптимизации (стоимость, надежность, техническое обслуживание), а также расширить область применения на крупномасштабные системы (химические процессы и т. д.), адаптировать к случаям с неидеальными датчиками.

Как указывалось выше, подходы, основанные на моделях, страдают от ограничений, связанных с доступностью и точностью априорных знаний о системе. Чтобы преодолеть эти ограничения, были разработаны так называемые безмодельные методы, или методы, управляемые данными. Они опираются исключительно на измерения параметров системы и позволяют, таким образом, диагностировать ее состояние путем прямого анализа собранных данных [6, 7].

Эти подходы в первую очередь задействуют техники машинного обучения, распознавания образов и, в более широком смысле, методы искусственного интеллекта (ИИ). В отличие от методов, исходящих из классической автоматки, которые основываются на численной обработке и использовании дифференциальных уравнений, подходы, основанные на ИИ, принимают символическую логику. Они, в частности, заключаются в решении комбинаторных проблем, представлении знаний здравого смысла и моделировании человеческих рассуждений для обработки неопределенностей и сложности систем [6]. В этом контексте ИИ появляется как дополнительный инструмент, особенно уместный для управления и диагностики, обогащающий спектр доступных техник.

В контексте определения оптимального размещения датчиков интересно использование метода машинного обучения (МО) с учителем [21]. В работе [22] этот подход использован для определения оптимального размещения датчиков в жидкостных потоках. Идея состоит в использовании способности алгоритмов МО измерять важность входов для выбора наиболее влиятельных датчиков. Метод использовался для определения положения датчиков на крыле летательного аппарата при моделировании профиля крыла и показал хорошие результаты, например, сократив время вычислений более чем в 10 раз. Несмотря на ряд преимуществ, у метода есть ограничения: зависимость от данных обучения, отсутствие физической интерпретируемости. Кроме того, валидация остается, по существу, численной, требующей экспериментов в аэродинамической трубе или в реальных промышленных условиях.



Обучение без учителя (кластеризация) совместно с другими методами использовалось для проблемы оптимального размещения датчиков в области мониторинга экологичности рабочей среды в офисном здании [23], а в работе [19] рассмотрен гибридный метод, интегрирующий кластеризацию и используемый для оптимального размещения датчиков, предназначенных для обнаружения и локализации утечек в сетях распределения воды. Их подход опирается на два основных этапа. На первом этапе строится матрица чувствительности к утечкам (FSM) [24] на основе моделирования. Каждый столбец этой матрицы представляет эффект утечки, в то время как каждая строка соответствует отклику потенциального датчика в терминах давления. На втором этапе применяется алгоритм Evidential C-Means (ECM) [25] для группировки датчиков-кандидатов согласно схожести их чувствительности к утечкам. Этот процесс позволяет кардинально сократить пространство поиска, переходя от 311 исходных датчиков к 25 представительным датчикам, сгруппированным в пять кластеров по пять элементов в каждом. Затем на этом сокращенном подмножестве выполняется полный перебор для выбора пяти оптимальных датчиков, максимизируя индекс локализуемости, который измеряет способность дифференцировать различные утечки из векторов чувствительности. Пример применения к зоне учета сети большого города иллюстрирует эффективность этого подхода. Вычислительная сложность была сокращена примерно в 440 000 раз по сравнению с полным перебором по полному набору датчиков. Кроме того, окончательный выбор пяти датчиков позволил гарантировать обнаружение всех 448 утечек с особенно высоким индексом локализуемости. Наконец, робастность подхода была подтверждена высокой степенью сохранения результатов, которые изменялись менее чем на 2% за 500 выполнений алгоритма ECM.

Однако, несмотря на указанные преимущества, некоторые ограничения остаются. Финальное решение зависит от качества начальной кластеризации и не гарантирует строгой оптимальности. Кроме того, метод чувствителен к выбору параметров кластеризации, особенно количеству кластеров и количеству представительных датчиков, удержанных на кластер. Он также опирается на упрощающие предположения, такие как фиксированная величина смоделированных утечек, и не учитывает шум измерений или неопределенности, связанные со спросом. Наконец, рассматриваются только датчики давления, что ограничивает разнообразие используемой информации. Для преодоления этих ограничений можно предложить несколько путей улучшения, в частности, сочетание кластеризации с генетическими алгоритмами (см. выше) или роевыми алгоритмами оптимизации [26], что могло бы дополнительно улучшить эффективность и стабильность полученных решений.

Обучение с подкреплением (RL) было применено с целью оптимального размещения датчиков для мониторинга в системах защищенного выращивания, в работе [27]. В этом случае каждое местоположение датчика соответствует «руке бандита», цель — определить позиции, максимизирующие измеряемую информацию (температура и влажность). Для решения этой проблемы авторы использовали алгоритм Томпсона Сэмплинга [28], основанный на бета-распределении, который балансирует исследование между тестированием новых местоположений и использованием выбранных датчиков, уже идентифицированных как полезные. Данные, собранные за 7 месяцев, охватывающих четыре сезона, анализировались ежемесячно. Было определено, что ни один датчик не был оптимальным одновременно для температуры и влажности, следовательно датчики «два в одном» не подходят. Кроме того, наблюдались важные сезонные вариации: наиболее релевантные датчики менялись в зависимости от месяца, делая необходимым адаптивный подход. Интересно, что результаты противоречат распространенным практикам размещения датчиков в центре теплиц, боковые позиции часто оказывались более информативными.

Положительными сторонами метода являются его **автономность** (RL обучается непосредственно из среды, без необходимости в размеченных данных), **адаптивность** (учет сезонных вариаций) и **эффективность**. Однако исследование ограничилось двумя переменными (температура и влажность), оставляя в стороне другие критические факторы, такие как CO₂, солнечная радиация или поток воздуха. Наконец, поскольку датчики размещены согласно предопределенной сетке и фиксированы, алгоритм не может оптимизировать вне этого дискретного пространства или адаптироваться к эволюционирующим средам.

ЗАКЛЮЧЕНИЕ

В данной статье рассмотрены и проанализированы основные методы, посвященные важной проблеме оптимального размещения датчиков для диагностики возможных нарушений в технологических процессах. Разнообразие методов отражает сложность и многомерность проблемы, решение которой должно обеспечить высокую эффективность и надежные результаты диагностики, наблюдаемость, отказоустойчивость и минимизацию затрат.

Анализ высветил фундаментальную разницу между методами, основанными на моделях, и методами, основанными на данных. Первые, такие как генетический алгоритм с МГК, количественный анализ диагностируемости или «ветвление и границы», предлагают формальную и строгую методологию. Их сила заключается



в их способности гарантировать теоретические свойства (такие как наблюдаемость или изолируемость) и предоставлять оптимальные или близкие к оптимуму решения для систем умеренного размера. Однако их применение определяется доступностью и точностью модели процесса, что часто трудно и дорого получить, особенно в случае сложных систем. Кроме того, их вычислительная сложность может стать существенным препятствием для использования этих методов в случае очень больших систем.

Методы, основанные на данных, опирающиеся на машинное обучение (с учителем, без учителя, с подкреплением), являются мощной альтернативой. Они используют непосредственно доступные данные, не требуя подробного моделирования. Их гибкость, адаптируемость и способность работать при большой размерности объектов контроля делают их перспективными инструментами для современных систем. Тем не менее, они имеют свои сложности: сильная зависимость от количества и качества массива данных для обучения, иногда отсутствие физической интерпретируемости результатов и, наконец, сложности с валидацией, которая часто должна выполняться на реальной системе.

Из этого анализа следует, что ни один метод не превосходит другие по всем характеристикам. Выбор зависит от контекста применения: наличия и качества доступной модели, размера и сложности системы, вычислительных ресурсов и времени, выделенного на оптимизацию, от природы диагностируемых нарушений и критичности требуемой эффективности и точности диагностики.

Перспективным направлением представляется комбинирование этих методов для объединения их преимуществ. Например, простая модель может быть использована для предварительного отбора подмножества кандидатов датчиков, на котором будет применен более требовательный к вычислениям метод машинного обучения. Количественный анализ диагностируемости, который уже интегрирует стохастические аспекты, выиграл бы от совмещения с техниками кластеризации для сокращения пространства поиска конфигураций.

В заключение нужно подчеркнуть, что оптимальное размещение датчиков остается активной и важной областью исследований для промышленности. Синергия между методами из классической автоматики и потенциал искусственного интеллекта позволит проектировать более надежные, эффективные и экономичные системы диагностики, способные гарантировать безопасность и рентабельность технологических процессов.

Список литературы (References)

1. Gaudron, P., Mouline, A. Les enjeux de l'industrie 4.0. *Management international*. 2017. Vol. 21. № 2. Pp. 165–169. <https://doi.org/10.7202/1052695ar>.
2. Summers, A. E. Techniques for assigning a target safety integrity level. *ISA Transactions*. 1998. Vol. 37. № 2. Pp. 95–104.
3. Mouzakitis, A. Classification of Fault Diagnosis Methods for Control Systems. *Measurement and Control*. 2013. Vol. 46. № 10. Pp. 303–308. <https://doi.org/10.1177/0020294013510471>.
4. Ali, Y., Narasimhan, S. Sensor network design for maximizing reliability of bilinear processes. *AIChE Journal*. 1996. Vol. 42. № 9. Pp. 2563–2575.
5. Hassani, S., Dackermann, U. A Systematic Review of Optimization Algorithms for Structural Health Monitoring and Optimal Sensor Placement. *Sensors*. 2023. Vol. 23. № 6. P. 3293. <https://doi.org/10.3390/s23063293>.
6. Khemliche, M. Procédé d'identification des défaillances dans les systèmes par placement de capteurs sur le modèle Bond-graph: *Thesis*. 2018.
7. A data driven method for optimal sensor placement in multi-zone buildings. *Energy and Buildings*. 2021. Vol. 243. P. 110956. <https://doi.org/10.1016/j.enbuild.2021.110956>.
8. Katoch, S., Chauhan, S. S., Kumar V. A review on genetic algorithm: past, present, and future. *Multimedia Tools and Applications*. 2021. Vol. 80. A review on genetic algorithm. № 5. Pp. 8091–8126. <https://doi.org/10.1007/s11042-020-10139-6>.
9. Musulin, E., Bagajewicz, M. J., Puigjaner, L. Design of Sensor Networks to Optimize PCA Monitoring Performance. *IFAC Proceedings Volumes*. 2003. Vol. 36. № 5. Pp. 687–692. [https://doi.org/10.1016/S1570-7946\(03\)80559-X](https://doi.org/10.1016/S1570-7946(03)80559-X).
10. Goldberg, D. E. Genetic Algorithms in Search, Optimization and Machine Learning. USA: Addison-Wesley Longman Publishing Co., Inc., 1989. 50 p.
11. Vergara, J. R., Estévez, P. A. A review of feature selection methods based on mutual information. *Neural Computing and Applications*. 2014. Vol. 24. № 1. Pp. 175–186. <https://doi.org/10.1007/s00521-013-1368-0>.
12. Eiben, A. E., Smith, J. E. Introduction to Evolutionary Computing: Natural Computing Series. Berlin, Heidelberg: Springer, 2015. 294 p.
13. Eriksson, D. Using quantitative diagnosability analysis for optimal sensor placement / D. Eriksson, M. Krysander, E. Frisk // *IFAC Proceedings Volumes*. 2012. Vol. 45. № 20. P. 940–945. <https://doi.org/10.3182/20120829-3-MX-2028.00196>.
14. Data-driven method for the quantitative fault diagnosability analysis of dynamic systems / F. Fu, D. Wang, L. Li [et al.] // *IET Control Theory & Applications*. 2019. Vol. 13. № 8. Pp. 1197–1203. <https://doi.org/10.1049/iet-cta.2018.5378>.
15. Chvatal, V. A Greedy Heuristic for the Set-Covering Problem / V. Chvatal // *Mathematics of Operations Research*. 1979. <https://doi.org/10.1287/moor.4.3.233>.
16. Introduction to algorithms / eds. T. H. Cormen, C. E. Leiserson, R. L. Rivest, C. Stein. 3. ed. Cambridge, Mass.: MIT Press, 2009. 1292 p.



17. Boubaker, O. Systèmes non-linéaires: Cours et exercices avec solutions. Systèmes non-linéaires / O. Boubaker, A. Lassoued publisher: Édition Marketing Ellipses. Édition Marketing Ellipses, 2023. 240 p.
18. Signal Detection in Correlated Non-Gaussian Noise Using Higher-Order Statistics / E. Palahina, M. Gamcová, I. Gladíšová [et al.] // Circuits, Systems, and Signal Processing. 2018. Vol. 37. № 4. P. 1704–1723. <https://doi.org/10.1007/s00034-017-0623-5>.
19. Branch-and-bound algorithms: A survey of recent advances in searching, branching, and pruning / D. R. Morrison, S. H. Jacobson, J. J. Sauppe, E. C. Sewell // *Discrete Optimization*. 2016. Vol. 19. Branch-and-bound algorithms. Pp. 79–102. <https://doi.org/10.1016/j.disopt.2016.01.005>.
20. Fijany, A., Vatan, F. A New Method for Sensor Placement Optimization. 41st AIAA/ASME/SAE/ASEE Joint Propulsion Conference & Exhibit. American Institute of Aeronautics and Astronautics, 2005. P. 3715. <https://doi.org/10.2514/6.2005-3715>
21. Supervised and Unsupervised Learning for Data Science: Unsupervised and Semi-Supervised Learning / eds. M. W. Berry, A. Mohamed, B. W. Yap. 1. Cham: Springer International Publishing, 2020. VIII, 187 p. <https://doi.org/10.1007/978-3-030-22475-2>.
22. Semaan, R. Optimal sensor placement using machine learning. *Computers & Fluids*. 2017. Vol. 159. Pp. 167–176. <https://doi.org/10.1016/j.compfluid.2017.10.002>.
23. Yoganathan, D., Kondepudi, S., Kalluri, B., Manthapuri, S. Optimal sensor placement strategy for office buildings using clustering algorithms. *Energy and Buildings*. 2018. Vol. 158. Pp. 1206–1225.
24. Hillier, F. S., Lieberman, G. J. Duality Theory. *Introduction to Operations Research*. McGraw-Hill Education, 2021. Pp. 200–224.
25. Masson, M.-H., Denoeux, T. ECM: An evidential version of the fuzzy c-means algorithm. *Pattern Recognition*. 2008. Vol. 41. ECM. № 4. Pp. 1384–1397. <https://doi.org/10.1016/j.patcog.2007.08.014>.
26. Wang, D., Tan, D., Liu, L. Particle swarm optimization algorithm: an overview. *Soft Computing*. 2018. Vol. 22. № 2. Pp. 387–408. <https://doi.org/10.1007/s00500-016-2474-6>.
27. A Reinforcement Learning Approach for Optimal Placement of Sensors in Protected Cultivation Systems / D. D. Uyeh, B. I. Bassey, R. Mallipeddi [et al.] // *IEEE Access*. 2021. Vol. 9. Pp. 100781–100800. <https://doi.org/10.1109/ACCESS.2021.3096828>.
28. A Tutorial on Thompson Sampling / D. J. Russo, B. V. Roy, A. Kazerouni [et al.] // *Foundations and Trends® in Machine Learning*. 2018. Vol. 11. № 1. Pp. 1–96. <https://doi.org/10.48550/arXiv.1707.02038>.

■ Информация об авторах

Диалло Амаду, аспирант кафедры автоматизации процессов химической промышленности Санкт-Петербургского государственного технологического института (технического университета); 190013, Россия, Санкт-Петербург, Московский проспект, д. 24–26/49 лит. А; e-mail: amdiallo95@gmail.com.

Ковалёв Дмитрий Александрович, кандидат технических наук, доцент, заведующий кафедрой автоматизации технологических процессов и производств Высшей школы технологии и энергетики, Санкт-Петербургского государственного университета промышленных технологий

и дизайна; 198095, Санкт-Петербург, ул. Ивана Черных, д. 4, Россия; SPIN-код: 3884–5685, AuthorID: 943016, e-mail: d.a.kovalyov@yandex.ru.

Русинов Леон Абрамович, доктор технических наук, профессор, заведующий кафедрой автоматизации процессов химической промышленности Санкт-Петербургского государственного технологического института (технического университета); 190013, Россия, Санкт-Петербург, Московский проспект, д. 24–26/49 лит. А; SPIN-код: 3646–5277, AuthorID: 48094, e-mail: lrusinov@yandex.ru.

■ Information about the authors

Diallo Amadou, PhD student of the Department of Chemical Process Automation of the Saint Petersburg State Technological Institute (Technical University), 26, Moskovski ave., St. Petersburg, Russia, 190013; e-mail: amdiallo95@gmail.com.

Kovalyov Dmitry Alexandrovich, PhD in Engineering, Associate Professor, Head of the Department of Automation of Technological Processes and Productions of the Higher School of Technology and Energy, Saint Petersburg State University

of Industrial Technologies and Design, 4 Ivan Chernykh Street, St. Petersburg, 198095; SPIN-code: 3884–5685, AuthorID: 943016, e-mail: d.a.kovalyov@yandex.ru.

Rusinov Leon Abramovich, Dr. Sci. In Engineering, Professor, Head of the Department of Chemical Process Automation of the Saint Petersburg State Technological Institute (Technical University), 26, Moskovski ave., St. Petersburg, Russia, 190013; SPIN-code: 3646–5277, AuthorID: 48094, e-mail: lrusinov@yandex.ru.

