

Разработка методов и алгоритмов диагностики устройств многофункциональной индикации с использованием предикативной аналитики

Д.М. Уманский

Национальный исследовательский университет «МИЭТ», г. Москва

Аннотация: В статье рассматривается проблема повышения надёжности устройств многофункциональной индикации (УМИ) в условиях цифровой трансформации производственных процессов. Предложен подход к предиктивной диагностике на основе анализа эксплуатационных и тепловых характеристик УМИ с использованием методов машинного обучения. Проведена классификация УМИ по физико-технологическим принципам и архитектурным уровням, что позволило структурировать диагностические модели. Рассматриваются математические методы предсказания отказов, включая логистическую регрессию, градиентный бустинг (CatBoost) и модели оценки остаточного ресурса. Особое внимание уделено разработке метода теплового профилирования Thermal Emission-Based UMI Profiling (TEB-UP), основанного на анализе тепловых карт и алгоритмах машинного зрения (РСА, автоэнкодеры, CNN). Показано, что температурная неравномерность является чувствительным индикатором деградации, опережающим традиционные показатели отказа. Метод TEB-UP демонстрирует потенциал к интеграции в системы мониторинга и предиктивного обслуживания в рамках концепций Индустрии 4.0 и 5.0.

Ключевые слова: устройства многофункциональной индикации, предиктивная диагностика, тепловое профилирование, остаточный ресурс, машинное обучение.

Современные промышленные системы становятся всё более сложными и взаимосвязанными, что требует новых подходов к управлению и контролю технологического оборудования. Одним из ключевых элементов таких систем являются устройства многофункциональной индикации (УМИ), которые обеспечивают визуализацию состояния различных процессов и параметров. Однако традиционные методы управления УМИ часто оказываются недостаточно эффективными для своевременного выявления потенциальных проблем и оптимизации работы оборудования. Это особенно актуально в условиях стремительного роста объёмов данных, поступающих от множества сенсоров и других источников информации.

Для решения этих задач всё большее значение приобретает применение предикативной аналитики, которая позволяет не только реагировать на уже произошедшие события, но и предсказывать будущие сценарии поведения оборудования.

Использование методов машинного обучения и интеллектуальных алгоритмов открывает новые горизонты в автоматизации УМИ, позволяя значительно улучшить точность диагностики, сократить время простоя и минимизировать риски аварийных ситуаций.

Цель исследования - разработка методов и алгоритмов предиктивной диагностики многофункциональных индикаторов на основе анализа данных, поступающих с производственного оборудования.

Эволюция промышленных технологий и устройств многофункциональной индикации

Устройства многофункциональной индикации (УМИ) — это интеллектуальные аппаратно-программные модули, обеспечивающие сбор, обработку и отображение разнородных данных в реальном времени. Они служат интерфейсом между человеком, киберфизическими системами и цифровыми потоками в рамках Индустрии 4.0 и 5.0. Современные УМИ отличаются адаптивностью, поддержкой IoT - протоколов (IoT - Интернет вещей), применением ИИ для анализа и персонализации информации, повышая эффективность, безопасность и устойчивость производственных и социально-технических систем [1,2].

Траектории развития технологических платформ в промышленности и УМИ, отражающие их синхронную эволюцию представлены на рис.1. График сопровождается временными маркерами (пунктир), соответствующими трем ключевым этапам индустриализации:

Индустрия 3.0 (1960-е – 1990-е, цифровизация и автоматизация):

Технологии: компьютеры, программируемые контроллеры (ПЛК), системы автоматизации производства.

УМИ: простые цифровые дисплеи и панели управления на основе ламповых или ранних жидкокристаллических экранов, ограничены по функционалу, часто монохромные и не интерактивные [3,4].




Рис.1. Этапы эволюции промышленных технологий и устройств многофункциональной индикации».

Индустрия 4.0 (2010-е – настоящее время, киберфизические системы):

Технологии: IoT, большие данные, облачные вычисления, искусственный интеллект, цифровые двойники.

УМИ: сенсорные панели управления интерфейсом «человек-машина», интегрированные с IoT, отображающие данные в реальном времени. Появляются элементы дополненной реальности для визуализации данных [5,6].

Индустрия 5.0 (2020-е – будущее, человеко-ориентированные системы):

Технологии: синергия человека и машины, адаптивные системы с ИИ, устойчивые и персонализированные процессы.

УМИ: интеллектуальные интерфейсы, такие как очки дополненной / виртуальной реальности, носимые устройства с биометрией, голосовые помощники. Они адаптируются к пользователю, предлагают рекомендации и обеспечивают совместную работу с роботами [7,8].

Классификация устройств многофункциональной индикации для целей диагностики

Для построения эффективных методов предиктивной диагностики УМИ необходима обоснованная классификация, отражающая как физические принципы действия устройств, так и их архитектурные особенности. Предлагаемая классификация основывается на двух ключевых признаках: (1) физико-технологической природе индикации и (2) уровне функциональной сложности УМИ.

I. Физико-технологический принцип индикации отражает физическую природу формирования визуального сигнала и напрямую связан с типичными механизмами отказов. Основные виды УМИ:

Электролюминесцентные: подвержены деградации люминофора, перегреву, снижению яркости.

Жидкокристаллические: чувствительны к нарушению поляризации, утечке напряжения, ухудшению контрастности.

Электрохромные и электрофорезные: характеризуются инерционностью, нестабильностью цвета, чувствительностью к напряжению.

Газоразрядные: возможны шум, дрейф напряжения зажигания, износ электродов.

Механические и аналоговые: подвержены трению, залипанию механических частей, физическому износу.

II. Уровень функциональной архитектуры описывает степень интеграции и интеллектуальности УМИ:

Пассивные УМИ — устройства без встроенной логики управления (например, простые LED-индикаторы).

Управляемые УМИ — устройства с внутренней логикой, способные отображать предустановленные шаблоны или взаимодействовать по интерфейсам (например, жидкокристаллический дисплей с контроллером, панели управления интерфейсом «человек-машина»).

Интеллектуальные УМИ — устройства с процессорами, ОС, возможностью обработки сенсорных сигналов, включая дисплеи с поддержкой дополненной/виртуальной, сенсорные экраны и встроенные алгоритмы.

Таблица 1

Матрица классификации УМИ

Тип индикации	Пассивные УМИ	Управляемые УМИ	Интеллектуальные УМИ
Электролюминесцентные	✓	✓	✓
Жидкокристаллические	✓	✓	✓
Электрофорезные / электрохромные	✓	✓	—
Газоразрядные	✓	✓	—
Механические / аналоговые	✓	—	—

Для целей диагностики разработана комбинированная матричная модель, объединяющая оба уровня классификации (таблица 1). Она позволяет соотнести тип индикации и уровень интеллектуальности устройства, что критически важно для выбора соответствующего диагностического подхода и аналитического инструментария.

Таким образом, предложенная система классификации является основой для систематизации методов диагностики и построения адаптивных алгоритмов предиктивного анализа состояний УМИ различного класса.

Математические модели предсказания неисправностей

Предиктивная аналитика представляет собой современный подход к прогнозированию состояния технических систем, основанный на использовании статистических моделей и алгоритмов машинного обучения. Основной целью применения данного метода является раннее выявление признаков деградации компонентов, обеспечение своевременного планирования технического обслуживания и снижение вероятности незапланированных простоев оборудования. Эти задачи особенно актуальны в контексте диагностики устройств многофункциональной индикации (УМИ), где стабильность работы напрямую влияет на безопасность производственных процессов и их эффективность.

В рамках диагностики систем УМИ предиктивная аналитика применяется для анализа эксплуатационных характеристик, таких как яркость индикации, частота отказов, энергопотребление, а также температурные и временные параметры. На основе данных сенсоров и информации об истории эксплуатации формируются вероятностные модели, способные прогнозировать потенциальные неисправности до их фактического проявления. Процесс построения предиктивных моделей включает несколько этапов: сбор и предварительную обработку данных, выделение диагностически значимых признаков, разработку моделей прогнозирования, интерпретацию полученных результатов и оценку точности прогноза.

Следует отметить, что данные о протекании технологического процесса далеко не всегда используются эффективно. Тем не менее, при наличии организованного сбора, длительного хранения информации и автоматизированных

систем обработки, такие данные могут стать основой для комплексной оптимизации производственных процессов и повышения технико-экономических показателей предприятий.

В целях повышения эффективности управления технологическими процессами разрабатываются интеллектуальные системы мониторинга в реальном времени, использующие методы машинного обучения для прогнозирования дальнейшего развития процессов, определения уровня отклонений от оптимальных режимов работы и автоматической корректировки управляющих воздействий либо выдачи рекомендаций операторскому персоналу. Предиктивные математические модели, интегрированные в такие системы, обеспечивают обработку входных параметров, прогноз динамики технологического процесса и выработку предложений по его оптимизации.

Так, в 2024 году затраты на глобальном рынке предиктивной аналитики достигли \$10,15 млрд. Это соответствует росту примерно на 10% по отношению к 2023-му, когда расходы оценивались в \$9,2 млрд. Отрасль демонстрирует стабильную положительную динамику, о чем говорится в обзоре Market Research Future, представленном в середине февраля 2025 года. Стабильный рост отрасли обусловлен как увеличением объёма генерируемых данных, так и расширением практики применения аналитических инструментов в бизнес-процессах. В условиях быстро меняющейся рыночной среды предприятия стремятся использовать доступные данные для совершенствования систем принятия решений, оптимизации распределения ресурсов и повышения качества обслуживания клиентов. На фоне нарастающего объёма информации потребность в высокоэффективных аналитических инструментах продолжает возрастать.

Таблица 2

Сравнительный анализ методов предиктивной диагностики для различных типов устройств индикации

Метод	Требования к данным	Формулы для расчета	Преимущества и ограничения	Применимость к типам УМИ
Логистическая регрессия [9,10]	Числовые признаки; бинарная метка отказа; масштабирование данных желательно	$P(y = 1 X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)}}$ где $y = 1$ — наличие неисправности; x_i — диагностические признаки; β_i — коэффициенты модели.	Простота, высокая скорость, интерпретируемость <i>Ограничена линейностью, не работает с комплексными структурами</i>	Жидкокристаллические, простые жидкокристаллические дисплеи с контроллером
Алгоритм машинного обучения «случайный лес» [11,12]	Обширные гетерогенные данные, допускаются пропуски	Энтропийная мера неопределенности: $H(S) = - \sum p_i \log_2(p_i),$ информационный прирост (Information Gain) как критерий выбора оптимальных разбиений	Работает с разными типами признаков, устойчива к шуму <i>Большая память, сложно интерпретировать</i>	Жидкокристаллические, сенсорные панели
Градиентный бустинг [10,13]	Категориальные и числовые признаки, большие выборки	строит модель в виде ансамбля деревьев решений: $F(x) = \sum_{m=1}^M \gamma_m \cdot h_m(x)$ где $h_m(x)$ — отдельные деревья, γ_m — веса, M — число итераций бустинга.	Автоматизация обработки, высокая точность <i>Требуется настройки, слабая интерпретируемость</i>	Комбинированные УМИ, IoT-индикаторы
Модель оценки остаточного ресурса [14-17]	Временные ряды деградации; метки момента отказа; стабильная частота измерений	Деградационная модель линейного убывания параметра $y(t) = y_0 - \alpha t + \varepsilon(t)$ где y_0 — начальное значение, α — скорость деградации, $\varepsilon(t)$ — случайная ошибка (шум). Оценка времени отказа (пороговая деградация до y_{fail}) вычисляется как:	Позволяет спрогнозировать момент выхода из строя; легко интерпретируется в физическом контексте <i>Требуется длительных наблюдений; чувствительна к шуму; ограничена</i>	Индикаторы с деградирующими параметрами (яркость, контрастность)

		$T_{fail} = \frac{y_0 - y_{fail}}{\alpha}$	линейными зависимостями	
--	--	--	----------------------------	--

Применение предиктивной аналитики позволяет предприятиям прогнозировать будущие тенденции развития рынка и изменения в потребностях клиентов на основе анализа исторических данных. Такой подход обеспечивает организациям конкурентные преимущества, способствует росту выручки и укреплению рыночных позиций.

В таблице 2 представлены требования, достоинства, ограничения различных методов диагностики и их применимость к системам УМИ, что позволяет сопоставить их эффективность и выбрать наиболее подходящий инструмент в зависимости от конкретных условий производства.

Физическая природа процессов в современных видах УМИ и разработка метода диагностики УМИ на основе теплового излучения

Несмотря на разнообразие конструкций УМИ, в данном исследовании акцент сделан на следующие типы:

Жидкокристаллические дисплеи, оснащенные светодиодной подсветкой, и дисплеи, где используются самоизлучающие органические светодиоды, — наиболее распространённые и чувствительные к деградации в промышленности, транспорте и быту;

Жидкокристаллические дисплеи широко применяются в интерфейсах управления, стабильны, но уязвимы к механическим и тепловым воздействиям;

Сенсорные панели управлением интерфейсом «человек-машина» — ключевые компоненты цифровых систем, требуют комплексной диагностики аппаратной и программной части.

Выбор обусловлен их высокой распространённостью, критичностью к отказам и возможностью прогнозирования деградации по параметрам яркости, температуры, отклика и др.

Большинство активных УМИ работают на основе токопроводящих слоёв, что вызывает тепловыделение и последующую деградацию материалов (рост сопротивления, снижение квантового выхода). Тепло отражает физико-химические процессы и может служить важным диагностическим маркером.

Тепловое поведение УМИ изменяется уже на ранних стадиях деградации. Исследования надёжности светодиодов и дисплеев [15, 18, 19] показывают, что в этот период возникают локальные перегревы и токовые утечки, изменяющие температурное распределение. Это делает температурную неравномерность надёжным предиктором отказа, опережающим снижение яркости, а тепловой профиль — чувствительным диагностическим признаком.

Измерение теплового излучения представляет собой бесконтактный и масштабируемый метод диагностики. С применением инфракрасных камер или микротермодатчиков строятся тепловые карты, автоматически сравниваемые с эталонными шаблонами. Такой подход позволяет проводить диагностику в реальном времени без вмешательства в устройство.

Тепловые карты обрабатываются алгоритмами машинного зрения: PCA, автоэнкодерами и сверточными нейросетями (CNN), что позволяет выявлять аномалии и количественно оценивать степень деградации. Это создаёт основу для интеграции в системы предиктивной аналитики и реализации функций раннего обнаружения отказов.

Предложенный метод, основанный на тепловом профилировании и алгоритмах машинного зрения, аналогичен подходам, применяемым в анализе жидкокристаллических дисплеев, оснащенных светодиодной подсветкой, и

дисплеев, где используются самоизлучающие органические светодиоды [20]. Его преимущество заключается в универсальности, интеграции с аналитикой и возможностью количественной оценки деградации, что делает его перспективным для Индустрии 4.0 и 5.0.

Оригинальный метод диагностики на основе теплового профилирования (TEB-UP)




Рис. 2. Алгоритм диагностики на основе теплового профилирования (ТЕВ-UP)

В статье представлен компактный диагностический алгоритм ТЕВ-UP (Thermal Emission-Based UMI Profiling), основанный на анализе тепловых карт, полученных с инфракрасной камеры. Метод предназначен для раннего выявления деградации УМИ (жидкокристаллические дисплеи, оснащенные светодиодной подсветкой, дисплеи, где используются самоизлучающие органические светодиоды, панели управления интерфейсом «человек-машина» и др.) и прогноза их остаточного ресурса. Этапы алгоритма представлены на диаграмме (рис.2).

Для количественной оценки остаточного ресурса может быть использована регрессионная модель, основанная на параметрах, извлечённых из тепловой карты: $RUL=f(A, T_{max}, T_{mean})$, где: A — площадь аномальной зоны, T_{max} — максимальная температура в аномальной области, T_{mean} — средняя температура аномалий.

Метод ТЕВ-UP интегрирует машинное зрение, предобработку изображений и элементы предиктивной аналитики, обеспечивая высокочувствительную оценку остаточного ресурса УМИ в системе мониторинга состояния критически важных интерфейсов визуализации, особенно в промышленной автоматике и пользовательских устройствах. предобработку изображений и элементы предиктивной аналитики, обеспечивая высокочувствительную оценку остаточного ресурса УМИ. в систему мониторинга состояния критически важных интерфейсов визуализации, особенно в промышленной автоматике и пользовательских устройствах.

Литература

1. Kagermann H. Recommendations for implementing the strategic initiative INDUSTRIE 4.0. Final report of the Industrie 4.0 Working Group. 2013. URL: din.de/resource/blob/76902/e8cac883f42bf28536e7e8165993f1fd/recommendations-for-implementing-industry-4-0-data.pdf (дата обращения: 18.06.2025).
2. Thangaraj J., Narayanan R.L. Industry 1.0 to 4.0: the evolution of smart factories // International Journal of Mechanical and Production Engineering. 2018. Vol. 6, № 7. pp. 231–236.
3. Adeyeri M. From Industry 3.0 to Industry 4.0: Smart predictive maintenance system as platform for leveraging // Arctic Journal. 2018. Vol. 71. pp. 64–81.
4. Lashen M. Different applications of programmable logic controller (PLC) // International Journal of Computer Science, Engineering and Information Technology. 2014. Vol. 4, № 1. pp. 27–32.
5. Javaid M., Haleem A., Singh R. P., Suman R., Santibañez Gonzalez E. Understanding the adoption of Industry 4.0 technologies in improving environmental sustainability // Sustainable Operations and Computers. 2022. Vol. 3. pp. 203–217.
6. Javaid M., Haleem A., Suman R. Digital Twin applications toward Industry 4.0: A review // Cognitive Robotics. 2023. Vol. 3. pp. 71–92.
7. Anang A. N., Obidi P. O., Mesogboriwon A. O., Obidi J. O., Kuubata M., Ogunbiyi D. The role of artificial intelligence in Industry 5.0: enhancing human-machine collaboration // World Journal of Advanced Research and Reviews. 2024. Vol. 24, № 2. pp. 380–400.
8. Khafaga A.A.A.E.M.A., Moreira L.C., Horan B. Towards Industry 5.0: augmented reality assistance systems for people-centred digitalisation and smart

manufacturing // Proc. of 28th International Conference on Automation and Computing (ICAC). Birmingham, UK, 2023. pp. 1–7.

9. Cucchiara A. Applied logistic regression // Technometrics. 2012. Vol. 34, № 3. pp. 358–359.

10. Hosmer D.W., Lemeshow S. Applied Logistic Regression. 2nd ed. Hoboken: John Wiley & Sons, 2000. URL: dl.icdst.org/pdfs/files4/7751d268eb7358d3ca5bd88968d9227a.pdf (дата обращения: 18.06.2025).

11. Aldrich C., Auret L. Fault detection and diagnosis with random forest feature extraction and variable importance methods // IFAC Proceedings Volumes. 2010. Vol. 43, № 9. pp. 79–86.

12. Prokhorenkova L., Gusev G., Vorobev A., Dorogush A.V., Gulin A. CatBoost: unbiased boosting with categorical features // Proc. of the 32nd International Conference on Neural Information Processing Systems (NeurIPS). 2018. pp. 6639–6649.

13. Mohammadi M., Al-Fuqaha A., Sorour S., Guizani M. Deep learning for IoT big data and streaming analytics: a survey // IEEE Communications Surveys & Tutorials. 2018. Vol. 20, № 4. pp. 2923–2960.

14. MathWorks. Predict Remaining Useful Life (RUL) // MATLAB Predictive Maintenance Toolbox. 2024. URL: mathworks.com/help/predmaint/predict-remaining-useful-life.html (дата обращения: 10.04.2025).

15. Li R., Kirkaldy N.D., Oehler F.F., et al. The importance of degradation mode analysis in parameterising lifetime prediction models of lithium-ion battery degradation // Nature Communications. 2025. Vol. 16. Article 2776.

16. Ефанов В.Н., Иванова Н.С., Разумов В.Г. Интеллектуальная технология оценки остаточного ресурса сложных технических систем // Вестник

ЮУрГУ. Сер. Компьютерные технологии, управление, радиоэлектроника. 2024. Т. 24, № 3. С. 54–66.

17. Никифоров С. Исследование параметров семейства светодиодов Cree XLamp // Компоненты и Технологии. 2006. № 64. С. 42–49.

18. Pugalenth K., Park H., Hussain S., Raghavan N. Predicting lumen degradation of light emitting diodes using hybrid particle filter trained neural networks // IEEE Access. 2021. pp. 1–1.

19. Reineke S., Thomschke M., Lüssem B., Leo K. White organic light-emitting diodes: status and perspective // Reviews of Modern Physics. 2013. Vol. 85. pp. 1245–1293.

20. Kim J., et al. Machine learning-based thermal anomaly detection in OLED displays // Journal of Display Technology. 2021. Vol. 17, № 5. pp. 123–130.

References

1. Kagermann H. Final report of the Industrie 4.0 Working Group. 2013. URL: [din.de/resource/blob/76902/e8cac883f42bf28536e7e8165993f1fd/recommendations-for-implementing-industry-4-0-data.pdf](https://www.din.de/resource/blob/76902/e8cac883f42bf28536e7e8165993f1fd/recommendations-for-implementing-industry-4-0-data.pdf) (date accessed: 18.06.2025).

2. Thangaraj J., Narayanan R.L. International Journal of Mechanical and Production Engineering. 2018. Vol. 6, № 7. pp. 231–236.

3. Adeyeri M. Arctic Journal. 2018. Vol. 71. pp. 64–81.

4. Lashen M. International Journal of Computer Science, Engineering and Information Technology. 2014. Vol. 4, № 1. pp. 27–32.

5. Javaid M., Haleem A., Singh R. P., Suman R., Santibañez Gonzalez E. Sustainable Operations and Computers. 2022. Vol. 3. pp. 203–217.

6. Javaid M., Haleem A., Suman R. Cognitive Robotics. 2023. Vol. 3. pp. 71–92.
7. Anang A. N., Obidi P. O., Mesogboriwon A. O., Obidi J. O., Kuubata M., Ogunbiyi D. World Journal of Advanced Research and Reviews. 2024. Vol. 24, № 2. pp. 380–400.
8. Khafaga A.A.A.E.M.A., Moreira L.C., Horan B. Proc. of 28th International Conference on Automation and Computing (ICAC). Birmingham, UK, 2023. pp. 1–7.
9. Cucchiara A. Technometrics. 2012. Vol. 34, № 3. pp. 358–359.
10. Hosmer D.W., Lemeshow S. Applied Logistic Regression. 2nd ed. Hoboken: John Wiley & Sons, 2000. URL: <https://dl.icdst.org/pdfs/files4/7751d268eb7358d3ca5bd88968d9227a.pdf> (date accessed 18.06.2025).
11. Aldrich C., Auret L. IFAC Proceedings Volumes. 2010. Vol. 43, № 9. P. 79–86.
12. Prokhorenkova L., Gusev G., Vorobev A., Dorogush A.V., Gulin A. Proc. of the 32nd International Conference on Neural Information Processing Systems (NeurIPS). 2018. pp. 6639–6649.
13. Mohammadi M., Al-Fuqaha A., Sorour S., Guizani M. IEEE Communications Surveys & Tutorials. 2018. Vol. 20, № 4. pp. 2923–2960.
14. MathWorks. MATLAB Predictive Maintenance Toolbox. 2024. URL: mathworks.com/help/predmaint/predict-remaining-useful-life.html (date accessed: 10.04.2025).
15. Li R., Kirkaldy N.D., Oehler F.F. Nature Communications. 2025. Vol. 16. Article 2776.
16. Efanov V.N., Ivanova N.S., Razumov V.G. Vestnik YUUrGU. Ser. Komp'yuternye tekhnologii, upravlenie, radioelektronika. 2024. T. 24, № 3. pp. 54–66.



17. Nikiforov S. Komponenty i Tekhnologii. 2006. № 64. pp. 42–49.
18. Pugalenthil K., Park H., Hussain S., Raghavan N. IEEE Access. 2021. pp. 1–1.
19. Reineke S., Thomschke M., Lüssem B., Leo K. Reviews of Modern Physics. 2013. Vol. 85. pp. 1245–1293.
20. Kim J., et al. Journal of Display Technology. 2021. Vol. 17, № 5. pp. 123–130.

Дата поступления: 15.05.2025

Дата публикации: 25.09.2025