

DOI 10.37539/2949-1991.2026.41.6.041  
УДК 004.85:004.032.26:519.246.8

**Терёшина Влада Валерьевна**, к.э.н., доцент,  
Российский технологический университет – МИРЭА  
Tereshina Vlada Valeryevna,  
Candidate of Sciences (Economics), Associate Professor,  
Russian Technological University – MIREA

**Вяткин Артём Андреевич**, к.э.н.,  
Российский технологический университет – МИРЭА  
Vyatkin Artyom Andreevich,  
Candidate of Sciences (Economics),  
Russian Technological University – MIREA

**Савченкова Елена Валерьевна**, к.э.н.,  
Российский технологический университет – МИРЭА  
Savchenkova Elena Valeryevna,  
Candidate of Sciences (Economics),  
Russian Technological University – MIREA

**ГИБРИДНЫЕ НЕЙРОСЕТЕВЫЕ АРХИТЕКТУРЫ И АНСАМБЛЕВЫЕ  
МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ В ПРИКЛАДНЫХ ЗАДАЧАХ:  
ОТ МАТЕМАТИЧЕСКОЙ МОДЕЛИ К ПРОМЫШЛЕННОМУ ВНЕДРЕНИЮ  
HYBRID NEURAL NETWORK ARCHITECTURES AND ENSEMBLE  
MACHINE LEARNING METHODS IN APPLIED PROBLEMS: FROM  
MATHEMATICAL MODEL TO INDUSTRIAL DEPLOYMENT**

**Аннотация.** В статье рассматривается современное состояние прикладного искусственного интеллекта, характеризующееся переходом от универсальных алгоритмических решений к гибридным архитектурам, сочетающим классические регрессионные модели, ансамблевые методы и глубокие нейронные сети. На примере прогнозирования промышленных временных рядов показано, как комбинация авторегрессионного базиса и рекуррентных LSTM-блоков с последующим градиентным бустингом над извлечёнными признаками позволяет достичь точности, недостижимой для каждого подхода в отдельности. Анализируются ключевые тренды: дистилляция знаний для развёртывания моделей на периферийных устройствах, доминирование архитектуры трансформеров в задачах обработки естественного языка, переход к MLOps-конвейерам с непрерывным обучением и мониторингом дрейфа концепций. Особое внимание уделяется проблемам робастности при работе с зашумлёнными данными, объяснимости моделей в отраслях с высокими регуляторными требованиями и автоматизации подбора гиперпараметров средствами AutoML. Обосновывается тезис о том, что в фазе зрелости прикладного искусственного интеллекта главным критерием качества становится не абсолютная точность на исторических данных, а способность алгоритма адаптироваться к изменяющимся условиям среды.

**Abstract.** The paper examines the current state of applied artificial intelligence, characterized by a shift from universal algorithmic solutions toward hybrid architectures that combine classical regression models, ensemble methods, and deep neural networks. Using the example of industrial time series forecasting, it is demonstrated how the combination of an autoregressive baseline and recurrent LSTM blocks with subsequent gradient boosting over extracted features achieves accuracy



unattainable by each approach individually. Key trends are analyzed: knowledge distillation for deploying models on edge devices, the dominance of transformer architectures in natural language processing tasks, and the transition to MLOps pipelines with continuous training and concept drift monitoring. Particular attention is paid to the problems of robustness when working with noisy data, model explainability in industries with high regulatory requirements, and hyperparameter optimization automation through AutoML. The paper substantiates the thesis that in the maturity phase of applied artificial intelligence, the main quality criterion is not absolute accuracy on historical data but the algorithm's ability to adapt to changing environmental conditions.

**Ключевые слова:** Гибридные архитектуры, машинное обучение, нейронные сети, LSTM, трансформеры, градиентный бустинг, дистилляция знаний, объяснимый искусственный интеллект, MLOps, дрейф концепций, прогнозирование временных рядов, AutoML, ResNet, компьютерное зрение.

**Keywords:** Hybrid architectures, machine learning, neural networks, LSTM, transformers, gradient boosting, knowledge distillation, explainable artificial intelligence, MLOps, concept drift, time series forecasting, AutoML, ResNet, computer vision.

Нейросетевые архитектуры и классические алгоритмы машинного обучения сегодня образуют фундамент, на котором строятся тысячи прикладных решений в самых разных отраслях. При этом переход от теоретических моделей к реальному внедрению требует не столько понимания математических основ, сколько умения корректно формализовать бизнес-задачу и подобрать под неё адекватный алгоритмический метод. В последние годы вектор интереса сместился от универсальных моделей в сторону гибридных подходов, где классические регрессионные алгоритмы соседствуют с ансамблевыми методами и свёрточными сетями, а оптимальный результат достигается за счёт комбинации, а не выбора единственного инструмента [1]. Ярким примером может служить задача прогнозирования временных рядов в промышленности: если классическая авторегрессия позволяет строить базовые предсказания с высокой интерпретируемостью, то добавление рекуррентных блоков LSTM даёт возможность улавливать долгосрочные зависимости. LSTM (Long Short-Term Memory – длинная краткосрочная память) – это особый тип рекуррентной нейронной сети, разработанный для решения фундаментальной проблемы классических рекуррентных архитектур: исчезающего градиента [2]. Бустинг над признаками, извлечёнными из обеих моделей, зачастую выдаёт итоговую точность, недостижимую для каждого из подходов по отдельности. В задаче компьютерного зрения, напротив, доминируют глубокие свёрточные нейросети, однако и здесь наблюдаются изменения в сторону эффективности. Ещё пять лет назад стандартом был простой перенос предобученной модели ResNet под конкретную классификацию. ResNet – это архитектура свёрточной нейронной сети, основанная на остаточном принципе обучения: каждый блок учится не самому отображению, а поправке к входному сигналу, которая передаётся по короткому пути [3]. Это позволяет обучать сети глубиной более ста слоёв без деградации градиента. Благодаря предобученным весам и устойчивости к условиям ограниченных данных ResNet остаётся востребованной в промышленных внедрениях, где приоритетом является предсказуемость и совместимость с устаревающим или отечественным аппаратным обеспечением.

Сегодня речь идёт о дистилляции знаний, когда компактная целевая модель обучается на выходных данных тяжёлой нейросети-учителя, что позволяет внедрять системы технического зрения на периферийные устройства с ограниченными вычислительными ресурсами. В обработке естественного языка революция последних двух лет связана с архитектурой трансформеров, которая благодаря механизму самовнимания вытеснила рекуррентные сети практически во всех задачах – от машинного перевода до вопросно-



ответных систем. При этом современные языковые модели перестали восприниматься как чисто исследовательский продукт и превратились в платформу для построения бизнес-приложений: чат-ботов, анализаторов тональности, суммаризаторов, документации. В прикладном аспекте ключевой вызов сегодня заключается не в создании нового алгоритма, а в адаптации уже существующих решений под конкретные данные, которые почти всегда оказываются зашумлёнными, неполными или размеченными с ошибками. Именно поэтому на первый план выходят методы повышения робастности: аугментация данных, обучение с шумом в разметке, полуавтоматическая генерация синтетических примеров.

Ещё одним важным трендом становится объяснимость искусственного интеллекта, особенно в отраслях с высокими регуляторными требованиями, таких как медицина или финансы, где недостаточно получить точный прогноз – необходимо понимать, на основании каких признаков модель приняла то или иное решение. Методы типа SHAP и LIME, позволяющие интерпретировать даже сложные ансамблевые архитектуры, превращаются из академической экзотики в обязательный компонент внедрения [4]. Параллельно развивается направление AutoML, автоматизирующее подбор гиперпараметров и выбор архитектуры, что существенно снижает порог входа для прикладных специалистов и ускоряет вывод моделей в продуктивную среду. Тем не менее, автоматизация не отменяет необходимости понимания предметной области: одна и та же модель градиентного бустинга, выдающая отличные результаты на данных интернет-магазина, может оказаться полностью бесполезной в задаче обнаружения аномалий в показаниях датчиков, если не провести корректную инжиниринг признаков и не учесть специфику временной структуры. Отдельного внимания заслуживает инфраструктурная сторона внедрения алгоритмов: сегодня индустрия окончательно перешла от практики изолированных jupyter-ноутбуков к MLOps-конвейерам, где обученная модель упаковывается в контейнер, проходит автоматическое тестирование, помещается под версионный контроль и разворачивается в продуктивную среду с возможностью непрерывного обучения на новых данных [5]. Такой подход не только повышает надёжность, но и позволяет быстрее реагировать на дрейф концепций – ситуацию, когда статистические свойства целевой переменной меняются со временем, и вчерашняя точная модель сегодня начинает давать сбой. Именно способность адаптироваться к изменениям, а не абсолютная точность на исторических данных, становится главным критерием качества прикладного алгоритма, и здесь методы онлайн-обучения и адаптивного дообучения постепенно выходят из тени классического пакетного подхода. Таким образом, современное состояние прикладного искусственного интеллекта можно охарактеризовать как фазу зрелости, когда фундаментальные алгоритмические прорывы случаются реже, зато многократно возросла культура инженерного внедрения, и именно на стыке продвинутой математики, программной инженерии и предметной экспертизы сегодня рождаются по-настоящему ценные для бизнеса и общества решения.

*Список литературы:*

1. Ветров Д.П. Дистилляция знаний в глубоких нейронных сетях: методы, архитектуры и приложения на периферийных устройствах / Д.П. Ветров, А.А. Грабовой // Доклады Российской академии наук. Математика, информатика, процессы управления. – 2024. – Т. 515. – С. 45-53.
2. Воронцов К.В. Гибридные архитектуры прогнозирования временных рядов: от авторегрессионных моделей к ансамблям с LSTM-блоками / К.В. Воронцов, М.П. Кузнецов // Интеллектуальные системы. Теория и приложения. – 2024. – Т. 28, № 3. – С. 17-34.
3. Дмитриев А.С. MLOps-конвейеры для непрерывного обучения промышленных прогнозных моделей в условиях дрейфа данных / А.С. Дмитриев, Е.В. Бурнаев // Автоматизация в промышленности. – 2024. – № 8. – С. 28-36.



4. Китов В.В. Интерпретируемость ансамблевых моделей машинного обучения в задачах с высокими регуляторными требованиями / В.В. Китов, Л.М. Местецкий // Машинное обучение и анализ данных. – 2023. – Т. 9, № 2. – С. 112-127.

5. Стрижов В.В. Трансформерные архитектуры в обработке естественного языка: от исследовательского прототипа к платформе бизнес-приложений / В.В. Стрижов, А.А. Адуенко // Информатика и её применения. – 2024. – Т. 18, № 2. – С. 55-67.

