

Никифоров Дмитрий Владимирович,
к.т.н, доцент, РТУ МИРЭА

Никандров Лев Борисович,
к.т.н, доцент, РТУ МИРЭА

Вяткин Артём Андреевич,
к.э.н, доцент, РТУ МИРЭА

Терёшина Влада Валерьевна,
к.э.н, доцент, РТУ МИРЭА

ГИБРИДНЫЕ НЕЙРОСЕТЕВЫЕ АНСАМБЛИ В ЗАДАЧАХ ОПЕРАТОРНОГО УПРАВЛЕНИЯ ТЕХНОЛОГИЧЕСКИМИ ПРОЦЕССАМИ

Аннотация. В работе раскрыта сущность гибридных ансамблей как многоуровневых архитектур, объединяющих различные типы моделей. Обоснована необходимость перехода от традиционных жестко запрограммированных алгоритмов к адаптивным, самообучающимся системам, способным функционировать в условиях нестационарности сырья, износа оборудования и высокой неопределенности внешней среды.

Ключевые слова: Гибридные нейросетевые ансамбли, операторное управление, технологические процессы, машинное обучение, ансамблевые методы, искусственный интеллект, агентные системы.

Управление технологическими процессами в современной промышленности сталкивается с проблемой, которая лежит на пересечении двух фундаментальных аспектов: сложность управляемых объектов постоянно растет, а требования к надежности и эффективности управления ужесточаются с каждым годом. Традиционные подходы, основанные на жестких физико-химических моделях или линейных регуляторах, демонстрируют свою недостаточность в условиях нестационарности сырья, износа оборудования, человеческого фактора и постоянно меняющихся внешних условий. Именно здесь на сцену выходят методы искусственного интеллекта, и среди них особое место занимают гибридные нейросетевые ансамбли, представляющие собой не просто очередной алгоритм, а целую парадигму построения систем управления, способных адаптироваться, учиться и принимать решения в условиях неопределенности. Суть этой парадигмы заключается в комбинировании нескольких моделей, каждая из которых видит данные под своим углом, а их коллективное решение оказывается значительно точнее и устойчивее, чем решение любой из них по отдельности, что напрямую коррелирует с теоремой Кондорсе о жюри присяжных, согласно которой вероятность правильного коллективного решения возрастает с увеличением числа независимых экспертов, каждый из которых ошибается реже, чем в половине случаев. В контексте операторного управления это означает, что ансамбль нейронных сетей способен улавливать тонкие закономерности в поведении технологического агрегата, которые недоступны одному классификатору или регрессору, и выдавать сигналы управления или диагностики с высокой степенью достоверности [1]. Говоря о гибридных ансамблях, мы подразумеваем не просто набор однородных нейронных сетей, обученных на одних и тех же данных, а сложную многоуровневую архитектуру, объединяющую различные



типы моделей и подходы. В основе такого ансамбля может лежать комбинация рекуррентных нейронных сетей, эффективных для анализа временных рядов, сверточных сетей, хорошо зарекомендовавших себя в извлечении пространственных признаков, и методов градиентного бустинга, которые демонстрируют выдающиеся результаты на структурированных данных. Например, в задаче прогнозирования энергопотребления сталелитейного завода на разные временные горизонты эффективной оказалась гибридная ансамблевая модель, объединяющая векторную авторегрессию, сети с гейтированными рекуррентными блоками и алгоритм экстремального градиентного бустинга в качестве мета-модели, что позволило превзойти традиционные статистические методы и чистые нейросетевые подходы благодаря способности архитектуры эффективно использовать сильные стороны различных моделей и продвинутые стратегии предобработки данных [2]. В этом случае модель VAR улавливает линейные зависимости между переменными, сеть GRU работает с долгосрочными нелинейными паттернами, а XGBoost на втором уровне иерархии обучается на ошибках первых двух моделей, формируя скорректированный финальный прогноз [3].

Ключевой особенностью гибридных ансамблей в задачах управления технологическими процессами является необходимость учета не только статистических закономерностей, но и физической сущности процесса. Это приводит к появлению гибридных моделей следующего поколения, где нейросетевой ансамбль не просто подменяет физическую модель, а дополняет ее. В такой постановке физическая модель, например, уравнение теплового баланса или кинетики химической реакции, вычисляет базовый прогноз, а нейросетевой суррогат, представляющий собой ансамбль различных архитектур, обучается предсказывать остаточную ошибку или отклонение физической модели от реальных данных [3]. Такой подход, реализованный, в частности, в когнитивных цифровых двойниках, позволяет сочетать предсказуемость и интерпретируемость физических законов с гибкостью и обучаемостью нейронных сетей, а выходной сигнал такого гибридного двойника представляет собой сумму физического предсказания и изученного нейросетью остатка [4]. Этот метод не только повышает точность прогнозов, но и обеспечивает физическую непротиворечивость решений, критически важную для операторного управления, где ошибка в управляющем воздействии может привести к аварийной ситуации. Оператор, видящий прогноз от такого гибридного ансамбля, может доверять ему больше, чем черному ящику, поскольку знает, что физическая составляющая гарантирует соблюдение фундаментальных законов природы. Не менее важным аспектом применения гибридных ансамблей является их интеграция в системы предиктивной и предписывающей аналитики, где они выступают не просто в роли классификаторов состояний, но и как инструменты для поиска причин отклонений и выработки рекомендаций. В исследовании, посвященном интеллектуальному мониторингу производственных процессов, был предложен гибридный подход, сочетающий нейросетевой ансамбль, управляемый генетическим алгоритмом для выбора оптимальных моделей, и механизм извлечения правил на основе генетических алгоритмов для объяснения причин возникновения брака [5]. Такой ансамбль решает две задачи одновременно: он отслеживает качество выпускаемой продукции и классифицирует дефектные категории, а затем на основе извлеченных правил указывает оператору, какие именно параметры процесса и в какую сторону следует изменить для восстановления нормального режима работы, что превращает систему мониторинга в полноценный инструмент поддержки принятия операторских решений [5]. Этот пример наглядно демонстрирует переход от пассивной системы сигнализации об отклонении к активной системе, предлагающей сценарии выхода из критической ситуации, что кардинально меняет роль оператора: он перестает быть реактивным элементом и становится стратегическим руководителем, который утверждает или корректирует рекомендации интеллектуальной системы.



Современное развитие этого направления движется в сторону создания гибридных систем с элементами агентного искусственного интеллекта, где функции между различными компонентами ансамбля распределены не только по типам моделей, но и по иерархическим уровням принятия решений. В такой архитектуре, разработанной для систем предиктивного обслуживания, агенты на основе больших языковых моделей выполняют роль стратегических координаторов, планируя рабочие процессы и сохраняя контекст, в то время как агенты с малыми языковыми моделями или основанные на жестких правилах выполняют конкретные задачи на периферийных устройствах, такие как обнаружение аномалий, извлечение признаков и оптимизация моделей. Между этими уровнями существует четкое разделение ответственности, а интерфейс с оператором обеспечивает прозрачность и контролируемость принимаемых решений, что позволяет системе динамически адаптировать модели, планировать обслуживание оборудования с учетом стоимости и генерировать понятные, приоритетные рекомендации для персонала. Такой подход, подтвержденный экспериментальными исследованиями на промышленных наборах данных, демонстрирует улучшение показателей надежности, масштабируемости и объяснимости решений, что напрямую отвечает на запрос промышленности в создании систем искусственного интеллекта, которые не просто управляют, но и объясняют свои действия. При всей мощи гибридных ансамблей их практическое внедрение в операторное управление сталкивается с рядом серьезных вызовов, главным из которых является проблема доверия и интерпретируемости. Оператор, несущий ответственность за безопасность процесса, должен понимать логику, по которой система предлагает то или иное управляющее воздействие, и здесь на помощь приходят методы объяснимого искусственного интеллекта, а также гибридные архитектуры, где часть компонентов ансамбля изначально прозрачна, например, деревья решений или линейные модели. Исследовательские проекты, такие как европейский проект ULTIMATE, целенаправленно разрабатывают промышленные гибридные модели искусственного интеллекта с улучшенной объяснимостью и интерпретируемостью, ставя во главу угла доверие оператора к системе, что должно привести к повышению эффективности производства, сокращению времени простоев и расширению возможностей персонала за счет перехода к высококвалифицированной работе с интеллектуальными ассистентами [4]. Следующим моментом является адаптивность ансамблей к изменяющимся условиям работы, поскольку технологический процесс не статичен, и модель, обученная на исторических данных, может со временем устаревать, что требует внедрения механизмов обнаружения дрейфа концепции и автоматического переобучения [3]. Для решения этой проблемы предлагаются усовершенствованные гибридные нейросетевые фреймворки, которые используют адаптивную идентификацию операционных состояний через обнаружение сдвигов в распределении данных и многомерное извлечение признаков, комбинируя заданные оператором установки и наблюдаемые временные ряды, что позволяет модели точно классифицировать текущий режим работы и выдавать прогнозы с учетом человеческого вмешательства.

Успех применения гибридных нейросетевых ансамблей в операторном управлении напрямую зависит от качества и объема данных, на которых они обучаются, а также от того, насколько полно эти данные отражают все возможные режимы работы оборудования. Промышленные данные часто характеризуются высокой зашумленностью, пропусками и несбалансированностью классов, когда нормальных режимов работы значительно больше, чем аварийных или предаварийных ситуаций. Ансамблевые методы, особенно с использованием бутстрап-выборок и агрегации, как в методе бэггинга, позволяют частично компенсировать эти проблемы за счет обучения каждой базовой модели на своей, уникальной подвыборке данных, что повышает общую устойчивость системы к выбросам и шумам. Метод бустинга, напротив, фокусируется на последовательном улучшении моделей, каждая следующая из которых обучается на примерах, где предыдущие ошибались, что позволяет



сместить фокус модели на трудные для распознавания случаи, хотя и требует большего объема данных и может быть чувствителен к выбросам. Выбор между этими и другими методами ансамблирования, включая стекинг, где прогнозы базовых моделей используются в качестве входных признаков для мета-модели, становится отдельной исследовательской задачей и зависит от специфики технологического процесса, доступных вычислительных ресурсов и требуемой интерпретируемости.

Гибридные нейросетевые ансамбли уже сегодня показывают впечатляющие результаты в самых разных областях операторного управления: от диагностики состояния прокатных станов и металлургических печей до управления химическими реакторами и поддержки принятия решений в распределенных энергосистемах. Например, в задачах диагностики металлических микроструктур ансамбль сверточных нейронных сетей продемонстрировал рост точности классификации дефектов по сравнению с одиночной моделью при увеличении числа классов, подтверждая эффективность ансамблей в снижении дисперсии ошибок и коррекции смещения моделей. Еще одним ярким примером является создание когнитивного цифрового двойника с гибридным ансамблем для управления солнечной электростанцией, где физическая модель преобразования энергии дополняется нейросетевыми суррогатами для прогнозирования variability выработки, а на основе выданных прогнозов строится система управления с подкреплением, учитывающая ограничения безопасности и тепловые режимы [5]. Этот пример особенно показателен, так как демонстрирует полный цикл: от сбора данных и их фильтрации байесовским сглаживанием до формирования управляющих сигналов и их визуализации оператору в иммерсивной среде, где он может оценить прогнозируемую траекторию и принять окончательное решение.

Таким образом, гибридные нейросетевые ансамбли представляют собой не просто еще один инструмент в арсенале специалиста по автоматизации, а фундаментальный сдвиг в способе построения систем операторного управления технологическими процессами, смещая акцент от жестко запрограммированных алгоритмов к адаптивным, самообучающимся системам, способным учитывать всю сложность реального производства. Объединение множества моделей позволяет компенсировать недостатки каждого отдельного алгоритма, обеспечивая высокую точность, устойчивость к шумам и выбросам, а также предоставляя возможность интерпретации принимаемых решений, что критически важно для выстраивания доверительных отношений между человеком и машиной. Будущее этого направления лежит в еще более тесной интеграции различных парадигм искусственного интеллекта: символьных методов, обеспечивающих логическую прозрачность, нейросетевых подходов, дающих гибкость обучения, и физических моделей, гарантирующих соблюдение законов природы, – все это будет объединено в многоуровневые агентные системы, где каждый компонент ансамбля выполняет свою специализированную роль, а оператор выступает в качестве высшего арбитра и стратегического партнера. В конечном итоге, именно такой синтез знаний и методов позволит сделать промышленность не только более эффективной, но и более безопасной, а процесс управления – более осмысленным и объяснимым.

Список литературы:

1. Ломакина Л. С., Двиговская А. Н., Корелин К. А. Диагностирование и прогнозирование состояний технических и технологических объектов на основе ансамблевых технологий машинного обучения // Информационные и математические технологии в науке и управлении. 2025. № 4(40). С. 26–37. DOI: 10.25729/ESI.2025.40.4.003.
2. Шевнина Ю. С., Хвостик П. М., Зайцев В. В., Винокуров А. А., Портнов Е. М. Прогностическое моделирование дефектов в изделиях микроэлектроники на основе нейросетевых ансамблей // Известия высших учебных заведений. Электроника. 2025. Т. 30, № 4. С. 487-496.



3. Пучков А. Ю., Дли М. И., Рысина Е. И. Нейро-нечеткий классификатор состояния технологического процесса // Известия Санкт-Петербургского государственного технологического института (технического университета). 2021. № 57(83). С. 105-110.

4. Жилов Р. А. Постройка ПИД-регулятора с использованием нейронных сетей // Известия Кабардино-Балкарского научного центра РАН. 2022. № 5. С. 38-47.

5. Невредин А. Р. Применение ансамблевых алгоритмов машинного обучения для предиктивной аналитики в промышленности // Будущее машиностроения России: сборник докладов: в 2 т. / Союз машиностроителей России, Московский государственный технический университет имени Н. Э. Баумана (национальный исследовательский университет) (МГТУ им. Н. Э. Баумана). М. : Изд-во МГТУ им. Н. Э. Баумана, 2021. Т. 2. С. 386-390.

