

А.А. Толстых, А.Н. Голубинский
**ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ ДАННЫХ НА БАЗЕ
ГЛУБОКОГО ОБУЧЕНИЯ С ПОДКРЕПЛЕНИЕМ
ДЛЯ ПРОГНОЗА РАБОЧИХ ЧАСТОТ И ПОЛОС В СИСТЕМЕ
КОГНИТИВНОГО РАДИО**

Толстых А.А., Голубинский А.Н. Интеллектуальный анализ данных на базе глубокого обучения с подкреплением для прогноза рабочих частот и полос в системе когнитивного радио.

Аннотация. В работе предложен метод решения задачи выбора канала связи в когнитивном радио на основе информации о текущем состоянии всех доступных каналов связи с использованием математического аппарата обучения с подкреплением. Метод заключается в формализации задачи выбора каналов связи в терминах «среда-агент» и обучения агентов с помощью алгоритмов Reinforce, SARSA и A2C. Приведён расчёт затрат памяти на решение задачи выбора каналов связи классическими методами. Оценка по памяти составляет 4×2^{2n} байт для случайного состояния каналов (занят/свободен) и $4 \times n^2$ байт – для одного свободного канала на каждом шаге при решении задачи табличным алгоритмом Q-обучения. Приведены две различные формализации вознаграждения для агента в рамках решаемой задачи при использовании обучения с подкреплением – для тривиального случая (бинарная доступность / недоступность частотного канала) и для более сложного случая – с учётом мощности (в дБ) в выбранном канале связи. Ограничение на первую формализацию состоит в том, что на каждой итерации должен быть только один свободный канал связи из всех доступных. Вторая предложенная формализация функции вознаграждения не накладывает подобных ограничений и более универсальна. Проведены вычислительные эксперименты для обеих формализаций функции вознаграждения, агенты обучающиеся с помощью алгоритмов SARSA и A2C, в среднем, достигают безошибочного решения задачи за 8000 эпизодов обучения для обеих формализаций обучения в модельной задаче для различных реализаций агентов. Алгоритм REINFORCE не позволяет достигать безошибочного решения, однако, формализация вознаграждения с учётом мощности повышает стабильность обучения алгоритмом REINFORCE. Даны теоретические оценки вычислительной сложности рассматриваемых методов, согласующиеся с вычислительными экспериментами.

Ключевые слова: когнитивное радио, обучение с подкреплением, глубокое обучение, искусственная нейронная сеть, многослойный перцептрон, функция вознаграждения, программно-определяемое радио, синтетические данные, аугментация, искусственный интеллект.

1. Введение. Функционирование когнитивных систем радиосвязи основывается на мониторинге радиочастотного спектра с целью идентификации и дальнейшего использования свободных полос частот. Классические подходы не всегда позволяют получить приемлемый на практике результат, в связи с этим, одним из возможных путей решения является применение технологий искусственного интеллекта [1 – 4], и, в частности, обучения с подкреплением [2, 5 – 14]. Таким образом, современный этап научно-технического развития

характеризуется переходом от автоматизации к интеллектуализации управления, при котором окончательное решение принимается интеллектуальной системой, на основании разнородных данных значительного объёма.

Следует отметить, что система когнитивного радио (CRS) – это радиосистема, использующая технологию, которая позволяет этой системе получать знания о своей среде эксплуатации и географической среде, об установившихся правилах и о своём внутреннем состоянии, динамически и автономно корректировать свои эксплуатационные параметры и протоколы согласно полученным знаниям для достижения заранее поставленных целей, обучаясь на основе полученных результатов [15].

Современное развитие аппаратных средств, программного обеспечения и баз данных, для эффективного нейросетевого моделирования на базе глубоких искусственных нейронных сетей, позволяет на сегодняшний день выделить актуальное для теории и практики научно-техническое направление – применение глубокого обучения с подкреплением для задач когнитивного радио [16 – 18].

Применение нейросетевого предиктора на основе глубокого обучения с подкреплением, позволяет проводить машинное обучение без разметки данных при использовании функции вознаграждения [19, 20], то есть при отсутствии «учителя».

Важным компонентом при этом является подготовка обучающих, валидационных и тестовых выборок, включающих композицию из реальных (например, сигналы, поступающие от трансивера на базе программно-определяемого радио или SDR- радиоприёмника) и аугментацию в виде синтетических данных для реализации нейросетевых предикторов (с формированием соответствующей базы данных для обучения).

Необходимо подчеркнуть, что отдельным приоритетным вопросом при решении поставленной задачи когнитивного радио является разработка и исследование адекватного критерия эффективности функционирования системы (например, состоящей из совокупности средств радиосвязи для различных режимов работы).

Цель работы – разработка метода прогноза рабочих частот и полос для системы когнитивного радио на базе глубокого обучения с подкреплением.

2. Постановка задачи. Рассмотрим радиоканал, в котором рабочий частотный диапазон разбит на полосы, и каждая полоса может быть занята или свободна для радиообмена данными. Математически это можно формализовать, сравнивая текущее значение мощности

(PdB_k) помехи в полосе с некоторым порогом (β), получив бинарное состояние: «1» – частотный канал (k) свободен, «0» – частотный канал занят:

$$PN_k = \begin{cases} 1, & \text{если } PdB_k \leq \beta; \\ 0, & \text{иначе,} \end{cases} \quad (1)$$

где порог выбирается из состояния помехово-шумовой обстановки (например, $\beta = -80$ дБм).

Требуется определить рабочие частоты и наибольшие полосы частот для динамически меняющейся электромагнитной обстановки (например, в которой присутствуют периодические и непериодические помехи, фон и другие шумы различной природы).

3. Описание метода. Определим в качестве критерия для решения поставленной задачи – максимизацию целевой функции в виде некоторого показателя качества прогноза. В этой связи необходимо максимизировать качество прогноза рекомендуемых свободных каналов:

$$\max[g_t], \quad (2)$$

где g_t – показатель качества прогноза, который определяется как функция от состояния радиоканалов в следующий момент времени. Например, как скалярное произведение соответствующих векторов и выглядит следующим образом:

$$g_t = a_t^T PN_{t+1}, \quad (3)$$

здесь a_t – вектор-столбец действия агента в текущий момент времени («1» – канал рекомендуется использовать, «0» – канал не рекомендуется использовать); PN_{t+1} – вектор-столбец состояния радиоканалов на основе измеренной или моделируемой помехово-шумовой обстановки в следующий момент времени с элементами $\{PN_k\}$ («1» – канал свободен, «0» – канал занят); «Т» – операция транспонирования.

Функцию вознаграждения (r_{t+1}) можно определить, через функциональную зависимость от показателя качества прогноза или в первом приближении, возможно, использовать их равенство:

$$r_{t+1} = g_t. \quad (4)$$

Два основных подхода к обучению с подкреплением для безмодельных методов (не задействуют динамику переходов среды в явном виде) – алгоритмы, основанные на полезности и алгоритмы на базе стратегии (политики) [19, 20].

Например, если для решения задачи воспользоваться Q-обучением (основано на полезности), то на каждом шаге на основе ε -жадной стратегии, текущего состояния среды (s_t) и Q-матрицы (Q_t) формируется текущее действие агента a_t , на базе которого получается состояние среды, т.е. матрица прогноза состояния радиоканала («1» – канал свободен, «0» – канал занят) в следующий момент времени s_{t+1} , например:

$$s_{t+1} = a_t, \quad (5)$$

которая также может быть дополнена априорной информацией, помимо вектора-столбца a_t , векторами-столбцами о текущем и предыдущих состояниях радиоканала (например: PN_{t+1} , PN_t , PN_{t-1}, \dots). Далее рассчитывается значение функции вознаграждения в следующий момент времени (r_{t+1}) и на его основе вычисляется Q-матрица значений ценности состояний в следующий момент времени (Q_{t+1}), используя такие гиперпараметры как скорость обучения (α) и коэффициент дисконтирования (γ) [19]. Настройка Q-функции осуществляется с помощью метода временных различий (TD-обучения, сочетающего в себе идеи метода Монте-Карло и динамического программирования) и использования итерационного метода для решения уравнения оптимальности Беллмана [20].

Существенным ограничением для непосредственного использования алгоритмов табличных методов решения на основе полезности и на основе стратегии является значительное множество возможных состояний (для Q-обучения – это большая размерность Q-матрицы, а для обучения на базе стратегии – большая размерность π -матрицы вероятностей действия в соответствующем состоянии). Например, при n одновременно анализируемых частотных каналов при случайном состоянии канала («свободен»/«занят») количество состояний среды (N) определяется выражением (количество строк Q-матрицы):

$$N = 2^n, \quad (6)$$

а количество возможных действий агента (M) также рассчитывается по формуле (количество столбцов Q-матрицы):

$$M = 2^n. \quad (7)$$

В результате Q-матрица содержит $N \times M$ элементов:

$$N \times M = 2^{2n}, \quad (8)$$

и для её описания при одинарной точности (FP32) потребуется:

$$V = 4 \times 2^{2n} \text{ байт}. \quad (9)$$

При $n=16$ следует, что только для хранения Q-матрицы потребуется 16 ГБ, а при $n=20$ необходимо 4 ТБ.

Однако, если рассмотреть тривиальный частный случай, например, когда из n каналов всегда свободен только один, то размер Q-матрицы существенно уменьшается, а расчётные формулы принимают вид:

$$N = n; \quad M = n, \quad N \times M = n \times n, \quad V = 4 n^2 \text{ байт}, \quad (10)$$

тогда при $n=16$ следует, что для хранения Q-матрицы потребуется 1 КБ, а при $n=20$ необходимо 1,6 КБ.

Таким образом, наличие закономерностей (например, детерминированных) появления помех в радиоканалах позволяет определённым образом уменьшить число возможных состояний, однако следует учитывать условия конкретной задачи и ограничения, накладываемые на объем памяти ОЗУ. Так как для агента очень важно, какие вычислительные мощности ему доступны, в частности какой объем вычислений может быть выполнен за один временной шаг, также сдерживающим фактором является доступная память [19].

Для преодоления проблемы размерности, связанной со значительным числом возможных состояний, предлагается воспользоваться компактной (относительно таблиц) параметризацией (приближенным методом решения) в виде аппроксимаций Q-функции полезности (рисунок 1) или π -функции стратегии (рисунок 2) искусственной нейронной сетью (ИНС) в виде многослойного персептрона (МСП) с параметрами w . Под глубокой нейронной сетью будем понимать ИНС, которая содержит три и более слоёв (два и более скрытых слоёв).





Рис. 1. Блок-схема аппроксиматора Q-функции полезности ИНС в виде МСП

Рис. 2. Блок-схема аппроксиматора π -функции стратегии ИНС в виде МСП

При этом для глубокого обучения с подкреплением существует множество эффективных алгоритмов, основанных на полезности (SARSA, DQN), стратегии (Policy Gradients, REINFORCE), комбинированные методы (A2C, A3C) и др. [20]. Заметим, что для сокращения размерности выходного слоя ИНС (количества выходов МСП) целесообразно использовать подход, базирующийся на обучении с подкреплением при многоцелевых действиях агента [21].

Полученные значения действий агента (a_t) позволяют прогнозировать свободные (пригодные для радиосвязи) частотные каналы без разметки данных для обучения. Следует отметить, что если прогнозные значения находящихся рядом каналов «свободны» (равны «1»), то это позволяет выбрать соответствующую более широкую полосу частот на рабочей частоте (которая является центральной частотой в окрестности полосы).

3. Теоретическая оценка вычислительной сложности рассматриваемых алгоритмов. В работе рассматриваются алгоритмы следующие алгоритмы обучения с подкреплением: REINFORCE, SARSA, A2C. Перед проведением вычислительного эксперимента целесообразно оценить вычислительную эффективность каждого из них, а затем сопоставить теоретические оценки с полученным эмпирическим материалом. Формальное построение оценки

вычислительной эффективности произведено с учётом следующих ограничений:

1. Предполагается дискретное пространство действий (выбор одного из n каналов);
2. Агент в виде МСП содержит один скрытый слой;
3. Последнее выбранное действие (отклик) агента интегрировано в тензор состояния среды;
4. Вычисление функции активации будем считать не влияющий на асимптотическую сложность ($f(x) \stackrel{\text{Def}}{=} O(1)$).

Для построения оценки алгоритмов введём следующие обозначения:

1. Среда характеризуется размерностью состояния d_s ; количеством дискретных действий d_a ; максимальной длиной эпизода T .
2. Агент (искусственная нейронная сеть) количеством нейронов в скрытом слое m ; входной размерностью d_s ; количеством выходных нейронов d_a .

Рассмотрим по порядку каждый из алгоритмов. Алгоритм REINFORCE представляет собой реализацию метода градиента политики (Policy Gradient), где агент обучает параметризованную политику $\pi_\theta(a|s)$, реализованную как МСП путём максимизации ожидаемой награды. Политика генерирует действия и агрегируются траектории в рамках одного эпизода, вычисляются функция стоимости и градиент политики обновляется. Формула градиента:

$$\nabla_\theta J(\theta) = \mathbb{E} \tau \sim \pi_\theta \left[\sum_{t=0}^T \nabla_\theta \log \pi_\theta(a_t | s_t) \cdot G_t \right], \quad (11)$$

где $G_t = \sum_{k=t}^T \gamma^{k-t} r_k$ дисконтированное вознаграждение (reward), γ – дисконтирующий фактор, $\tau = (s_0, a_0, r_0, \dots, s_T)$ – траектория в рамках эпизода. Для каждого эпизода вычисляется: прямое вычисление МСП для выбора действия $O(T \cdot m^2)$, вычисление функции вознаграждения $O(T)$ и вычисление градиентов для МСП $O(T \cdot m^2)$. Таким образом, основные вычисления приходятся на прямой проход и обратное распространение ошибки в МСП. Сложность алгоритма REINFORCE линейна по T , однако в значительной мере зависит от размера МСП. Для наших целей, можно считать, что вычисление REINFORCE заключается в вычислении прямого прохода МСП и обратного распространения ошибки по нему для каждой итерации эпизода.

Алгоритм SARSA представляет собой метод аппроксимации Q-функции $Q_\theta(s, a)$ реализованной в виде МСП. Агент выбирает действия по ε -жадной стратегии. Обновление на каждом шаге определяется следующим образом [20]:

$$Q(s_t, a_t) = Q(s_t, a_t) + \alpha [r_t + \gamma Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t)], \quad (12)$$

где $a_{t+1} \sim \pi(s_{t+1})$ представляет собой политику; α – скорость обучения. Градиенты для МСП в алгоритме SARSA вычисляются как [20]:

$$\theta = \theta - \alpha \nabla_\theta (r_t + \gamma Q_\theta(s_{t+1}, a_{t+1}) - Q_\theta(s_t, a_t))^2. \quad (13)$$

Аналогично алгоритму REINFORCE на первом этапе вычисляется прямой проход МСП $O(T \cdot m^2)$, после чего происходит шаг симуляции $O(T)$, затем второе вычисление прямого прохода по МСП для вычисления a_{t+1} $O(T \cdot m^2)$, вычисление ошибки на основе функции вознаграждения $O(T)$ и вычисление градиентов для МСП $O(T \cdot m^2)$. Таким образом, асимптотически алгоритм SARSA имеет такую же сложность что и REINFORCE, однако, как и в случае с REINFORCE можно дать оценку в количестве прямых проходов и обратного распространения ошибки, для SARSA соответственно 2 и 1 на каждую итерацию в эпизоде.

Последний рассматриваемый алгоритм A2C представляет собой синхронный вариант метода актор-критик и имеет 2 МСП: актора для аппроксимации политики $\pi_\theta(a|s)$ и критика для оценки функции стоимости $V_\phi(s)$. Также как и в предыдущих алгоритмах, на первом этапе вычисляется прямой проход по МСП-актору $O(T \cdot m^2)$, затем вычисляется прямой проход по МСП-критику $O(T \cdot m^2)$, после чего вычисляются шаг симуляции и функция потерь $O(T)$, завершается все вычислением градиентов для МСП-актора $O(T \cdot m^2)$ и МСП-критика $O(T \cdot m^2)$. Таким образом, для алгоритма A2C сложность линейна по длине эпизода, однако на каждую итерацию необходимо вычислить 2 прямых прохода по МСП и 2 прохода обратного распространения ошибки.

Учитывая тот факт, что наибольший вклад в оценку вычислительной сложности рассматриваемых алгоритмов вносит прямой проход и обратное распространение ошибки в МСП целесообразно расширить оценку на произвольный МСП с L скрытыми слоями по $m \in \{m_1, m_2, \dots, m_L\}$ нейронов в каждом, таким образом сняв

ограничение II. Учитывая ограничение IV прямой проход по l слою L - слойного МСП оценивается как:

$$O(m_{\{l-1\}} \times m_{\{l\}} + m_{\{l\}}) \xrightarrow{m=\max(m_{l-1}, m_l)} O(m^2). \quad (14)$$

Заметим, что сложность прямого прохода в терминах O равна сложности обратного распространения ошибки. В качестве верхней оценки вычислительной сложности для L -слойного МСП целесообразно принять значение $O(L \times \max(m)^2)$ – сложность вычисления каждого слоя соответствует сложности вычисления наиболее широкого (содержащего наибольшее число нейронов) слоя МСП. В рамках рассматриваемой задачи данное округление оценки допустимо, так как, сравниваются алгоритмы, обучающие одинаковые L - слойные МСП (в том числе МСП-критик для алгоритма SARSA имеет ту же архитектуру, что и МСП для остальных алгоритмов). Таким образом, для всех рассмотренных алгоритмов сложность остаётся линейной по T , оценка не изменяется при замене реализации аппроксиматора с однослойного персептрона на МСП.

В результате проведённого анализа, учитывая, что проход обратного распространения ошибки по МСП содержит, в среднем в 2 раза больше операций [4], сформулируем следующие количественные оценки: наиболее быстрым является алгоритм REINFORCE, приблизительно в 1,5 раза медленнее SARSA, а A2C приблизительно в 2 раза медленнее.

4. Моделирование среды. Для моделирования работы алгоритмов обучения с подкреплением на основе формализации задачи была построена следующая модель среды: в наборе из N каналов в каждый момент времени t свободен только один канал. Формально симуляция среды представляет собой правило, по которому для каждого шага времени t строится вектор из N величин соответствующих уровню шумов, индекс элемента вектора соответствует индексу канала. Среда является параметрической и определяется следующим набором параметров: N – общее число каналов, $f_{\text{пор}}(t)$ – закон изменения свободного канала; $P_{(\text{ш}, \text{min})}$ – минимальный уровень шумов (дБ); $P_{(\text{ш}, \text{max})}$ – максимальный уровень шумов (дБ); $P_{(c, \text{min})}$ – минимальный уровень полезного сигнала (дБ); $P_{(c, \text{max})}$ – максимальный уровень полезного сигнала (дБ); V – максимальная амплитуда флуктуаций шумов; T – общее время (дискретное) генерации, сколько векторов будет сгенерировано до окончания текущей сессии.

Подобная формализация позволяет достаточно гибко моделировать сложные ситуации, например при $P_{(c,min)} < P_{(ш,max)}$ в некоторых моментах времени t полезный сигнал может оказаться ниже уровня шумов и т.д. На рисунке 3 приведена визуализация для среды с периодическим законом $f_{пор}$ для числа каналов $N = 3$ и $N = 15$.




Рис. 3. Визуализация среды для $N = 3$ и $N = 15$ каналов

Порождающий закон является детерминированным и периодическим (для обеспечения генерации любого наперед заданного количества шагов генерации T), с этой точки зрения среда является детерминированной. С другой стороны, выбор конкретных числовых значений на каждом шаге происходит по случайному закону. Рассмотрим формирование вектора состояния среды X^t на шаге t подробно. При инициализации среды для каждого канала выбирается значение из равномерного распределения $X^0 = \{x_i = U[P_{(ш,min)}, P_{(ш,max)}] \forall i \in N\}$ – устанавливается «фон». Далее, определяется индекс свободного канала на шаге $t = 0$ из порождающего закона $n = f_{пор}(0)$, значение $X_n^0 = U[P_{(c,min)}, P_{(c,max)}]$. Далее рассмотрим переход $t_1 \rightarrow t$: для фонового шума вычисляется изменение $X^t = \{x_i^{(t-1)} = x_i^{(t-1)} + U[-V, V] \forall i \in N\}$,

если рассчитанная величина x_i^t превышает $P_{(ш,max)}$ или ниже $P_{(ш,min)}$ то знак выражения меняется ($x_i^{(t-1)} = x_i^{(t-1)} - U[-V, V]$). Таким образом, обеспечивается плавное изменение фоновых шумов. Для свободного канала операция $t_1 \rightarrow t$ аналогичная инициализации.

Технически для того, чтобы обеспечить плавное изменение уровня шума в программном классе генерации хранится вектор состояния фона (без свободного канала) и полный вектор среды раздельно. Однако такие накладные расходы в современных компьютерах пренебрежительно малы.

Предложенная среда позволяет генерировать достаточно сложные последовательности состояний, например, $f_{пор}$ может быть непериодическим или случайным. В настоящей работе был рассмотрен случай периодического порождающего закона, обобщение результатов на более широкий класс порождающих законов является предметом дальнейших работ.

5. Обсуждение результатов. В качестве примера рассмотрим среду, в которой два из $N = 3$ радиоканалов заняты, а один свободен. Положим, что номер свободного канала изменяется по детерминированному закону с периодически повторяющейся последовательностью на 30 временных интервалах. Состояние радиоканала моделируется следующими уровнями: минимальный уровень шумов -120 дБ, максимальный уровень шумов -80 дБ, минимальный уровень полезного сигнала -80 дБ, максимальный уровень полезного сигнала -120 дБ. Амплитуда флуктуации шумов 3 дБ, порождающий закон $f_{(пор)}(t) = mod(t, N)$ – периодическое смещение «вправо» по каналам (по модулю N).

В качестве аппроксимации политики используется следующий набор МСП: с одним скрытым слоем, содержащим 10 нейронов; с двумя скрытыми слоями по 10 нейронов в каждом; с тремя скрытыми слоями по 10 нейронов в каждом.

Для каждого МСП из набора проводилась серия экспериментов по обучению алгоритмами REINFORCE, SARSA и A2C.

В рассмотренном для численного моделирования примере награда агента выбиралась двумя способами – в первом r_{t+1} зависит от состояния в следующий наблюдаемый момент времени, следующим образом:

$$r_{t+1} = \begin{cases} 1, & \text{PdB}_k \leq -80; \\ -\left(\frac{\text{PdB}_k}{50} + 1,6\right), & \text{PdB}_k > -80, \end{cases} \quad (15)$$

где PdV_k – мощность (дБ) в выбранном (предсказанном) канале связи. Во втором – на основе выражения (4).

Для первого способа вознаграждения на основе выражения (14) на рисунке 4 представлен график для метода градиента стратегии (политики) по алгоритму REINFORCE зависимости суммарных (полных) вознаграждений и скользящее среднее по оценкам в 200 контрольных точках. Следует отметить, что максимальное полное вознаграждение составляет 30.

Оптимизация производилась с помощью метода Adam [22] со скоростью обучения 0,001; параметры методов обучения с подкреплением: начальное значение $\varepsilon = 0,5$; конечное значение $\varepsilon = 0,001$; коэффициент дисконтирования $\gamma = 0,7$. На рисунках 4-9 используется сокращение «СВ» – суммарное вознаграждение, цифра после МСП («МСП-1») обозначает количество скрытых слоёв в МСП.

В ходе экспериментов алгоритм REINFORCE демонстрирует способность достигать оптимального (безошибочного) решения в диапазоне от 10000-12000 эпизодов обучения. Однако стоит отметить, что траектория функции вознаграждения характеризуется заметными осцилляциями, особенно на поздних этапах обучения.

На рисунке 5 представлен график для метода градиента полезности (ценности) по алгоритму SARSA зависимости суммарных (полных) вознаграждений и соответствующее скользящее среднее для способа вознаграждения на основе выражения (15).

Алгоритм SARSA, демонстрирует достижение оптимального (безошибочного) решения в районе 8000 эпизодов обучения. Такая относительно высокая скорость сходимости по сравнению REINFORCE, может быть объяснена фундаментальными особенностями SARSA: механизмом самонастройки (bootstrapping), где обновление Q-значений для текущей пары (состояние, действие) зависит от оценки следующего действия, выбранного в соответствии с той же политикой. В частности, правило обновления SARSA подразумевает, что агент оценивает текущее действие на основе предсказанной ценности следующего состояния и действия $Q(s', a')$, где a' выбирается не оптимально (как в Q-Learning), а по текущей, возможно, случайной, политике – например, на ранних этапах ε -жадной стратегии выбора действий. С другой стороны, после снижения ε до практически нулевых значений (около 8000 эпизодов) дополнительная оценка ценности следующего действия приводит к более быстрой сходимости к безошибочному решению и снижению осцилляций графика суммарного вознаграждения (которые обусловлены ненулевым значением ε на протяжении всего обучения).

Аналогичной особенностью обусловлена и повышенная дисперсия функции суммарного вознаграждения, что представлено на рисунке 4: поскольку обновления опираются на коррелированные образцы из траекторий, генерируемых текущей политикой, случайные колебания в выборе действий (включая случайные шаги на начальных итерациях ϵ -жадной стратегии выбора действий) усиливают шум в оценках, приводя к более высокой амплитуде колебаний функции.

На рисунке 6 представлен график для комбинированного метода (актор-критика с преимуществом) по алгоритму A2C зависимости суммарных (полных) вознаграждений и соответствующее скользящее среднее для способа вознаграждения на основе выражения (14).

Алгоритм A2C, демонстрирует достижение оптимального (безошибочного) решения около 8000 эпизодов обучения. Скорость сходимости аналогична SARSA, однако порождена другим механизмом. Она, в первую очередь, обусловлена использованием двух нейронных сетей: МСП-актора для аппроксимации политики $\pi(a|s)$ и МСП-критика для оценки функции ценности $V(s)$, которая прогнозирует ожидаемое дисконтированное суммарное вознаграждение по текущему состоянию. На основе этой оценки производится более эффективная оптимизация по сравнению с алгоритмами, строящих оценки на основе метода Монте-Карло. Однако, как было показано в разделе 4, алгоритм A2C в 2 раза медленнее REINFORCE, следовательно, быстрая сходимость по эпизодам компенсируется высокой вычислительной сложностью каждой эпизода. Этим же объясняется наличие больших (по амплитуде и частоте) осцилляций графика суммарного вознаграждения по сравнению с SARSA, так как МСП-критик даже на поздних эпохах обучения может производить неверные прогнозы функции ценности $V(s)$.

Анализ графиков, представленных на рисунках 3-5, позволяет сделать вывод о том, что алгоритмы SARSA и A2C достигают полного (безошибочного) предсказания свободного канала в модельной среде за одинаковое (в среднем) количество эпизодов. Алгоритм REINFORCE не достигает уровня полного (безошибочного) предсказания. Следует отметить, что графики скользящего среднего получены по серии экспериментов (по 10 для каждого алгоритма и каждой реализации МСП) и отражают общий характер, а не конкретную реализацию, траектория обучения которой достаточно сильно зависит от начальной инициализации весов МСП.




Рис. 4. Полное вознаграждение и скользящее среднее для алгоритма REINFORCE




Рис. 5. Полное вознаграждение и скользящее среднее для алгоритма SARSA




Рис. 6. Полное вознаграждение и скользящее среднее для алгоритма A2C

Для второго способа вознаграждения на основе выражения (4) на рисунках 7-9 представлены графики соответственно для алгоритмов REINFORCE, SARSA и A2C зависимости суммарных (полных) вознаграждений и скользящее среднее.




Рис. 7. Полное вознаграждение и скользящее среднее для алгоритма REINFORCE




Рис. 8. Полное вознаграждение и скользящее среднее для алгоритма SARSA




Рис. 9. Полное вознаграждение и скользящее среднее для алгоритма A2C

Из сравнения графиков на рисунках 7-9 и рисунках 4-6 следует, что выбор конкретной формализации функции вознаграждения (4) или (15) не оказывает существенного влияния на общую сходимость рассмотренных алгоритмов SARSA и A2C, однако функция (15) значительно улучшает сходимость алгоритма REINFORCE.

На рисунке 10 приведены графики среднего времени вычисления одного эпизода в разрезе алгоритмов и реализаций МСП. Следует отметить, что все эксперименты проводились в одинаковых условиях (зафиксирована программная реализация библиотеки вычисления градиентов, аппаратная составляющая и программная реализация моделируемой среды).

На рисунке 10 высота столбца соответствует среднему времени вычисления одного эпизода обучения; черные линии – стандартное отклонение 3σ (99,7% эпизодов). Из рисунка 9 следует, что оценки приведённые в разделе 4 подтверждаются вычислительным экспериментом: алгоритм REINFORCE является наиболее быстрым, SARSA медленнее (в среднем) в 1,67 раз, A2C медленнее относительно REINFORCE (в среднем) в 2,10 раз.

Другим важным выводом является тот факт, что формализации функции вознаграждения (4) или (15) не оказывает значительного влияния на сходимость алгоритмов SARSA и A2C, однако формализация (15) является более универсальной и повышает эффективность алгоритма REINFORCE. Таким образом, формализация (15) может быть рекомендована как отправная точка в решении практических задач выбора свободного канала.




Рис. 10. Зависимость среднего суммарного вознаграждения от времени

На рисунке 11 приведён сводный график для обучения агентов алгоритмом REINFORCE для $N \in [3, 100]$. Все внутренние параметры среды и агентов фиксированы (численные значения совпадают со значениями, приведёнными в начале раздела 5 для $N = 3$). Для

каждого N выбирается число временных интервалов как $T = N \times 10$, таким образом, для детально рассмотренного случая $N = 3: T = 30$, для $N = 100: T = 1000$ и т.д.




Рис. 11. Сводный график обучения агентов для $N \in [3,100]$

Следует отметить, что время растёт приблизительно как $O(N)$, однако, подобная тенденция должна быть исследована в областях больших ($N > 10^3$), так как вероятно, увеличение сложности изменит своё поведение. Подобное исследование целесообразно при практической заинтересованности в агентах, работающих с тысячами каналов. С другой стороны, для рассматриваемой модели среды обеспечивается устойчивое обучение агента до безошибочного решения в рассмотренном диапазоне каналов. Таким образом, можно сделать вывод о достаточно эффективном обобщении решения задачи на большее число каналов, при учёте сохранения параметров модели среды.

6. Заключение. Таким образом, для решения задачи формирования прогноза рабочих частот и полос частотной области предложен метод для системы когнитивного радио, базирующийся на глубоком обучении с подкреплением. Предложенный конструктивный метод позволяет оценить рабочие частоты и соответствующую ширину полосы частот при заданных условиях и ограничениях. Учитывая теоретические оценки вычислительной сложности, полученные в разделе 4 и анализируя отношения времени сходимости алгоритмов до безошибочного решения можно сделать вывод о согласованности теоретических и экспериментальных

результатов. Целью дальнейших исследований целесообразно определить анализ оценки эффективности включения дополнительной априорной информации в матрицу состояний среды и выбор функций вознаграждения для решения конкретных научно-прикладных задач когнитивного радио.

Литература

1. Тонг В., Чжу П. Сети 6G. Путь от 5G к 6G глазами разработчиков. От подключенных людей и вещей к подключенному интеллекту // М.: ДМК Пресс. 2022. 624 с.
2. Fette В.-А. *Cognitive Radio Technology* // Elsevier. 2006. 622 p.
3. Комашинский В.И., Смирнов Д.А. Нейронные сети и их применение в системах управления и связи // М.: Горячая линия–Телеком. 2003. 93 с.
4. Голубинский А.Н., Толстых А.А. Гибридный метод обучения сверточных нейронных сетей // Информатика и автоматизация. 2021. Т. 20. № 2. С. 463–490. DOI: 10.15622/ia.2021.20.2.8.
5. Wu C., Chowdhury K.-R., Di Felice M., Meleis M. Spectrum Management of Cognitive Radio Using Multi-Agent Reinforcement Learning // 9th International Conference on Autonomous Agents and Multiagent Systems. 2010. vol. 1–3. pp. 1705–1712. DOI: 10.1145/1838194.1838199.
6. Kiran U., Kumar P.-D., Reddy R.-K., Ranjith M. Efficient Exploration for Reinforcement Learning Based Distributed Spectrum Sharing in Cognitive Radio System // International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering. 2013. vol. 2. no. 11. pp. 5596–5604.
7. Yau K.-L.-A., Poh G.-S., Chien S.-F., Al-Rawi H.-A.-A. Application of Reinforcement Learning in Cognitive Radio Networks: Models and Algorithms // The Scientific World Journal. 2014. vol. 1. pp. 1–23. DOI: 10.1155/2014/209810.
8. Abolarinwa J.-A., Latiff A.-N.-M. Channel Decision in Cognitive Radio Enabled Sensor Networks A Reinforcement Learning Approach // International Journal of Engineering and Technology (IJET). 2015. vol. 7. no. 4. pp. 1394–1404.
9. Raj V., Dias I., Tholeti T., Kalyani S. Spectrum Access In Cognitive Radio Using A Two Stage Reinforcement Learning Approach // IEEE. 2018. vol. 12. no. 1. pp. 20–34. DOI: 10.1109/JSTSP.2018.2798920.
10. Tubachi S., Venkatesan M., Kulkarni A.-V., et al. Predictive learning model for Cognitive Radio using Reinforcement Learning // IEEE International Conference on Power, Control, Signals and Instrumentation Engineering (ICPCSI). 2017. pp. 564–567. DOI: 10.1109/ICPCSI.2017.8391775.
11. Jang S.-J., Han C.-H., Lee K.-E., et al. Reinforcement learning-based dynamic band and channel selection in cognitive radio ad-hoc networks // J Wireless Com Network. 2019. vol. 2019. pp. 1–25. DOI: 10.1186/s13638-019-1433-1.
12. Singhal C., Thanikaiselvan V. Cross Layering Using Reinforcement Learning In Cognitive Radio-Based Industrial Internet Of Ad-Hoc // International Journal of Computer Networks & Communications (IJCNC). 2022. vol. 14. no. 4. pp. 1–17. DOI: 10.5121/ijcnc.2022.14401.
13. Talekar S., Banait S., Patil M. Improved Q-Reinforcement Learning Based Optimal Channel Selection In Cognitive Radio Networks // International Journal of Computer Networks & Communications (IJCNC). 2023. vol. 15. no. 3. pp. 1–14. DOI: 10.5121/ijcnc.2023.15301.
14. Rosen D., Rochez I., McIrvin C., Lee J., D’Alessandro K., Wiecek M., et al. RFRL Gym_A Reinforcement Learning Testbed for Cognitive Radio Applications //

- International Conference on Machine Learning and Applications (ICMLA). 2023. pp. 279–286. DOI: 10.1109/ICMLA58977.2023.00046.
15. Отчет (Сектора связи Международного союза электросвязи) МСЭ-R SM.2152 (09/2009) «Определения системы радиосвязи с программируемыми параметрами (SDR) и системы когнитивного радио (CRS)».
 16. Chitnavis S., Kwasinski A. Cross Layer Routing in Cognitive Radio Network Using Deep Reinforcement Learning // IEEE Wireless Communications and Networking Conference (WCNC). 2019. pp. 1–13. DOI: 10.1109/WCNC.2019.8885918.
 17. Obite F., Usman A.-D., Okafor E. An overview of deep reinforcement learning for spectrum sensing in cognitive radio networks // Digital Signal Processing. 2021. vol. 113. pp. 1–18. DOI: 10.1016/j.dsp.2021.103014.
 18. Tondwalkar A., Kwasinski A. Deep Reinforcement Learning for Distributed and Uncoordinated Cognitive Radios Resource Allocation. 2022. pp. 1–13. arXiv: 2205.13944v1.
 19. Саттон Р. С., Барто Э. Дж. Обучение с подкреплением // М.: ДМК Пресс. 2020. 552 с.
 20. Грессер Л., Кенг В.Л. Глубокое обучение с подкреплением: теория и практика на языке Python // СПб.: Питер. 2022. 416 с.
 21. Wang H., Yu Y. Exploring Multi-Action Relationship in Reinforcement Learning // Springer, Cham. 2016. pp. 1–13. DOI: 10.1007/978-3-319-42911-3_48.
 22. Kingma D., Ba J. Adam: A Method for Stochastic Optimization. // CoRR. 2014. T. abs/1412.6980.

Толстых Андрей Андреевич — канд. техн. наук, инженер-программист, ООО «РТК». Область научных интересов: искусственные нейронные сети, машинное обучение, обучение с подкреплением. Число научных публикаций — 65. tolstykh.aa@yandex.ru; проспект Высоковольтный, 1, 127566, Москва, Россия.

Голубинский Андрей Николаевич — д-р техн. наук, доцент, начальник отдела, Российский научный фонд (РНФ). Область научных интересов: машинное обучение, нейросетевое моделирование, автоматизированные системы управления с элементами искусственного интеллекта, обработка речевых сигналов. Число научных публикаций — 250. annikgol@mail.ru; улица Солянка, 14, 109240, Москва, Россия; p.т.: +7 (910) 346-6537.

A. TOLSTYKH, A. GOLUBINSKIY
**DATA MINING BASED ON DEEP REINFORCEMENT LEARNING
FOR PREDICTION OF OPERATING FREQUENCIES AND BANDS
IN A COGNITIVE RADIO SYSTEM**

Tolstykh A., Golubinskiy A. Data Mining Based on Deep Reinforcement Learning for Prediction of Operating Frequencies and Bands in a Cognitive Radio System.

Abstract. The paper proposes a method for solving the problem of choosing a communication channel in cognitive radio based on information about the current state of all available communication channels using the mathematical apparatus of reinforcement learning. The method consists in formalizing the problem of choosing communication channels in terms of "environment-agent" and training agents using the REINFORCE, SARSA and A2C algorithms. The calculation of memory costs for solving the problem of selecting communication channels using classical methods is given. The memory estimate is 4×2^{2n} bytes for a random state of channels (busy/free) and $4 \times n^2$ bytes for one free channel at each step when solving the problem using the tabular Q-learning algorithm. Two different formalizations of the reward for the agent within the framework of the problem being solved using reinforcement learning are presented – for the trivial case (binary availability/unavailability of the frequency channel) and for a more complex case considering the power (in dB) in the selected communication channel. The restriction on the first formalization is that at each iteration there should be only one free communication channel out of all available channels. The second proposed formalization of the reward function does not impose such restrictions and is more universal. Computational experiments are presented for the corresponding formalizations of the reward function. Agents are trained using the SARSA and A2C algorithms. On average, error-free solutions are achieved after 8,000 training episodes for the corresponding formalizations of training in a model problem for various agent implementations. The REINFORCE algorithm does not provide error-free solutions, but reward formulation takes into account the improved training efficiency of the REINFORCE algorithm. Theoretical estimates of the computational complexity of the considered methods are provided, which are consistent with the computational experiments.

Keywords: cognitive radio, reinforcement learning, deep learning, artificial neural network, multilayer perceptron, reward function, software-defined radio, synthetic data, augmentation, artificial intelligence.

References

1. Tong W., Zhu P. Seti 6G. Put' ot 5G k 6G glazami razrabotchikov. Ot podklyuchennykh lyudey i veshchey k podklyuchennomu intellektu [6G networks. The path from 5G to 6G through the eyes of developers. From connected people and things to connected intelligence]. Moscow: DMK Press, 2022. 624 p. (In Russ.).
2. Fette B.-A. Cognitive Radio Technology. Elsevier. 2006. 622 p.
3. Komashinskiy V., Smirnov D. Neyronnye seti i ikh primeneniye v sistemakh upravleniya i svyazi [Neural networks and their application in control and communication systems]. Moscow: Hotline–Telecom, 2003. 93 p. (In Russ.).
4. Golubinskiy A., Tolstykh A. [Hybrid method for training convolutional neural networks]. Informatika i avtomatizatsiya – Informatics and Automation. 2021. vol. 20. no. 2. pp. 463–490. DOI: 10.15622/ia.2021.20.2.8. (In Russ.).
5. Wu C., Chowdhury K.-R., Di Felice M., Meleis M. Spectrum Management of Cognitive Radio Using Multi-Agent Reinforcement Learning. 9th International Conference

- on Autonomous Agents and Multiagent Systems. 2010. vol. 1–3. pp. 1705–1712. DOI: 10.1145/1838194.1838199.
6. Kiran U., Kumar P.-D., Reddy R.-K., Ranjith M. Efficient Exploration for Reinforcement Learning Based Distributed Spectrum Sharing in Cognitive Radio System. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*. 2013. vol. 2. no. 11. pp. 5596–5604.
 7. Yau K.-L.-A., Poh G.-S., Chien S.-F., Al-Rawi H.-A.-A. Application of Reinforcement Learning in Cognitive Radio Networks: Models and Algorithms. *The Scientific World Journal*. 2014. vol. 1. pp. 1–23. DOI: 10.1155/2014/209810.
 8. Abolarinwa J.-A., Latiff A.-N.-M. Channel Decision in Cognitive Radio Enabled Sensor Networks A Reinforcement Learning Approach. *International Journal of Engineering and Technology (IJET)*. 2015. vol. 7. no. 4. pp. 1394–1404.
 9. Raj V., Dias I., Tholeti T., Kalyani S. Spectrum Access In Cognitive Radio Using A Two Stage Reinforcement Learning Approach. *IEEE*. 2018. vol. 12. no. 1. pp. 20–34. DOI: 10.1109/JSTSP.2018.2798920.
 10. Tubachi S., Venkatesan M., Kulkarni A.-V., et al. Predictive learning model for Cognitive Radio using Reinforcement Learning. *IEEE International Conference on Power, Control, Signals and Instrumentation Engineering (ICPCSI)*. 2017. pp. 564–567. DOI: 10.1109/ICPCSI.2017.8391775.
 11. Jang S.-J., Han C.-H., Lee K.-E., et al. Reinforcement learning-based dynamic band and channel selection in cognitive radio ad-hoc networks. *J Wireless Com Network*. 2019. vol. 2019. pp. 1–25. DOI: 10.1186/s13638-019-1433-1.
 12. Singhal C., Thanikaiselvan V. Cross Layering Using Reinforcement Learning In Cognitive Radio-Based Industrial Internet Of Ad-Hoc. *International Journal of Computer Networks & Communications (IJCNC)*. 2022. vol. 14. no. 4. pp. 1–17. DOI: 10.5121/ijcnc.2022.14401.
 13. Talekar S., Banait S., Patil M. Improved Q-Reinforcement Learning Based Optimal Channel Selection In Cognitive Radio Networks. *International Journal of Computer Networks & Communications (IJCNC)*. 2023. vol. 15. no. 3. pp. 1–14. DOI: 10.5121/ijcnc.2023.15301.
 14. Rosen D., Rochez I., McIrvine C., Lee J., D'Alessandro K., Wiecek M., et al. RFRL Gym_A Reinforcement Learning Testbed for Cognitive Radio Applications. *International Conference on Machine Learning and Applications (ICMLA)*. 2023. pp. 279–286. DOI: 10.1109/ICMLA58977.2023.00046.
 15. Report (International Telecommunication Union Telecommunication Sectors) ITU-R SM.2152 (09/2009) [Definitions of Software Defined Radio (SDR) and Cognitive Radio System (CRS)]. (In Russ.).
 16. Chitnavis S., Kwasinski A. Cross Layer Routing in Cognitive Radio Network Using Deep Reinforcement Learning. *IEEE Wireless Communications and Networking Conference (WCNC)*. 2019. pp. 1–13. DOI: 10.1109/WCNC.2019.8885918.
 17. Obite F., Usman A.-D., Okafor E. An overview of deep reinforcement learning for spectrum sensing in cognitive radio networks. *Digital Signal Processing*. 2021. vol. 113. pp. 1–18. DOI: 10.1016/j.dsp.2021.103014.
 18. Tondwalkar A., Kwasinski A. Deep Reinforcement Learning for Distributed and Uncoordinated Cognitive Radios Resource Allocation. 2022. pp. 1–13. arXiv: 2205.13944v1.
 19. Sutton R., Barto E. *Obuchenie s podkrepleniem [Reinforcement learning]*. Moscow: DMK Press, 2020. 552 p. (In Russ.).
 20. Gresser L., Keng V. *Glubokoye obuchenie s podkrepleniem: teoriya i praktika na yazyke Python [Deep Reinforcement Learning: Theory and Practice in Python]*. SPB: Peter. 2022. 416 p.

21. Wang H., Yu Y. Exploring Multi-Action Relationship in Reinforcement Learning. Springer, Cham. 2016. pp. 1–13. DOI: 10.1007/978-3-319-42911-3_48.
22. Kingma D., Ba J. Adam: A Method for Stochastic Optimization. CoRR. 2014. T. abs/1412.6980.

Tolstykh Andrey — Ph.D., Software engineer, ООО “РТК”. Research interests: artificial neural networks, machine learning, reinforcement learning. The number of publications — 65. tolstykh.aa@yandex.ru; 1, Vysokovoltny Ave., 127566, Moscow, Russia.

Golubinskiy Andrey — Ph.D., Dr.Sci., Associate Professor, Head of Department, Russian Science Foundation (RSF). Research interests: machine learning, neural network modeling, automated control systems with artificial intelligence elements, speech signal processing. The number of publications — 250. annikgol@mail.ru; 14, Solyanka St., 109240, Moscow, Russia; office phone: +7 (910) 346-6537.

А.С. МИРОНОВ, А.А. САЕНКО, Е.С. ФОМИНА
**РАЗРАБОТКА АРХИТЕКТУРЫ ЦИФРОВОГО ДВОЙНИКА
ЭКОСИСТЕМЫ ВОДНОГО ОБЪЕКТА ДЛЯ СОХРАНЕНИЯ
ЭКОЛОГИЧЕСКОЙ УСТОЙЧИВОСТИ**

Мионов А.С., Саенко А.А., Фомина Е.С. Разработка архитектуры цифрового двойника экосистемы водного объекта для сохранения экологической устойчивости.

Аннотация. Целью работы является разработка архитектуры цифрового двойника экосистемы водного объекта для обеспечения экологической устойчивости, включая мониторинг, прогнозирование и управление водными ресурсами в условиях антропогенного воздействия и климатических изменений. В работе предложена модульная архитектура цифрового двойника, включающая модуль сбора и слияния мультимодальных данных, цифровые модели экосистемы, экспертную систему, модуль регулирования нормативно-правовой базы, геоинформационную систему, модуль графического представления данных. Архитектура основана на интеграции данных с сенсоров, спутников, метеостанций и систем дистанционного зондирования, с применением моделей машинного обучения и больших языковых моделей для анализа нормативной документации. Разработана архитектура цифрового двойника водного объекта, позволяющая в реальном времени отслеживать параметры экосистемы, оценивать соответствие нормативам, формировать отчёты и рекомендации для субъектов природопользования и органов управления. Проведено тестирование эффективности различных моделей обработки правовых текстов, выявлены оптимальные подходы к их семантическому анализу. Обоснована возможность интеграции цифрового двойника в систему государственного регулирования природных ресурсов. Предложенная авторами архитектура цифрового двойника представляет собой комплексный инструмент устойчивого управления водными ресурсами, обеспечивающий прогнозирование состояния водных объектов, своевременное выявление рисков и формирование научно обоснованных управленческих решений, способствуя снижению экологических угроз и сохранению водных ресурсов.

Ключевые слова: цифровой двойник, водные ресурсы, экосистема водного объекта, управление природными ресурсами, экспертная система.

1. Введение. Природные экосистемы и окружающая среда во всем мире испытывают существенное давление из-за комплекса глобальных и локальных факторов: изменения климата, рост населения, урбанизация, загрязнение и нерациональное использование природных ресурсов [1]. Водные объекты играют фундаментальную роль в поддержании климатического баланса, гидрологического цикла и здоровья человека, однако они подвержены быстрой деградации под воздействием антропогенных факторов.

Примеры из разных регионов мира иллюстрируют масштаб и разнообразие вызовов, с которыми сталкиваются водные объекты. Так, в Китае в северо-западном оазисе Миньцин [2] отмечается критическое снижение уровня грунтовых вод и деградация экосистем, что негативно сказывается на социально-экологических системах региона.

Реализованные меры по комплексному управлению бассейном реки Шиян привели к стабилизации уровня грунтовых вод и частичному восстановлению экологии, однако сохранение экосистем требует продолжительной адаптивной стратегии с учётом внутренних региональных особенностей. Аналогичные проблемы наблюдаются в озере Илун [3], которое за последние десятилетия испытало значительное сокращение площади, вызванное мелиоративными работами и изменениями в землепользовании. Бассейн реки Хуанхэ сталкивается с серьёзными экологическими проблемами, включая дефицит воды, эрозию почв, снижение биоразнообразия и деградацию водных и лесных экосистем, что усугубляется антропогенными и климатическими воздействиями. Подобные вызовы так же фиксируются и в бассейне реки Хунцзян, где наблюдается ухудшение качества воды, утрата биоразнообразия и усиление эрозии почв, что усугубляется промышленным и бытовым загрязнением, а также деградацией лесных сообществ. Комплексные природоохранные проекты, включающие улучшение очистки сточных вод и увеличение лесных площадей, демонстрируют положительный эффект, приводящий к восстановлению экосистем.

Особенно важна значимость гидрологического режима как ключевого фактора устойчивости экосистем водных объектов. В бассейне реки Амур [4], на территории России и Китая, наблюдается сокращение водных поверхностей и водной растительности вследствие климатических изменений и антропогенного воздействия. В озере Цаохай провинции Гуйчжоу резкие колебания уровня воды, а не эвтрофикация, вызвали массовое вымирание погружённой растительности, что подчёркивает необходимость регулирования гидрологического режима [5]. Озеро Тайху в провинции Цзянсу стало объектом масштабной вспышки цветения воды, что привело к серьёзным экологическим угрозам и заставило власти принять системные меры по улучшению качества воды и восстановлению природных экосистем [6]. Один из наиболее показательных примеров – озеро Байяндянь, крупнейшее мелководное озеро севера Китая [7]. После создания в 2017 году нового района Сюньань были инициированы масштабные мероприятия по восстановлению водной среды озера. Только в 2023 году удалось наблюдаться резкое увеличение биомассы погружённых макрофитов в 4,2 раза по сравнению с 2018 годом, что свидетельствует о переходе от доминирования водорослей к макрофитному режиму. Построение пищевой сети с использованием модели Ecorpath с Ecosim подтвердило перестройку трофических связей и увеличение устойчивости системы.

Основными факторами восстановления стали снижение нагрузки питательными веществами, гидрологическая регуляция и биологическое управление.

В европейских странах также зафиксированы множественные случаи деградации и восстановления водных экосистем. В бассейне реки Фийос отмечается высокая вероятность катастрофических наводнений вследствие изменения климата и экстремальных осадков, что требует развития систем раннего предупреждения, инженерной инфраструктуры и просветительской работы для населения [8]. В Польше озёра подверглись значительной деградации из-за поступления неочищенных сточных вод, нарушивших буферные свойства и химический состав [9]. Восстановление с применением методов последовательного коагулирования и связывания фосфора способствовало снижению эвтрофикации и улучшению качества воды, что подчеркивает важность комплексных технологических подходов и долгосрочного мониторинга для устойчивого управления водными экосистемами.

Особенно интересен случай естественного заболачивания осушенных водно-болотных угодий в районе Ольштынского озера в Польше [10], где в XIX веке проводились масштабные дренажные работы, исчезло более 140 озёр общей площадью около 3000 га. Однако восстановление ранее осушенных озёр остаётся недостаточно изученным.

Современные наблюдения фиксируют постепенное восстановление части этих водоёмов, в основном за счёт естественных процессов. Тем не менее, качество воды и трофический статус остаются нестабильными: повышенное содержание фосфора фиксируется в восстановленных озёрах и болотах, а отсутствие системных программ восстановления делает дальнейший прогресс зависимым от климатических условий.

Глобально эвтрофикация остаётся одной из главных проблем для пресных вод, вызывая цветение водорослей, дефицит кислорода, снижение биоразнообразия и угрозы для здоровья [11]. Эвтрофицированные осадки становятся источниками парниковых газов, усугубляя климатические изменения. Современные меры по восстановлению водоёмов включают снижение внешнего поступления питательных веществ и внутренние вмешательства – удаление биомассы и донных отложений с использованием их в сельском хозяйстве и энергетике, что способствует переходу к замкнутой экономике. Примером успешного технологического вмешательства является использование модифицированного бентонита с лантаном

(LMB) в озере Берензее (Германия), позволившего стабилизировать фосфор в донных отложениях и снизить биопродуктивность, предотвращая массовое цветение цианобактерий [12].

Похожий случай наблюдался в озере Фельдбергер Хаусзе (Северо-Восточная Германия), где длительный процесс восстановления после прекращения сброса сточных вод в 1980-х завершился переходом к мезотрофному состоянию лишь к 2015 году, чему способствовали как природные процессы, так и биоманипуляции, включая осаждение фосфора и регулирование зоопланктона [13].

Таким образом, международный опыт показывает, что сохранение и восстановление водных экосистем требуют комплексных, регионально адаптированных стратегий, сочетающих научный мониторинг, технологические инновации, эффективное управление ресурсами и вовлечение местного населения. Важна интеграция природных, социально-экономических и управленческих факторов для обеспечения экологической устойчивости водных ресурсов и повышения качества жизни населения.

В этих условиях авторы считают, что цифровые двойники водных экосистем могут стать эффективным инструментом сохранения и управления водными ресурсами.

В настоящее время применение концепции цифровых двойников в рамках природных экологических и экосистем набирает популярность в мире [14 – 16]. Например, предлагается создание инфраструктуры пространственных данных для цифрового двойника лесной экосистемы. Цифровой двойник EсоPro предназначен для прогнозирования состояния экосистем под воздействием климатических и антропогенных факторов, предоставляя доступ к модели «Earth System Model».

Цифровой двойник объекта (ЦД) – система, состоящая из цифровой модели объекта и двусторонних информационных связей с объектом (при наличии изделия) и (или) его составными частями.

Цифровые двойники функционируют в режиме реального времени параллельно с их физическими оригиналами, обеспечивая мониторинг состояния, анализ изменений и прогнозирование последствий различных сценариев. Это обеспечивает возможность оптимизации режимов эксплуатации водных ресурсов с учетом экологических ограничений регионального, федерального и мирового масштабов, что особенно важно в условиях изменения климата и роста антропогенной нагрузки. В отличие от традиционного цифрового моделирования, концепция цифровых двойников предполагает наличие динамической связи с объектом, постоянную актуализацию данных

и возможность использования результатов анализа для управления. Преимущества цифровых моделей заключаются в том, что они позволяют делать предсказания и сравнивать их с реальными данными. Однако такие модели учитывают лишь часть факторов, а сложность экспоненциально возрастает с увеличением числа переменных. Кроме того, недостатками являются отсутствие связи с физическим объектом в реальном времени и невозможность управления им. На рисунке 1 представлена обобщённая схема функционирования цифрового двойника.




Рис. 1. Обобщённая схема функционирования цифрового двойника

Цифровые двойники можно классифицировать на три категории: цифровые двойники-прототипы (Digital Twin Prototype, DTP), экземпляры (Digital Twin Instance, DTI) и агрегированные двойники (Digital Twin Aggregate, DTA) [17].

DTP – это прототип некоторого физического объекта, включающий информационную модель, содержащую данные, необходимые для проектирования и последующего создания физического объекта, включая его конструктивные характеристики, технологические параметры и материалы. Такие модели широко используются в высокотехнологичных отраслях – от машиностроения до авиационной промышленности.

DTI – это двойник-экземпляр, который применяется для моделирования уже существующего физического объекта, к которому он привязан на протяжении всего жизненного цикла. Этот тип включает цифровое представление геометрии, параметров эксплуатации, истории обслуживания, а также результаты мониторинга и прогнозируемые изменения состояния.

DTA – это двойники-агрегаторы, в свою очередь, представляет собой интеграционную платформу, объединяющую множество DTI в рамках единой распределённой информационно-вычислительной системы, что открывает возможности для комплексного анализа

и управления группой объектов для последующего воздействия на их состояние.

В работе предлагается описание модульной архитектуры цифрового двойника водного объекта для обеспечения экологической устойчивости, включая мониторинг, прогнозирование и управление водными ресурсами в условиях антропогенного воздействия и климатических изменений.

2. Общее описание модульной архитектуры цифрового двойника водного объекта. Авторами предлагается следующая модульная архитектура цифрового двойника водного объекта, которая представлена замкнутой рекурсивной системой и включает следующие основные модули (рисунок 2): реальный водный объект (экосистема), сбор и слияния мультимодальных данных, цифровые модели экосистемы, экспертную систему, регулирование нормативно-правовой базы, геоинформационную систему (ГИС), графическое представление данных. Связь между модулями позволяет организовать обмен данными, обеспечивая оптимизацию управления природным объектом.



Рис. 2. Модульная архитектура цифрового двойника водного объекта

Следует отметить, что в настоящее время существуют информационные системы такие как GRDC, HydroSHEDS, USGS, «Метео ДВ», «Волга», «Гидрология», «Речные бассейны Европейской России», применяемые в сфере мониторинга и управления водными ресурсами [18 – 26]. Такие системы характеризуются отсутствием комплексной интеграции мультимодальных источников данных, недостаточной связанностью с прогнозными моделями экосистем, ограниченной реализацией экспертных модулей и слабой поддержкой механизмов регулирования состояния водных объектов в реальном времени. В результате указанные выше информационные системы

выполняют роль **неполных** цифровых двойников, позволяя лишь частично моделировать процессы в водных экосистемах. На рисунке 3 приведён модульный состав широко используемых неполных цифровых двойников.

| Компоненты | 1 | 2 | 3 | 4 | 5 | 6 | 7 |
|---|---|---|---|---|---|---|---|
| Водный объект (данные наблюдений) | ± | + | + | + | ± | ± | ± |
| Сбор и слияние мультимодальных данных | | ± | | ± | ± | ± | |
| Модели экосистемы | ± | ± | ± | ± | | | |
| ГИС (геоинформационная составляющая) | + | + | + | + | + | + | + |
| Графическое представление данных | ± | + | + | + | ± | ± | + |
| Экспертная система | | | | | | | |
| Регулирование нормативно-правовой базы (управляющие воздействия) | | | | | | | |

Рис. 3. Модульный состав существующих информационных систем (неполных цифровых двойников): 1. GRDC; 2. HydroSHEDS; 3. USGS; 4. ГИС «Метео ДВ»; 5. ГИС «Волга»; 6. ГИС «Гидрология»; 7. Геопортал «Речные бассейны Европейской России»

Предлагаемая архитектура цифрового двойника в рамках исследования предполагает обязательное наличие контура управления объектом исследования – водным объектом (экосистемой водного объекта). Контур управления представляется в общем виде следующей информационной последовательностью: через модуль сбора и слияния мультимодальных данных, информация, переданная в геоинформационную систему, поступает в модуль цифровой модели экосистемы водного объекта и из нее в модуль экспертной системы к модулю регулирования нормативно-правовой базы и через него, за счет принимаемых решений обратнo к водному объекту.

3. Модуль «Сбор и слияние мультимодальных данных». Важным компонентом предлагаемой системы является модуль сбора и слияния мультимодальных данных (рисунок 4), который интегрирует информацию из разнородных источников, включая спутники, наземные сенсоры, гидрологические и метеорологические станции, а также данные, поступающие из модуля экспертной системы нормативно-правовой базы функционирования природного объекта. Основные функциональные компоненты модуля представлены в таблице 1.

Ключевым компонентом эффективного функционирования цифрового двойника является обеспечение полноты, достоверности и актуальности данных. Для комплексного мониторинга водных ресурсов необходимо систематическое получение и интеграция информации о водном уровне, качестве воды, гидрологических характеристиках, метеорологических и климатических параметрах, а также о водопользовании. Кроме того, требуется учет данных, регулирующих состояние водных объектов в соответствии с установленными нормативами. Источниками информации могут быть: спутниковые системы дистанционного зондирования Земли; наземные гидрологические и метеостанции; локальные комплексные системы мониторинга; данные полевых выездов (аэрофотосъемка и данные собранные надводным аппаратом); данные из экспертной системы, включая нормативно-правовую базу функционирования природного объекта.

Таблица 1. Основные функциональные компоненты модуля «Сбор и слияние мультимодальных данных»

| Класс / Метод | Название процесса | Входные данные | Выходные данные | Исполнитель |
|-------------------------|--|---|--|------------------|
| DataCollector.collect() | Сбор данных с датчиков, спутников, нормативных источников | Потоки данных | Сырые разнородные данные, временные метки | Цифровая система |
| DataMerger.merge() | Слияние мультимодальных данных | Сырые разнородные данные, временные метки | Единая база геопространственных данных (ГИС-хранилище) | Цифровая система |
| DataValidator.clean() | Автоматическая верификация и очистка, обеспечение совместимости с международными стандартами | Единая база геопространственных данных | Очищенные структурированные данные | Цифровая система |
| DataValidator.update() | Сохранение данных в базу данных | Очищенные структурированные данные | Обновленная единая база геопространственных данных (ГИС-хранилище) | Цифровая система |




Рис. 4. Структура модуля «Сбор и слияние мультимодальных данных»

Частота обновления данных варьируется в зависимости от типа источника. Наземные станции могут передавать данные каждые несколько минут или часов, что позволяет поддерживать непрерывный мониторинг. Спутниковые данные обновляются в зависимости от периодичности пролета спутника над регионом, что обычно составляет от нескольких дней до недели. Полевые данные собираются с периодичностью, зависящей от специфики задач мониторинга – это могут быть как ежемесячные, так и сезонные замеры.

4. Модуль «Цифровые модели экосистемы». Цифровая модель объекта – система математических и компьютерных моделей, а также электронных документов объекта, описывающая структуру, функциональность и поведение вновь разрабатываемого или эксплуатируемого объекта на различных стадиях жизненного цикла, для которой на основании результатов цифровых и (или) иных испытаний выполнена оценка соответствия предъявляемым к объекту требованиям. Основу цифровой модели в рамках цифрового двойника водного объекта составляют математические, физические и вычислительные методы, которые позволяют воспроизводить динамику процессов, протекающих в природных экосистемах. Основные функциональные компоненты модуля представлены в таблице 2.

В общем случае, согласно [27], существующие математические методы моделирования водных экосистем в зависимости от объекта или процесса исследования подразделяются на гидрофизические, биологические и динамические модели (представляют собой интеграцию биологических и гидрофизических моделей).

Таблица 2. Основные функциональные компоненты модуля «Цифровые модели экосистемы»

| Класс / Метод | Название процесса | Входные данные | Выходные данные | Исполнитель |
|---|---|---|---|------------------|
| EcoModel.train_model() | Построение / обучение цифровой модели машинного обучения | Обновленная единая база геопространственных данных | Настроенная цифровая модель машинного обучения | Цифровая система |
| EcoModel.simulate() | Прогноз состояния водного объекта | Настроенная модель машинного обучения + новые данные | Прогнозные показатели состояния экосистемы | Цифровая система |
| EcoModel.validate() | Верификация / калибровка | Прогноз + реальные данные | Откалиброванная модель | Цифровая система |
| EcoModel.PhysicSimulator.simulate_scenarios() | Сценарное моделирование биологических и гидрофизических моделей | Климатические, гидрологические, биологические данные из базы геопространственных данных | Прогноз динамики экосистемы, сценарии изменений | Цифровая система |
| EcoModel.Data.update() | Сохранение данных в базу данных | Результаты EcoModel.simulate() и EcoModel.Ecosystem Simulator.simulate_scenarios() | Обновленная единая база геопространственных данных | Цифровая система |
| EcoModel.getData() | Получение данных цифровой модели и физического моделирования | Результаты EcoModel.simulate() и EcoModel.Ecosystem Simulator.simulate_scenarios() | Сводные данные из EcoModel.simulate() и EcoModel.Ecosystem Simulator.simulate_scenarios() | Цифровая система |

Модели машинного обучения используются для оперативного прогноза интегральных показателей состояния водного объекта на основе обновляемой единой базы геопространственных данных. В частности, они применяются для кратко- и среднесрочного прогноза параметров качества воды и общего состояния экосистемы при поступлении новых данных, а также для последующей верификации и калибровки.

Физические и биофизические модели применяются в рамках сценарного моделирования и ориентированы на анализ причинно-следственных процессов и долгосрочных изменений экосистемы. Они используются для оценки динамики уровня воды, гидрологических и гидрофизических характеристик, а также биологических процессов, включая сценарии эвтрофикации и реакции экосистемы на климатические и антропогенные воздействия.

В зависимости от типа задач и доступных данных применяются различные методологии моделирования [28]: физическое моделирование, моделирование с помощью модели, управляемой данными, моделирование с помощью модели машинного обучения.

Физические модели основываются на законах природы и описывают процессы с использованием уравнений механики, гидродинамики, термодинамики и других разделов физики. Они особенно эффективны при наличии глубокого понимания процессов, происходящих в системе.

Модели, управляемые данными, строятся на основе статистического анализа и позволяют выявлять зависимости между параметрами объекта, основываясь на эмпирических данных. Такие модели часто используются для анализа сложных систем с большим количеством взаимосвязанных факторов.

Модели машинного обучения применяются для решения задач прогнозирования и классификации. Эти модели обучаются на исторических данных и используют алгоритмы глубокого обучения или другие методы искусственного интеллекта для моделирования поведения и определения ключевых закономерностей.

Данные, поступающие от реальных объектов, играют ключевую роль в построении и использовании цифровой модели. Они используются для: обучения моделей, что позволяет создавать точные представления природных объектов и их поведения; калибровки, при которой параметры модели подстраиваются для соответствия реальным условиям; верификации и валидации, что предполагает сравнение прогностических результатов модели с эмпирическими данными для повышения точности.

На сегодняшний день разработано множество систем для моделирования водных экосистем, которые активно применяются в научной и практической деятельности: AQUATOX, SWAT (Soil and Water Assessment Tool), CE-QUAL-W2, Ecopath, Loop Analysis и STELLA [29, 30].

5. Модуль «Экспертная система». Модуль «Экспертная система» (рисунок 5) представляет собой кибернетическую систему

поддержки принятия решений, функционирующую на основе формализованных знаний о динамике водного объекта и нормативно-правовых ограничениях. Экспертная система играет важную роль в анализе законодательной базы и консолидации данных для построения прогнозов и содержит базы данных нормативных актов, связанных с процессом природопользования, модуль для анализа документов, экспертную базу данных, модуль поддержки и принятия управленческих решений, систему генерации отчетности о состоянии природного объекта. Основные функциональные компоненты модуля представлены в таблице 3.

Таблица 3. Основные функциональные компоненты модуля «Экспертная система»

| Класс / Метод | Название процесса | Входные данные | Выходные данные | Исполнитель |
|---|-------------------------------------|--|---|------------------|
| ExpertSystem.integrate_data() | Интеграция данных из моделей и ГИС | Сводные данные из EcoModel.getData() + экспертная база | Сводные данные для анализа | Цифровая системы |
| ExpertSystem.analyze_scenarios() | Многокритериальный анализ сценариев | Сводные данные ExpertSystem.integrate_data() | Оценка рисков и сценариев | Цифровая системы |
| ExpertSystem.generate_recommendations() | Генерация рекомендаций | Оценка сценариев | Рекомендации для регуляторов и природопользователей | Цифровая системы |

Нормативно правовая база актов включает: федеральные и региональные законы, регулирующие природопользование; нормативы и стандарты качества воды и состояния окружающей среды; международные соглашения и экологические программы по улучшению состояния окружающей среды [31–33].

Современные методы обработки текста играют ключевую роль в работе экспертной системы. Для анализа и извлечения информации из нормативно-правовых документов, а также для генерации отчетов используются алгоритмы машинного обучения, искусственные нейронные сети, в частности большие языковые модели [34]. Эти алгоритмы способны выделять ключевую информацию из больших объемов текстов и проводить семантический анализ, сопоставляя содержание документа с текущей ситуацией. В экспертной системе большие языковые модели используются в таких модулях как анализ

документов и системе генерации отчетности о состоянии природного объекта.

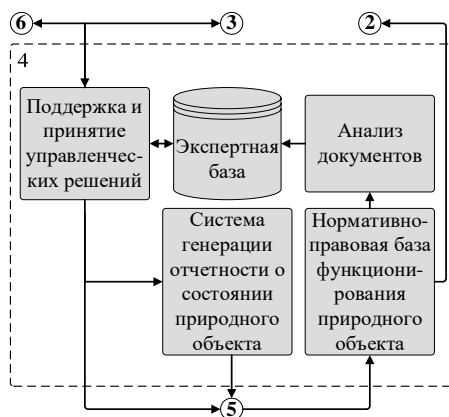


Рис. 5. Структура модуля «Экспертная система»

Ключевым свойством системы является ее адаптивность, обеспечиваемая механизмами непрерывного обновления базы знаний (как за счет поступления новых нормативных актов, так и через накопление прецедентов принятия решений) и динамической калибровки моделей на основе данных мониторинга. Это позволяет рассматривать модуль как интеллектуальный регулятор в контуре управления сложной эколого-технической системой, где объект управления (водный объект) характеризуется существенной нелинейностью, распределенными параметрами и стохастическими возмущениями. Теоретической основой функционирования системы выступает синтез принципов оптимального управления (критерии качества водной среды) и устойчивость к неопределенностям входных данных, что обеспечивает выполнение целевых показателей состояния экосистемы в условиях изменяющихся внешних воздействий. Математический аппарат системы включает: аппарат нечеткой логики для работы с неопределенностями в экспертных знаниях.

Особое внимание уделяется анализу документов. Модуль «Анализ документов» представляет собой автоматизированную систему обработки и семантического анализа нормативно-правовых актов [35], технической документации и регламентирующих материалов, связанных с управлением водными ресурсами. Его основная функция заключается в преобразовании неструктурированных текстовых данных в формализованные знания,

пригодные для интеграции в экспертную систему водного объекта. Основные функциональные компоненты модуля представлены в таблице 4.

Таблица 4. Основные компоненты модуля «Анализ документов»

| Класс / Метод | Название процесса | Входные данные | Выходные данные | Исполнитель |
|--|--|--|------------------------------------|------------------|
| DocAnalyzer.parse() | Сбор и конвертация документов | Государственные реестры, базы законодательства | Структурированные тексты | Цифровая система |
| DocAnalyzer.extract_entities() | Извлечение нормативно-значимых сущностей | Структурированные тексты | Нормативные параметры и связи | Цифровая система |
| DocAnalyzer.integrate_with_expert_db() | Сохранение данных в экспертной БД | Нормативные параметры | Обновлённая экспертная база данных | Цифровая система |

Модуль анализа документов реализует комплексный подход к обработке документов, включающий следующие ключевые процессы: автоматизированный сбор и предварительная обработка документов из разнородных источников (государственные реестры, базы законодательства, локальные хранилища); лингвистический анализ текстов с применением методов обработки естественного языка и машинного обучения; извлечение нормативно-значимых сущностей и параметров; выявление семантических связей и потенциальных противоречий между различными нормативными актами.

В основе работы модуля лежит многоуровневая архитектура обработки данных. На первом уровне осуществляется парсинг и конвертация документов из исходных форматов в структурированное представление. На втором уровне происходит предварительная обработка исходного текста с помощью методов токенизации и морфологического анализа. На третьем уровне применяются алгоритмы машинного обучения, включая трансформерные модели, для семантического анализа текста, распознавания именованных сущностей (выделение нормативов, организаций, географических объектов, дат) и классификации документов. Четвертый уровень отвечает за интеграцию извлеченных данных с экспертными знаниями и нормативными базами, включая механизмы разрешения конфликтов и верификации данных. Пятый уровень отвечает за хранение информации в экспертной базе и полнотекстовый поиск по ней.

Количество выпущенных нормативных и правовых актов, содержащихся в информационной системе, охватывающей все федеральные и ведомственные нормативно-правовые документы, по следующим ключевым запросам: «водные ресурсы», «водные экосистемы», «природные объекты» – составило 2798 единиц. Для дальнейшего анализа было отобрано 500 документов в формате PDF, содержащих наиболее релевантную информацию по теме управления водными объектами и охраны водной среды. Поскольку анализ выбранных документов представляет собой обработку большого объема неструктурированной текстовой информации, были рассмотрены различные подходы с использованием больших языковых моделей (LLM). Таблица 5 демонстрирует сравнительную эффективность различных подходов к реализации языковых моделей при решении задач анализа нормативно-правовой документации. Основным критерием оценки выступало качество ответов (% корректных или релевантных результатов) при работе с запросами, связанными с тематикой водных ресурсов и экосистем.

Таблица 5. Сравнение эффективности различных подходов в реализации языковых моделей

| Модель | Качество ответов, % | Машинное обучение |
|---|---------------------|--------------------------------|
| llama3.1 + similarity_search | 80 | Трансформер |
| RAG llama3.1 | 70 | Трансформер |
| deepseek-r1 | 60 | Трансформер |
| YandexGPT 5 Pro | 90 | Трансформер |
| multilingual-e5-large(Эмбединг) + similarity_search | 80 | Трансформер(XLM-RoBERTa-large) |

Наилучшие показатели продемонстрировала модель YandexGPT 5 Pro, обеспечив 90% качества ответов, что может быть связано с ее обучением на русскоязычных данных. Следует отметить, что YandexGPT 5 Pro – единственная модель из таблицы 5, которая функционировала в облачной среде с ограничением на обработку не более 25 документов за сессию, однако, при увеличении объема обрабатываемых документов точность этой модели потенциально может снизиться.

Также хорошие результаты показали подходы на основе llama3.1 с механизмом similarity search и multilingual-e5-large, достигнув 80% качества. Использование RAG-архитектуры с llama3.1 оказалось менее

эффективным (70%), что, вероятно, связано с ограничениями по полноте и релеванности retrieved-документов. Модель deepseek-g1 показала худший результат – 60%, что может свидетельствовать о недостаточной адаптации к правовой тематике или ограниченной поддержке русского языка. Возможные направления улучшения результатов:

- адаптация моделей к предметной области: дополнительное дообучение на корпусе нормативно-правовых актов, связанных с водными ресурсами и экологическим регулированием, может значительно повысить точность ответов;

- улучшение retrieval-компоненты в RAG: повышение качества поиска релевантных фрагментов, через обучение эмбеддингов – улучшение векторных представлений текста для задач поиска, кластеризации или классификации.

Таблица 6 представляет результаты сравнительного анализа трёх различных подходов к извлечению информации из 500 штук нормативно-правовых документов. Основным критерием эффективности выступает процент корректных извлечений информации по ключевым признакам (тематическая релевантность, точность, полнота).

Таблица 6. Сравнение эффективности LLM и ручного анализа

| Метод | Корректность, % |
|----------------------|-----------------|
| RAG LLM | 76 |
| Регулярные выражения | 49 |
| Эксперт | 98 |

Наибольшую точность продемонстрировал экспертный (ручной) анализ, обеспечив 98% корректности ответов. Это объясняется глубоким пониманием контекста, правовой терминологии и способности интерпретировать сложные формулировки, которые часто остаются за пределами возможностей формализованных алгоритмов. Однако основной недостаток экспертного подхода – низкая скорость обработки и невозможность масштабирования на большие массивы данных без существенных затрат.

Метод с использованием RAG LLM показал 76% корректности ответов, что делает его наиболее сбалансированным подходом с точки зрения соотношения точности и скорости.

Метод на основе регулярных выражений дал лишь 49% корректных результатов, что объясняется его жесткой структурой, неустойчивостью к вариативности юридического языка и

невозможностью учета контекста. Регулярные выражения хорошо работают только при строго повторяющихся шаблонах, но не подходят для обработки юридических текстов с множественными синтаксическими конструкциями и вариациями формулировок.

6. Модуль «Регулирование нормативно-правовой базы».

Модуль «Регулирование нормативно-правовой базы» отвечает за управление водным объектом. В этом модуле результаты работы экспертной системы анализируются лицами, принимающими решения (органы власти и субъекты природопользования), при этом субъектом природопользования может выступать физический объект или цифровой двойник. Принимающие решения лица, опираясь на полученные данные, принимают решение о загрязненности водного объекта и вырабатывают дальнейшие действия по устранению причин загрязнений. Процесс управления водными объектами является циклическим и может быть представлен в виде структуры (рисунок 6). Основные функциональные компоненты модуля представлены в таблице 7.

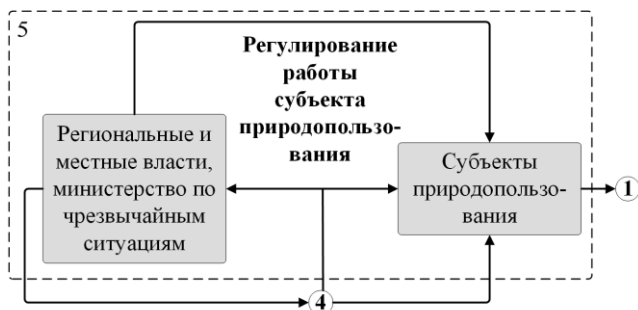


Рис. 6. Структура модуля «Регулирование нормативно-правовой базы»

В процессе принятия решений лицо, принимающее решение сталкивается с множеством разнородных, а зачастую и противоречивых мнений. В связи с этим утверждение о существовании единственного оптимального варианта действий далеко не всегда соответствует действительности.

Следует учитывать, что сама ситуация выбора может иметь многоуровневую структуру и делиться на отдельные взаимосвязанные подзадачи. Каждая из них может быть формализована с помощью специализированной оптимизационной цифровой модели. Таким образом, процесс принятия управленческого решения в сложных условиях можно рассматривать как последовательное решение ряда частных задач, выстроенных в определённой иерархии, а осуществлять управление состоянием природного

нужно объекта, в этом случае, за счет автоматической выработки управленческих решений в рамках цифрового двойника.

Таблица 7. Основные функциональные компоненты модуля «Регулирование нормативно-правовой базы»

| Класс / Метод | Название процесса | Входные данные | Выходные данные | Исполнитель |
|------------------------------------|---|---|--|---|
| RegulationModule.react_changes() | Механизм оперативного реагирования | Отчёты об изменениях законодательства + рекомендации экспертной системы | Новые нормативные требования | Человек + Цифровая система |
| RegulationModule.update_database() | Формирование базы данных нормативных документов | Новые нормативные требования | Актуализированная база нормативных актов | Человек (утверждает) + Цифровая система (загружает) |
| | Формирование предписаний и уведомлений субъектам природопользования | Утвержденные решения, адресаты | Предписания/ уведомления (PDF/API), сроки исполнения | Человек |
| | Учёт исполнения, сбор подтверждений и обратной связи | Предписания, отчеты исполнителей, телеметрия | Статусы исполнения, нарушения сроков | Человек |
| | Применение санкций/стимулов при невыполнении/перевыполнении | Статус исполнения, регламент, санкции | Решение о мерах воздействия | Человек + Цифровая система |

Исходя из этого, опираясь на результаты системного анализа, аналитических прогнозов и рекомендаций экспертной системы предлагается три алгоритма работы:

1. принятие управленческих решений происходит в полуавтоматическом режиме и контролируется ответственным лицом;
2. принятие управленческих решений контролируется ответственным лицом;
3. управленческое решение принимается ответственным лицом с помощью когнитивных и аналитических инструментов,

которые обеспечивают поддержку принятия решений и предоставляются цифровым двойником.

7. Описание работы цифрового двойника водного объекта по предложенной архитектуре. Исходя из описанных выше модулей архитектура цифрового двойника водного объекта представляется схемой на рисунке 7.

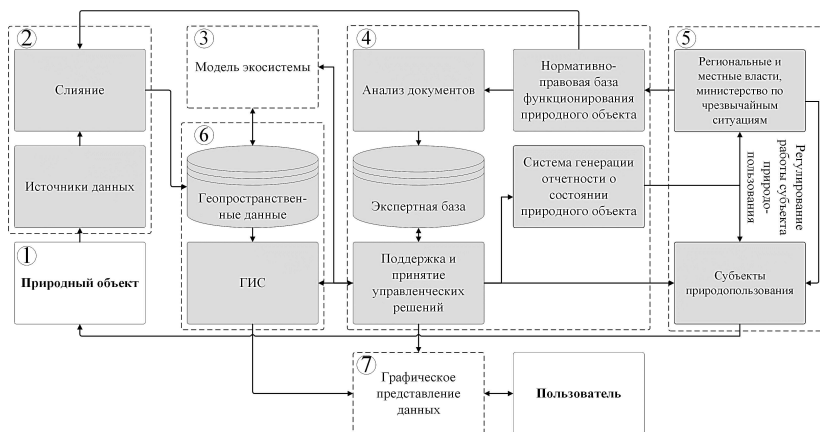


Рис. 7. Архитектура цифрового двойника водного объекта

Рисунок 7 представляет собой расширенную архитектуру цифрового двойника водного объекта с детализированными функциональными модулями и потоками данных, тогда как рисунок 2 демонстрирует укрупнённую структурную схему ключевых модулей без детальной проработки внутренних связей.

Описание принципа работы системы цифрового двойника выглядит следующим образом. В режиме реального времени система сбора и слияния мультимодальных данных фиксирует данные с датчиков мониторинга параметров экосистемы природного объекта в базе геопространственных данных, которая является частью геоинформационной системы. Источниками данных выступают данные с датчиков мониторинга качества воды, таких как измерители температуры, pH и концентрации загрязняющих веществ, а также устройства для отслеживания флоры и фауны природного объекта. Помимо этого, источниками данных являются метеорологические станции и системы дистанционного зондирования Земли, а также модуль экспертной системы нормативно-правовой базы функционирования природного объекта. Полученные данные составляют основу информационного наполнения системы.

Собранные данные передаются в цифровую модель экосистемы, где они обрабатываются и анализируются.

Данные экспертной системы, а также данные из цифровой модели экосистемы передаются в геоинформационную систему. В этой системе информация визуализируется и становится доступной для пространственного анализа. Цифровая модель экосистемы предоставляет экспертной системе необходимые данные для проведения анализа и выработки рекомендаций. Экспертная система использует эти данные вместе с нормативными актами и параметрами, хранящимися в базе геоинформационной системы, чтобы оценить текущее состояние природного объекта и предложить меры по его улучшению, рационализации использования или сохранению.

Из модуля анализа документов выделенная семантическая информация сохраняется в экспертной базе данных для дальнейшей работы модуля поддержки и принятия управленческих решений. На основе новых данных, полученных из цифровой модели и семантических данных из экспертной базы данных модуль поддержки и принятия управленческих решений корректирует внутреннюю работу, принимает решение и передает данные для генерации отчетности о возможных нарушениях в экологической обстановке.

Решение по результатам работы экспертной системы, через систему генерации отчетности направляются субъектам природопользования, таким как компании, занимающиеся добычей полезных ископаемых, сельским хозяйством, лесозаготовкой и другими видами деятельности, оказывающими влияние на природные объекты. Это позволяет им адаптировать свою деятельность под текущие условия и минимизировать негативное воздействие на окружающую среду. Субъекты природопользования и другие цифровые двойники, используют результаты работы цифрового двойника для повышения эффективности своих операций.

Органы управления, такие как Минприроды России, Росводресурсы, Росприроднадзор, Росгидромет, министерство по чрезвычайным ситуациям, а также региональные и местные власти, используют данные экспертной системы для принятия обоснованных решений. Эти решения касаются регулирования использования природных ресурсов, предотвращения экологических угроз и реализации природоохранных мероприятий. Органы управления вносят изменения в базу данных нормативных актов, отражающие новые законодательные инициативы и требования. Эти обновления затем используются экспертной системой при анализе и выработке рекомендаций. Решения, принятые органами управления оказывают

непосредственное воздействие на субъекты природопользования, обязывая их соблюдать установленные стандарты и ограничения.

Представленная архитектура цифрового двойника водного объекта основана на распределенной микросервисной архитектуре. Для программной реализации «цифрового двойника» был определен следующий технологический стек: языки программирования – python, Rust; для контейнеризации и оркестрации сервисов – технологии Docker и Kubernetes; для организации очередей задач между микросервисами – брокер RabbitMQ; для хранения геопространственных данных – СУБД PostgreSQL с расширением PostGIS; авторские библиотеки моделей машинного обучения для классификации и семантической сегментации участков местности, а так же RAG LLM llama3.1 с библиотеками сематического поиска и векторизации текста; для доступа к нормативно-правовым документам – API Гарант.

Создание цифрового двойника водного объекта позволяет оперативнее реагировать на изменения, происходящие в природном объекте. Для примера рассмотрим ситуацию с антропогенным воздействием человека на экосистемы озера Кабан, РФ [36, 37]. При реализации цифрового двойника требуется проследить во времени изменение объекта, в данном случае озера Кабан, а также принятые нормативно-правовые акты, регулирующие воздействие человека.

Исторически известно, что озеро Кабан в Казани начали загрязняться с конца XVII века из-за кожевенных и мыловаренных мастерских, а в XIX–XX веках усугубилось сбросами от заводов (ТЭЦ, химкомбинат, обувной комбинат «Спартак»), что привело к цветению водорослей, гибели экосистемы, накоплению сероводорода, тяжелых металлов. Начиная с 1981 г. благодаря правительственным постановлениям и мерам санэпиднадзора началась «реанимация» с предупреждениями и штрафами предприятиям и уже через 3 года ситуация в озерах улучшилась. Мероприятия проводимые с 1981 по 1994 г.: 1981–1984 г. – прекращение сброса промышленных стоков; канализование и отведение части хозяйственно-фекальных стоков; 1982 г. – создание временной проточности; кратковременная аэрация; 1984–1987 г. – изъятие донных отложений (Нижний Кабан); 1988–1994 г. – изъятие донных отложений (Средний Кабан). В 2011 г. выявили 27 источников стоков на Среднем Кабане, установили фитоочистные каскады с растениями для естественной фильтрации, водные сады и очистные на Нижнем Кабане, что запустило самовосстановление бактериями при закрытии стоков. До конца проблема очистки озер Кабан не решена, но концепция набережных с эко-энергосистемой, экологические нормативы РТ и федеральные

санитарные нормы, привели к благоустройству 1,5 км берегов и снижению токсичности.

Обобщая изложенную выше информацию, можно представить состояния озера Кабан на временной оси. В соответствии с временными метками информация поступает на целевые модули «цифрового двойника» где происходит обработка информации. На рисунке 8 графически представлен процесс обработки информации с привязкой к функциональным модулям архитектуры системы, представленной на рисунке 7. Горизонтальная ось времени иллюстрирует ключевые исторические и современные периоды антропогенного воздействия и восстановления водного объекта: от начального этапа деградации до современного этапа цифрового мониторинга и прогнозирования с помощью «цифрового двойника».




Рис. 8. Привязка модулей цифрового двойника водного объекта к о. Кабан

8. Заключение. Цифровой двойник экосистемы природного объекта в целом, и экосистемы водного объекта в частности, является передовым инструментом управления и контроля. Научная новизна работы заключается в разработке архитектуры цифрового двойника включающего обязательное наличие контура управления экосистемой водного объекта, учитывающего результаты работы экспертной системы, чего ранее не рассматривали существующие подходы. Интеграция методов машинного обучения, анализа больших данных и методов обработки естественного языка обеспечивает возможность выявления скрытых закономерностей, что значительно повышает качество управленческих решений. Предлагаемая архитектура цифрового двойника водного объекта позволяет оперативно реагировать на изменения, оптимизировать процесс природопользования и предотвращать экологические кризисы. Использование такой архитектуры создаёт основу для устойчивого природопользования, позволяя минимизировать негативные воздействия, оперативно реагировать на отклонения от экологических нормативов и обеспечивать долгосрочную сохранность водных объектов.

Литература

1. Jones K.R., Venter O., Fuller R.A., Allan J.R., Maxwell S.L., Negret P.J., Watson J.E. One-third of global protected land is under intense human pressure // *Science*. 2018. vol. 360. no. 6390. pp. 788–791. DOI: 10.1126/science.aap9565.
2. Liu M., Nie Z., Cao L., Wang L., Lu H. Nature-Based Solutions for the Restoration of Groundwater Level and Groundwater-Dependent Ecosystems in a Typical Inland Region in China // *Water*. 2024. vol. 16. no. 1. DOI: 10.3390/w16010033.
3. Bao N., Song W., Ma J., Chu Y. Multi-Source Remote Sensing Analysis of Yilong Lake's Surface Water Dynamics (1965–2022): A Temporal and Spatial Investigation // *Water*. 2024. vol. 16. no. 14. DOI: 10.3390/w16142058.
4. Chen M., Zhang R., Jia M., Cheng L., Zhao C., Li H., Wang Z. Accurate and rapid extraction of aquatic vegetation in the China side of the Amur River Basin based on Landsat imagery // *Remote Sensing*. 2024. vol. 16. no. 4. DOI: 10.3390/rs16040654.
5. Chao F., Jiang X., Wang X., Lu B., Liu J., Xia P. Water level fluctuation rather than eutrophication induced the extinction of submerged plants in Guizhou's Caohai Lake: Implications for lake management // *Water*. 2024. vol. 16. no. 5. DOI: 10.3390/w16050772.
6. Li Y., Tong J., Wang L. Full implementation of the river chief system in China: Outcome and weakness // *Sustainability*. 2020. vol. 12. no. 9. DOI: 10.3390/su12093754.
7. Li H., Jin L., Si Y., Mu J., Liu Z., Liu C., Zhang Y. Lake Restoration Improved Ecosystem Maturity Through Regime Shifts – A Case Study of Lake Baiyangdian, China // *Sustainability*. 2024. vol. 16. no. 21. DOI: 10.3390/su16219372.
8. Aksoy B. Flood Analysis in Lower Filyos Basin Using HEC-RAS and HEC-HMS Software // *Sustainability*. 2025. vol. 17. no. 11. DOI: 10.3390/su17115220.
9. Grochowska J.K., Gozdziejewska A.M., Augustyński-Tunowska R. Changes in the Buffer Properties of the Restored Lake Complex // *Sustainability*. 2024. vol. 16. no. 18. DOI: 10.3390/su16187990.
10. Skwierawski A. Contemporary Evolution and Water Quality of Lakes Rewetted After 19th Century Drainage in the Olsztyn Lake District (Poland) // *Water*. 2024. vol. 16. no. 24. DOI: 10.3390/w16243661.
11. Tammeorg O., Chorus I., Spears B., Noges P., Nurnberg G.K., Tammeorg P., Sondergaard M., Jeppesen E., Paerl H., Huser B., Horppila J., et al. Sustainable lake restoration: From challenges to solutions // *Wiley Interdisciplinary Reviews: Water*. 2024. vol. 11. no. 2. pp. DOI: 10.1002/wat2.1689.
12. Epe T.S., Finsterle K., Yasserli S. Nine years of phosphorus management with lanthanum modified bentonite (Phoslock) in a eutrophic, shallow swimming lake in Germany // *Lake and Reservoir Management*. 2017. vol. 33. no. 2. pp. 119–129. DOI: 10.1080/10402381.2016.1263693.
13. Kasprzak P., Gonsiorczyk T., Grossart H.P., Hupfer M., Koschel R., Petzoldt T., Wauer G. Restoration of a eutrophic hard-water lake by applying an optimised dosage of poly-aluminium chloride (PAC) // *Limnologia*. 2018. vol. 70. pp. 33–48. DOI: 10.1016/j.limno.2018.04.002.
14. Шайгура С.В., Митрофанов Е.М., Жаров В.Г., Феоктистова В.М. Инфраструктура пространственных данных для цифрового двойника лесной экосистемы // *Дизайн и технологии*. 2022. № 91-92(133-134). С. 160–168.
15. Lee S., Kalmus P., Ferraz A., Goodman A., Pearson K., Doran G., Platt F., Hu B., Ekanayaka A., Chakraborty S. Ecopro: Ecological Projection Digital Twin // *IGARSS 2024 – IEEE International Geoscience and Remote Sensing Symposium*. 2024. pp. 2311–2314.
16. Hu D., Zhou C., Xie F. Application of Digital Twin Technology in Assessing the Level of Water Ecological Civilization Construction in Yangtze River Basin // *Hydraulic*

- Structure and Hydrodynamics. 2024. pp. 343–352. DOI: 10.1007/978-981-97-7251-3_30.
17. Потапов В.П., Кузьмин Д.Г., Сероус Т.О. Научно-практические основы проекта «Цифровой Ускат» и особенности его реализации // Уголь. 2022. № 11(1161). С. 40–47. DOI: 10.18796/0041-5790-2022-11-40-47.
 18. Global Runoff Data Centre. URL: <https://portal.grdc.bafg.de/applications/public.html?publicuser=PublicUser#dataDownload/Home> (дата обращения: 25.09.2025).
 19. HydroSHEDS. URL: <https://www.hydrosheds.org/> (дата обращения: 25.09.2025).
 20. USGS National Water Dashboard. URL: <https://dashboard.waterdata.usgs.gov/app/nwd/en/?aoi=default> (дата обращения: 25.09.2025).
 21. ФГИС «Экомониторинг». URL: <https://rfi.mnr.gov.ru/projects/247/> (дата обращения: 25.09.2025).
 22. Frolov A.V., Asmus V.V., Borshch S.V., Vil'fand R.M., Zhabina I.I., Zatyagalova V.V., Krovotyntsev V.A., Kudryavtseva O.I., Leont'eva E.A., Simonov Y.A., Stepanov Y.A. GIS-Amur system of flood monitoring, forecasting, and early warning // Russian Meteorology and Hydrology. 2016. vol. 41. pp. 157–169. DOI: 10.3103/S1068373916030018.
 23. GIS «Meteo DV» URL: <https://meteo-dv.ru/> (дата обращения: 25.09.2025).
 24. Дерюгина В.В., Василенко Е.В., Кровотынцев В.А., Кухарский А.В. Технологические решения при создании спутникового сегмента информационной системы мониторинга наводнений в бассейне р. Волга // Интерэкспо Гео-Сибирь. 2022. Т. 4. С. 40–47. DOI: 10.33764/2618-981X-2022-4-40-47.
 25. Дерюгина В.В., Борщ С.В., Кровотынцев В.А., Симонов Ю.А. ВЕБ ГИС системы мониторинга и прогнозирования гидрологической обстановки в бассейнах крупных рек России с использованием наземных и спутниковых данных // Материалы 17-й Всероссийской открытой конференции «Современные проблемы дистанционного зондирования Земли из космоса» (г. Москва, 11–15 ноября 2019). М.: ИКИ РАН, 2019. С. 84.
 26. Фролова Н.Л., Самсонов Т.Е., Киреева М.Б., Семин В.Н., Эн-тин А.Л. Веб-приложение «Водный режим рек Европейской территории России»: структура и функциональные возможности // Водное хозяйство России: проблемы, технологии, управление. 2024. № 2. С. 6–22. DOI: 10.35567/19994508-2024-2-6-22.
 27. Щепетова В.А. Основы математического моделирования в экологии: монография. Пенза: ПГУАС. 2015. 122 с.
 28. Dihan M.S., Akash A.I., Tasneem Z., Das P., Das S.K., Islam M.R., Islam M.M., Badal F.R., Ali M.F., Ahamed M.H., et al. Digital twin: Data exploration, architecture, implementation and future // Heliyon. 2024. vol. 10. no. 5. DOI: 10.1016/j.heliyon.2024.e26503.
 29. Patonai K., Fabian V.A. Comparison of three modelling frameworks for aquatic ecosystems: practical aspects and applicability // Community Ecology. 2022. vol. 23. no. 3. pp. 439–451. DOI: 10.1007/s42974-022-00117-3.
 30. Bai J., Zhao J., Zhang Z., Tian Z. Assessment and a review of research on surface water quality modeling // Ecological Modelling. 2022. vol. 466. DOI: 10.1016/j.ecolmodel.2022.109888.
 31. Воеводина Л.А., Воеводин О.В. О необходимости внесения изменений в водный комплекс РФ // Экология и водное хозяйство. 2021. Т. 3. № 2. С. 99–112. DOI: 10.31774/2658-7890-2021-3-2-99-112.

32. Josefsson H. The Water Framework Directive and Transnational Situations: A Call to Rethink Transboundary Water Management? // *Journal for European Environmental & Planning Law*. 2025. vol. 22. no. 1-2. pp. 168–186. DOI: 10.1163/18760104-22010209.
33. Biswas S., Dandapat B., Alam A., Satpati L. India's achievement towards sustainable Development Goal 6 (Ensure availability and sustainable management of water and sanitation for all) in the 2030 Agenda // *BMC Public Health*. 2022. vol. 22. no. 1. DOI: 10.1186/s12889-022-14316-0.
34. Матвеева А.Р., Антонов Е.В. Методика формирования базы данных характеристик сложного технологического объекта с использованием больших языковых моделей. *Вестник НИЯУ МИФИ*. 2024. Т. 13(5). pp. 350–357. DOI: 10.26583/vestnik.2024.5.7.
35. Бирюкова Е.Д., Миронов А.С. Методы подготовки данных для алгоритмов классификации текста // *Информационные технологии XXI века: сборник научных трудов*. Хабаровск: Тихоокеанский государственный университет, 2023. С. 180–185.
36. Фролова Л.Л., Мингазова Н.М. Сравнительный анализ выбора восстановительных технологий для озер Кабан г. Казани // *Вестник Тамбовского университета, сер.: Естественные и технические науки*. 1996. Т. 1. № 2. С. 166–168.
37. Meeting on the elimination of industrial wastewater releases into Sredniy Kaban Lake. URL: <https://eco.tatarstan.ru/eng/index.htm/news/127082.htm?ysclid=mjka2htb45872248994> (дата обращения: 10.12.2025).

Миронов Андрей Сергеевич — канд. техн. наук, доцент высшей школы, высшая школа кибернетики и цифровых технологий, Тихоокеанский государственный университет (ТОГУ). Область научных интересов: подводная робототехника, обработка сигналов, аппаратные и программные средства определения координат в морской среде, разработка цифровых двойников природных объектов и экосистем, алгоритмы обработки информации с использованием методов машинного обучения, проектирование навигационных систем и систем связи. Число научных публикаций — 100. andrei.s.mironov@yandex.ru; Тихоокеанская улица, 136, 680035, Хабаровск, Россия; р.т.: +7(421)222-4356.

Саенко Александр Александрович — аспирант, высшая школа кибернетики и цифровых технологий, Тихоокеанский государственный университет (ТОГУ). Область научных интересов: разработка цифровых двойников природных объектов, мультисенсорные системы сбора и обработки измерительной информации, методы повышения эффективности компьютерного зрения для гидроакустических систем. Число научных публикаций — 8. saa2410@mail.ru; Тихоокеанская улица, 136, 680035, Хабаровск, Россия; р.т.: +7(924)105-9678.

Фомина Екатерина Сергеевна — старший преподаватель высшей школы, высшая школа кибернетики и цифровых технологий, Тихоокеанский государственный университет (ТОГУ). Область научных интересов: программные средства определения координат в морской среде, методы и средства обработки информации, получаемой с мультисенсорных систем технического зрения, включая применение методов машинного обучения и системный анализ. Число научных публикаций — 51. fominaekt@gmail.com; Тихоокеанская улица, 136, 680035, Хабаровск, Россия; р.т.: +7(999)082-8010.

Поддержка исследований. Исследование выполнено за счет гранта Российского научного фонда №24-11-20024 «Методы и средства построения цифровых моделей русла, береговой линии и водоохранной зоны реки Амур и ее основных притоков».

A. MIRONOV, A. SAENKO, E. FOMINA
**DEVELOPMENT OF A DIGITAL TWIN ARCHITECTURE FOR
AN AQUATIC ECOSYSTEM TO PRESERVE ENVIRONMENTAL
SUSTAINABILITY**

Mironov A., Saenko A., Fomina E. **Development of a Digital Twin Architecture for an Aquatic Ecosystem to Preserve Environmental Sustainability.**

Abstract. The purpose of this work is to develop a digital twin architecture of an aquatic ecosystem to preserve environmental sustainability, including monitoring, forecasting, and management of water resources in the context of anthropogenic impact and climate change. The paper proposes a modular digital twin architecture that includes a module for collecting and combining multimodal data, digital ecosystem models, an expert system, a regulatory framework module, a geographic information system, and a graphical data representation module. The architecture is based on the integration of data from sensors, satellites, weather stations, and remote sensing systems, using machine learning models and large language models to analyze regulatory documentation. The developed architecture of the digital twin of a water body allows monitoring ecosystem parameters in real time, assessing compliance with regulatory requirements, and generating reports and recommendations for organizations involved in natural resource management and governing bodies. The effectiveness of various models of legal text processing was tested, and optimal approaches to their semantic analysis were determined. The expediency of integrating the digital twin into the state environmental management system is substantiated. The digital twin architecture proposed by the authors is a comprehensive tool for sustainable water resources management that allows predicting the state of water bodies, timely identifying risks and developing scientifically sound management solutions, thereby reducing environmental threats and preserving water resources.

Keywords: digital twin, water resources, aquatic ecosystems, natural resource management, expert system.

References

1. Jones K.R., Venter O., Fuller R.A., Allan J.R., Maxwell S.L., Negret P.J., Watson J.E. One-third of global protected land is under intense human pressure. *Science*. 2018. vol. 360. no. 6390. pp. 788–791. DOI: 10.1126/science.aap9565.
2. Liu M., Nie Z., Cao L., Wang L., Lu H. Nature-Based Solutions for the Restoration of Groundwater Level and Groundwater-Dependent Ecosystems in a Typical Inland Region in China. *Water*. 2024. vol. 16. no. 1. DOI: 10.3390/w16010033.
3. Bao N., Song W., Ma J., Chu Y. Multi-Source Remote Sensing Analysis of Yilong Lake's Surface Water Dynamics (1965–2022): A Temporal and Spatial Investigation. *Water*. 2024. vol. 16. no. 14. DOI: 10.3390/w16142058.
4. Chen M., Zhang R., Jia M., Cheng L., Zhao C., Li H., Wang Z. Accurate and rapid extraction of aquatic vegetation in the China side of the Amur River Basin based on Landsat imagery. *Remote Sensing*. 2024. vol. 16. no. 4. DOI: 10.3390/rs16040654.
5. Chao F., Jiang X., Wang X., Lu B., Liu J., Xia P. Water level fluctuation rather than eutrophication induced the extinction of submerged plants in Guizhou's Caohai Lake: Implications for lake management. *Water*. 2024. vol. 16. no. 5. DOI: 10.3390/w16050772.
6. Li Y., Tong J., Wang L. Full implementation of the river chief system in China: Outcome and weakness. *Sustainability*. 2020. vol. 12. no. 9. DOI: 10.3390/su12093754.

7. Li H., Jin L., Si Y., Mu J., Liu Z., Liu C., Zhang Y. Lake Restoration Improved Ecosystem Maturity Through Regime Shifts – A Case Study of Lake Baiyangdian, China. *Sustainability*. 2024. vol. 16. no. 21. DOI: 10.3390/su16219372.
8. Aksoy B. Flood Analysis in Lower Filyos Basin Using HEC-RAS and HEC-HMS Software. *Sustainability*. 2025. vol. 17. no. 11. DOI: 10.3390/su17115220.
9. Grochowska J.K., Gozdziejewska A.M., Augustyniak-Tunowska R. Changes in the Buffer Properties of the Restored Lake Complex. *Sustainability*. 2024. vol. 16. no. 18. DOI: 10.3390/su16187990.
10. Skwierawski A. Contemporary Evolution and Water Quality of Lakes Rewetted After 19th Century Drainage in the Olsztyn Lake District (Poland). *Water*. 2024. vol. 16. no. 24. DOI: 10.3390/w16243661.
11. Tammeorg O., Chorus I., Spears B., Noges P., Nurnberg G.K., Tammeorg P., Sondergaard M., Jeppesen E., Paerl H., Huser B., Horppila J., et al. Sustainable lake restoration: From challenges to solutions. *Wiley Interdisciplinary Reviews: Water*. 2024. vol. 11. no. 2. pp. DOI: 10.1002/wat2.1689.
12. Epe T.S., Finsterle K., Yasseri S. Nine years of phosphorus management with lanthanum modified bentonite (Phoslock) in a eutrophic, shallow swimming lake in Germany. *Lake and Reservoir Management*. 2017. vol. 33. no. 2. pp. 119–129. DOI: 10.1080/10402381.2016.1263693.
13. Kasprzak P., Gonsiorczyk T., Grossart H.P., Hupfer M., Koschel R., Petzoldt T., Wauer G. Restoration of a eutrophic hard-water lake by applying an optimised dosage of poly-aluminium chloride (PAC). *Limnologica*. 2018. vol. 70. pp. 33–48. DOI: 10.1016/j.limno.2018.04.002.
14. Shaitura S.V., Mitrofanov E.M., Zharov V.G., Feoktistova V.M. [Spatial data infrastructure for forest ecosystem digital twin]. *Dizajn i tehnologii – Design and technology*. 2022. no. 91-92(133-134). pp. 160–168. (In Russ.).
15. Lee S., Kalmus P., Ferraz A., Goodman A., Pearson K., Doran G., Platt F., Hu B., Ekanayaka A., Chakraborty S. Ecopro: Ecological Projection Digital Twin. *IGARSS 2024 – IEEE International Geoscience and Remote Sensing Symposium*. 2024. pp. 2311–1214.
16. Hu D., Zhou C., Xie F. Application of Digital Twin Technology in Assessing the Level of Water Ecological Civilization Construction in Yangtze River Basin. *Hydraulic Structure and Hydrodynamics*. 2024. pp. 343–352. DOI: 10.1007/978-981-97-7251-3_30.
17. Potapov V. P., Kuzmin D. G., Serous T.O. [Scientific and practical foundations of the Digital Uskat Project and specific features of its implementation]. *Ugol’ – Coal*. 2022. no. 11(1161). pp. 40–47. (In Russ.). DOI: 10.18796/0041-5790-2022-11-40-47.
18. Global Runoff Data Centre. Available at: <https://portal.grdc.bafg.de/applications/public.html?publicuser=PublicUser#dataDownload/Home>. (accessed 25.09.2025).
19. HydroSHEDS. Available at: <https://www.hydrosheds.org/>. (accessed 25.09.2025).
20. USGS National Water Dashboard. Available at: <https://dashboard.waterdata.usgs.gov/app/nwd/en/?aoi=default>. (accessed 25.09.2025).
21. FGIS «E'konitoring» [FGIS «Ecomonitoring»]. Available at: <https://rfi.mnr.gov.ru/projects/247/>. (accessed 25.09.2025).
22. Frolov A.V., Asmus V.V., Borshch S.V., Vil'fand R.M., Zhabina I.I., Zatyagalova V.V., Krovotyntsev V.A., Kudryavtseva O.I., Leont'eva E.A., Simonov Y.A., Stepanov Y.A. GIS-Amur system of flood monitoring, forecasting, and early warning. *Russian Meteorology and Hydrology*. 2016. vol. 41. pp. 157–169. DOI: 10.3103/S1068373916030018.
23. GIS «Meteo DV». Available at: <https://meteo-dv.ru/>. (accessed 25.09.2025).

24. Deryugina V.V., Vasilenko E.V., Krovotintsev V.A., Kukharsky A.V. [Technological solutions used of the development segment of the flood monitoring information system in the Volga river basin]. *Intere'kspo Geo-Sibir' – Interexpo Geo-Siberia*. 2022. vol. 4. pp. 40–47. DOI: 10.33764/2618-981X-2022-4-40-47. (In Russ.).
25. Deryugina V.V., Borshch S.V., Krovotyntsev V.A. Simonov Yu.A. [WEB GIS system for monitoring and forecasting the hydrological situation in the basins of large rivers in Russia using ground and satellite data] *Materialy 17-j Vserossijskoj otkrytoj konferencii «Sovremennye problemy distancionnogo zondirovaniya Zemli iz kosmosa» [Proceedings of the 17th All-Russian open conference Modern Problems of Remote Sensing of the Earth from Space]*. Moscow: IKI RAN. 2019. pp. 84. (In Russ.).
26. Frolova N.L., Samsonov T.E., Kireyeva M.V., Semin V.N., Entin A.L. [WEB application «Water Regime of the Rivers of the European Part of Russia»: Structure and functionality]. *Vodnoe xozyajstvo Rossii: problemy, tehnologii, upravlenie – Water Sector of Russia: Problems, Technologies, Management*. 2024. no. 2. pp. 6–22. DOI: 10.35567/19994508-2024-2-6-22. (In Russ.).
27. Shhepeta V.A. *Osnovy matematicheskogo modelirovaniya v e'kologii: monografiya*. [Fundamentals of mathematical modeling in ecology: monograph]. Penza: PSUAC. 2015. 122 p. (In Russ.).
28. Dihan M.S., Akash A.I., Tasneem Z., Das P., Das S.K., Islam M.R., Islam M.M., Badal F.R., Ali M.F., Ahamed M.H., et al. Digital twin: Data exploration, architecture, implementation and future. *Heliyon*. 2024. vol. 10. no. 5. DOI: 10.1016/j.heliyon.2024.e26503.
29. Patonai K., Fabian V.A. Comparison of three modelling frameworks for aquatic ecosystems: practical aspects and applicability. *Community Ecology*. 2022. vol. 23. no. 3. pp. 439–451. DOI: 10.1007/s42974-022-00117-3.
30. Bai J., Zhao J., Zhang Z., Tian Z. Assessment and a review of research on surface water quality modeling. *Ecological Modelling*. 2022. vol. 466. DOI: 10.1016/j.ecolmodel.2022.109888.
31. Voevodina L.A., Voevodin O.V. [On the need to making amendments to the water code of the Russian Federation]. *E'kologiya i vodnoe xozyajstvo – Ecology and water management*. DOI: 10.31774/2658-7890-2021-3-2-99-112. (In Russ.).
32. Josefsson H. The Water Framework Directive and Transnational Situations: A Call to Rethink Transboundary Water Management? *Journal for European Environmental & Planning Law*. 2025. vol. 22. no. 1-2. pp. 168–186. DOI: 10.1163/18760104-22010209.
33. Biswas S., Dandapat B., Alam A., Satpati L. India's achievement towards sustainable Development Goal 6 (Ensure availability and sustainable management of water and sanitation for all) in the 2030 Agenda. *BMC Public Health*. 2022. vol. 22. no. 1. DOI: 10.1186/s12889-022-14316-0.
34. Matveeva A.R., Antonov E.V. [Methodology for forming a database of characteristics of a complex technological object using large language models]. *Vestnik Natsional'nogo Issledovatel'skogo Yadernogo Universiteta «MIFI»*. 2024. vol. 13. no. 5. pp. 350–357. (In Russ.).
35. Biryukova E.D., Mironov A.S. [Methods for data preparation for text classification algorithms]. *Informacionnye tehnologii XXI veka: sbornik nauchnyx trudov [Technologies of the XXI Century: Collection of Scientific Papers]*. Khabarovsk: Pacific National University. 2023. pp. 180–185. (In Russ.).
36. Frolova L.L., Mingazova N.M. [Comparative analysis of restoration technologies to be chosen for lakes Kaban of Kazan] *Vestnik Tambovskogo universiteta. Seriya Estestvennye i tehniczeskie nauki – Tambov university reports. Series: Natural and technical sciences*. 1996. vol. 1. no. 2. pp. 166–168. (In Russ.).

37. Meeting on the elimination of industrial wastewater releases into Sredniy Kaban Lake. Available at: <https://eco.tatarstan.ru/eng/index.htm/news/127082.htm?ysclid=mjka2htb45872248994> (accessed 10.12.2025).

Mironov Andrey — Ph.D., Associate professor at the Higher School, Higher School of Cybernetics and Digital Technologies, Pacific National University (PNU). Research interests: underwater robotics, signal processing, hardware and software for determining coordinates in the marine environment, development of digital twins of natural objects and ecosystems, information processing algorithms using machine learning methods, design of navigation and communication systems. The number of publications — 100. andrei.s.mironov@yandex.ru; 136, Tikhookeanskaya St., 680035, Khabarovsk, Russia; office phone: +7(421)222-4356.

Saenko Aleksandr — Ph.D. student, Higher School of Cybernetics and Digital Technologies, Pacific National University (PNU). Research interests: development of digital twins of natural objects, multisensory systems for collecting and processing measurement information, methods for improving the efficiency of computer vision for hydroacoustic systems. The number of publications — 8. saa2410@mail.ru; 136, Tikhookeanskaya St., 680035, Khabarovsk, Russia; office phone: +7(924)105-9678.

Fomina Ekaterina — Senior lecturer at the Higher School, Higher School of Cybernetics and Digital Technologies, Pacific National University (PNU). Research interests: software tools for determining coordinates in the marine environment, methods and tools for processing information obtained from multisensor technical vision systems, including the application of machine learning methods and system analysis. The number of publications — 51. fominaekt@gmail.com; 136, Tikhookeanskaya St., 680035, Khabarovsk, Russia; office phone: +7(999)082-8010.

Acknowledgements. The research was supported by the Russian Science Foundation (grant No. 24-11-20024).