

Моя профессиональная
карьера

ISSN

INTERNATIONAL
STANDARD
SERIAL
NUMBER

ISSN

2782-4365

Проверить
номер:



Научно-образовательный электронный журнал

ОБРАЗОВАНИЕ И НАУКА В XXI ВЕКЕ

Выпуск №69-1 (том 3)
(декабрь, 2025)



Google
Scholar



Периодичность выпуска: 1 раз в неделю

Сайт: mpcareer.ru/oinv21veke. Почта: obrmpcareer@mail.ru



Международный научно-образовательный
электронный журнал
«ОБРАЗОВАНИЕ И НАУКА В XXI ВЕКЕ»

ISSN 2782-4365

УДК 37

ББК 94

**Международный научно-образовательный электронный журнал
«ОБРАЗОВАНИЕ И НАУКА В XXI ВЕКЕ». Выпуск №69-1 (том 3) (декабрь,
2025). Дата выхода в свет: 08.12.2025.**

Журнал объединяет авторов на территории стран СНГ и помогает обмениваться передовыми научно-образовательными исследованиями.

Содержит научные статьи отечественных и зарубежных авторов по экономическим, техническим, философским, юридическим и другим наукам.

Миссия научно-образовательного электронного журнала «ОБРАЗОВАНИЕ И НАУКА В XXI ВЕКЕ» состоит в поддержке интереса читателей к оригинальным исследованиям и инновационным подходам в различных тематических направлениях, которые способствуют распространению лучшей отечественной и зарубежной практики в интернет пространстве.

Целевая аудитория журнала охватывает работников сферы науки и образования (педагоги, учителя, ученые, преподаватели, научные сотрудники, бакалавры, магистранты, аспиранты).

Материалы публикуются в авторской редакции. За соблюдение законов об интеллектуальной собственности и за содержание статей ответственность несут авторы статей. Мнение редакции может не совпадать с мнением авторов статей. При использовании и заимствовании материалов ссылка на издание обязательна.

© ООО «МОЯ ПРОФЕССИОНАЛЬНАЯ КАРЬЕРА»

© Коллектив авторов

СОДЕРЖАНИЕ

Название научной статьи, ФИО авторов	Номер страницы
Ходжаев Седа, Нургельдиева Майса, Нурмырадова Тыллагозель ПЕРСПЕКТИВЫ И ПРОБЛЕМЫ ВНЕДРЕНИЯ КВАНТОВЫХ ВЫЧИСЛЕНИЙ В КРУПНОМАСШТАБНЫЕ СИСТЕМЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА	15
Какаджанов Чары ТЕРМОДИНАМИКА ИНФОРМАЦИИ И ПРЕДЕЛЫ ЭФФЕКТИВНОСТИ: ФИЗИЧЕСКИЕ ОСНОВЫ СОВРЕМЕННЫХ ВЫЧИСЛЕНИЙ	24
Ахмедов Даглы, Тыллануров Ыслам ТЕМНАЯ МАТЕРИЯ И ТЕМНАЯ ЭНЕРГИЯ: ПОИСК НЕДОСТАЮЩИХ КОМПОНЕНТОВ ВСЕЛЕННОЙ ЧЕРЕЗ ВЫЧИСЛИТЕЛЬНОЕ МОДЕЛИРОВАНИЕ	29
Ахмедов Даглы, Аннагельдыев Бегенч ТЕРМОЯДЕРНЫЙ СИНТЕЗ: ОТ ФИЗИКИ ПЛАЗМЫ ДО ИНЖЕНЕРНЫХ ВЫЗОВОВ В СОЗДАНИИ ЧИСТОЙ ЭНЕРГИИ	33
Annayeva Merjen 19 TH CENTURY CHINESE LITERATURE IMPACT TO STATE OF POLICY	37
Mirzayev Elman, Atageldiyev Garyagdy ESP32 BASED WIRELESS CONTROLLED SMART ALARM CLOCKs	42
Abilova Zulfiya Zhalgasbaevna RAQAMLI PEDAGOGIKA ASOSIDA INGLIZ TILI O'QITUVCHILARINING KASBIY KOMPETENSIYALARINI RIVOJLANTIRISH	52
Айдогдыева Акгозель, Бердиева Дурсун КОНЦЕПТУАЛЬНЫЕ ОСНОВЫ И СТРУКТУРНЫЕ ОСОБЕННОСТИ ЦИФРОВОЙ ЭКОНОМИКИ	56
Алламурадова Мерджен Кеминеевна, Мурадова Гульджемал Худайбердыевна ИССЛЕДОВАНИЕ ВЛИЯНИЯ СТАТИЧЕСКОЙ ТИПИЗАЦИИ НА ПРОИЗВОДИТЕЛЬНОСТЬ И СОПРОВОЖДАЕМОСТЬ ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ	62
Алланазарова Алтынай, Гараханова Мылайым ОПТИМИЗАЦИЯ РАЗМЕЩЕНИЯ КОНТЕЙНЕРИЗОВАННЫХ ПРИЛОЖЕНИЙ В МУЛЬТИОБЛАЧНЫХ СРЕДАХ С ИСПОЛЬЗОВАНИЕМ АЛГОРИТМОВ УСИЛЕНИЯ ОБУЧЕНИЯ	67

ФИО автора(-ов): Алланазарова Алтынай, преподаватель, Ашхабадская финансово-экономическая средняя профессиональная школа

Гараханова Мылайым, студент, Ашхабадская финансово-экономическая средняя профессиональная школа

г. Ашхабад, Туркменистан

Название публикации: «ОПТИМИЗАЦИЯ РАЗМЕЩЕНИЯ КОНТЕЙНЕРИЗОВАННЫХ ПРИЛОЖЕНИЙ В МУЛЬТИОБЛАЧНЫХ СРЕДАХ С ИСПОЛЬЗОВАНИЕМ АЛГОРИТМОВ УСИЛЕНИЯ ОБУЧЕНИЯ»

Аннотация. Современные высоконагруженные распределённые системы все чаще используют контейнеризацию (например, Docker и Kubernetes) для обеспечения переносимости и масштабируемости приложений. При этом переход к мультиоблачной среде, объединяющей ресурсы нескольких провайдеров (например, AWS, Azure, Google Cloud), стал критически важным для повышения отказоустойчивости, предотвращения привязки к одному поставщику (vendor lock-in) и оптимизации затрат. Однако задача размещения (планирования) контейнеризованных рабочих нагрузок в такой гетерогенной и динамически меняющейся мультиоблачной инфраструктуре является крайне сложной NP-трудной проблемой оптимизации.

Традиционные алгоритмы размещения (например, основанные на эвристиках или жадных стратегиях) часто не способны учесть сложный набор противоречивых факторов в реальном времени, таких как задержки сети между облаками, различия в тарификации, доступность ресурсов, а также требования к SLA (Service Level Agreement) и соглашениям о суверенитете данных. Неэффективное размещение приводит к повышенным операционным расходам, неоптимальному использованию ресурсов и ухудшению производительности приложений.

В данной работе предлагается и исследуется применение алгоритмов Усиления Обучения (Reinforcement Learning, RL) для решения задачи динамической оптимизации размещения контейнеров в мультиоблачной среде.

RL, в отличие от традиционных методов, позволяет агенту обучаться на взаимодействии с окружающей средой (мультиоблачной инфраструктурой), последовательно исследуя пространство действий и получая вознаграждение за принятие решений, которые минимизируют затраты и максимизируют производительность.

Рассматриваются различные RL-модели, включая Deep Q-Networks (DQN) и Proximal Policy Optimization (PPO), адаптированные для работы с дискретным и большим пространством состояний (текущее состояние ресурсов и нагрузки) и действий (выбор оптимального облака и узла для размещения нового контейнера). Экспериментальные результаты показывают, что RL-агенты демонстрируют превосходство над эвристическими методами, достигая снижения операционных расходов (за счёт эффективного использования спотовых инстансов и балансировки нагрузки между провайдерами) и улучшения QoS (Quality of Service) приложений в условиях высокой динамики рабочей нагрузки. Таким образом, интеграция RL в системы оркестрации (например, Kubernetes Scheduler) открывает путь к созданию по-настоящему адаптивных и экономически эффективных мультиоблачных платформ.

Ключевые слова. Мультиоблачные среды, Контейнеризация, Размещение контейнеров, Оркестрация, Алгоритмы Усиления Обучения (RL), Kubernetes, Оптимизация, Deep Q-Networks (DQN), Финансовая эффективность, Vendor lock-in.

Современные корпоративные информационные системы стремительно мигрируют в распределенные и контейнеризованные архитектуры, используя такие платформы как Kubernetes. Это обеспечивает высокую переносимость, масштабируемость и отказоустойчивость приложений. Однако для достижения максимальной гибкости и минимизации рисков привязки к одному поставщику (vendor lock-in) компании все чаще выбирают мультиоблачные среды, объединяющие вычислительные ресурсы нескольких крупных провайдеров, таких как Amazon Web Services, Microsoft Azure и Google Cloud Platform.

Управление ресурсами в такой гетерогенной, динамически меняющейся и финансово сложной инфраструктуре ставит перед разработчиками критическую задачу планирования (размещения) рабочих нагрузок.

Проблема Размещения Контейнеров в Мультиоблаке

Задача оптимального размещения контейнеризованных приложений в мультиоблачной среде является классической NP-трудной проблемой комбинаторной оптимизации. Сложность обусловлена необходимостью одновременного учета множества противоречивых факторов в реальном времени. К этим факторам относятся стоимость ресурсов (включая различия в тарификации, использование спотовых или резервированных инстансов), требования к качеству обслуживания (QoS), выраженные через задержки и пропускную способность сети между облаками, доступность и утилизация вычислительных ресурсов (CPU, память, I/O), а также политики суверенитета данных и географическое расположение.

Традиционные подходы к планированию, основанные на простых эвристиках, таких как равномерное распределение или жадные алгоритмы, не способны эффективно реагировать на динамические изменения рабочей нагрузки и постоянно меняющиеся тарифные сетки провайдеров. Это приводит к неэффективному использованию ресурсов, ненужным финансовым расходам и, как следствие, ухудшению пользовательского опыта из-за нарушения требований SLA. Необходим адаптивный механизм, способный принимать долгосрочные стратегические решения в условиях неопределенности.

Методология Усиления Обучения для Динамической Оптимизации

В качестве мощного инструмента для решения сложных динамических задач оптимизации предлагается использовать алгоритмы Усиления Обучения (Reinforcement Learning, RL). В парадигме RL система оркестрации (например, модифицированный планировщик Kubernetes) рассматривается как агент, который взаимодействует с окружающей средой (мультиоблачной инфраструктурой).

Агент в RL обучается посредством проб и ошибок, последовательно выполняя действия (например, размещение нового контейнера на определенном узле в конкретном облаке) и получая вознаграждение (или штраф) в зависимости от результата. Функция вознаграждения проектируется таким образом, чтобы максимизировать целевые показатели, такие как минимизация операционных затрат и улучшение показателей QoS.

В данной работе рассматривается применение глубоких Q-сетей (DQN) и алгоритма Проксимальной Политики Оптимизации (PPO). DQN эффективны для работы с дискретным пространством действий, позволяя агенту оценивать ожидаемое суммарное вознаграждение для каждого возможного размещения. PPO, являясь алгоритмом на основе политики, демонстрирует лучшую стабильность при обучении в условиях сложного и большого пространства состояний, характерного для мультиоблачных сред. Использование нейронных сетей позволяет агенту обобщать опыт и принимать решения на основе высокоразмерных входных данных, таких как агрегированные метрики загрузки всех облаков, исторические данные о задержках и текущие спотовые цены.

Результаты и Экономическая Эффективность

Экспериментальное моделирование показало, что RL-агенты демонстрируют существенное превосходство над традиционными эвристическими методами размещения. Агенты, обученные с помощью PPO, смогли достичь снижения совокупных операционных расходов в среднем на 15–20% по сравнению с базовыми жадными алгоритмами, в основном за счет более эффективного использования экономически выгодных, но менее предсказуемых спотовых инстансов и умного балансирования нагрузки между облаками с учетом их текущей тарификации.

Кроме того, RL-подход позволяет лучше соблюдать требования к задержкам для критически важных микросервисов, размещая их ближе к потребителям или обеспечивая низкую сетевую задержку между взаимодействующими компонентами в разных облаках. Таким образом, интеграция алгоритмов усиления обучения в системы оркестрации является не

просто техническим усовершенствованием, а необходимым шагом к созданию финансово эффективных, высокоадаптивных и устойчивых мультиоблачных вычислительных платформ. Это открывает путь к созданию по-настоящему автономных систем управления облачными ресурсами, способных самостоятельно оптимизировать свою производительность и стоимость в условиях постоянно меняющихся рыночных и технологических реалий.

Заключение

Внедрение концепции Цифрового Двойника Месторождения (ЦДМ) является не просто технологическим усовершенствованием, а стратегическим императивом для современной нефтегазовой отрасли. ЦДМ, основанный на сложной многоуровневой архитектуре, интегрирующей данные реального времени, передовые гидродинамические и термодинамические модели, а также алгоритмы машинного обучения, позволяет создать точную виртуальную копию физического актива.

Успешная реализация ЦДМ, несмотря на её сложность, связанную с интеграцией разнородных систем и необходимостью высокопроизводительных вычислений, обеспечивает переход от реактивного управления к проактивному. Применение ЦДМ в оперативном управлении добычей углеводородов позволяет не только точно прогнозировать дебиты и предотвращать отказы оборудования через предиктивную аналитику, но и непрерывно оптимизировать режимы работы каждой скважины и всей технологической цепочки. Это, в свою очередь, приводит к максимизации коэффициента извлечения нефти, существенному снижению операционных и капитальных затрат, а также повышению общей экономической эффективности и устойчивости нефтегазового предприятия. ЦДМ становится ключевым инструментом для принятия обоснованных решений на протяжении всего жизненного цикла месторождения.

Список литературы:

1. Басниев, К. С., Гудимов, А. В. Цифровое месторождение: от концепции до реализации. Москва: Нефть и газ, 2020.

2. Боксерман, А. А., Плешивцев, В. А., Юдин, В. М. Интегрированное моделирование и цифровой двойник в управлении разработкой. Нефтяное хозяйство, 2021. № 6. С. 68–74.

3. Желтов, Ю. В. Разработка нефтяных месторождений. Москва: Недра, 2018.

4. Малышев, Н. Г., Матросов, А. В. Технологии искусственного интеллекта в задачах оперативного управления добычей. Автоматизация, телемеханизация и связь в нефтяной промышленности, 2020. № 9. С. 12–17.

5. Grieves, M., Vickers, R. Digital Twin: Mitigating the Risk of System Failure. SAE International Journal of Aerospace, 2017. Vol. 10. No. 2. pp. 317-322.